

# Predição de pressão sanguínea através de sinais de fotopletismografia usando redes neurais MLP e LSTM

## Blood pressure prediction through photoplethysmography signals using MLP and LSTM neural networks

Gustavo S. Cardoso<sup>1</sup>, Mateus G. Lucas<sup>2</sup>, Samuel S. Cardoso<sup>2</sup>

<sup>1</sup>Departamento de Comunicações/Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, Brasil

<sup>2</sup>Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, Brasil

### Resumo

A pressão arterial é um dos sinais vitais básicos dos seres humanos e sua aferição deve ser feita regularmente durante o dia por pessoas que possuam algum tipo de doença cardiovascular. Os métodos tradicionais de medição geralmente precisam realizar a oclusão de uma artéria, causando desconforto ao paciente. Isto impede o monitoramento contínuo de pressão e até mesmo desencoraja um monitoramento regular durante o dia. Tendo em vista tal problema, neste trabalho são apresentados e comparados dois algoritmos de aprendizado de máquinas que utilizam sinais de fotopletismografia (PPG) para estimar a pressão arterial sem a necessidade da oclusão da artéria. O primeiro algoritmo implementado foi uma reprodução do método proposto por Kurylyak *et al.*, o qual serviu de referência para o desenvolvimento da rede LSTM (Long Short-Term Memory) proposta neste trabalho, a qual utilizou as características temporais do sinal de PPG como parâmetros de entrada. Para o treinamento dos algoritmos foi utilizada a base de dados MIMIC II (Multiparameter Intelligent Monitoring in Intensive Care). Para avaliação desses métodos foram feitas análises estatísticas dos resultados obtidos com relação aos valores de referência da pressão arterial, já definidos nas bases de dados. Os resultados obtidos indicam que a arquitetura baseada na rede LSTM utilizando características temporais do sinal de PPG como parâmetro de entrada podem produzir melhores resultados quando comparado com a rede MLP (Multi Layer Perceptron).

**Palavras-chave:** fotopletismografia; aprendizado de máquina; pressão arterial; LSTM.

### Abstract

Blood pressure is one of the basic vital signs of human beings and its measurement must be done regularly during the day by people who have some type of cardiovascular disease. Traditional methods of measurement usually need to occlude an artery, causing discomfort to the patient. This prevents continuous pressure monitoring and even discourages regular monitoring during the day. In view of this problem, in this work, two machine learning algorithms using photoplethysmography (PPG) signals are presented and compared to estimate blood pressure without the need for artery occlusion. The first algorithm implemented was a reproduction of the method proposed by Kurylyak *et al.*, which served as a reference for the development of the LSTM (Long Short-Term Memory) network proposed in this work, which used the temporal characteristics of the PPG signal as parameters input. For the training of the algorithms, the MIMIC II database (Multiparameter Intelligent Monitoring in Intensive Care) was used. For the evaluation of these methods, statistical analyzes of the results obtained were carried out in relation to the blood pressure reference values, already defined in the databases. The results obtained indicate that the architecture based on the LSTM network using temporal characteristics of the PPG signal as an input parameter can produce better results when compared to the MLP (Multi Layer Perceptron) network.

**Keywords:** photoplethysmography; machine learning; blood pressure; LSTM.

### 1. Introdução

A hipertensão arterial primária é uma doença que não tem cura, além de atacar mais de trinta milhões de brasileiros (1). O tratamento normalmente consiste em alimentação balanceada, atividades físicas, uso de medicação e monitoração regular da pressão arterial durante o dia para mantê-la dentro de valores adequados (2). Medir a pressão arterial significa obter o maior (pressão sistólica - SBP) e o menor valor (pressão diastólica - DBP) de pressão durante o ciclo cardíaco (2).

Alguns métodos tradicionais para medição de pressão arterial, como o auscultatório e o oscilométrico, indicam apenas o valor de pressão para um determinado ciclo cardíaco. Além disto, estes métodos necessitam realizar oclusão da artéria no local de medição, ou seja, realizam força interrompendo o fluxo sanguíneo na região, o que causa desconforto ao indivíduo que tem a pressão aferida (3, 4).

Devido às complicações dos métodos tradicionais de medição de pressão arterial, diversos métodos não invasivos estão sendo estudados ao redor do mundo, com o objetivo de possibilitar maior conforto e segurança para a monitoração contínua de pressão. Entre as técnicas de medição de sinal bioelétrico que têm sido intensamente estudadas devido ao seu potencial para aplicações de monitoramento contínuo e não invasivo de pressão se destaca a técnica de PPG (Figura 1).

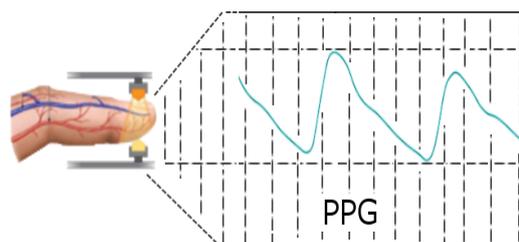


Figura 1. Representação da técnica de fotopletismografia.

Existem na literatura muitos trabalhos que estudam a utilização de sinais de PPG para estimar a pressão arterial. Em (5) utilizou-se uma técnica chamada PTT (*pulse transit time*), que usa sinais de PPG e de eletrocardiografia (ECG). Já em (6) são utilizados dois sinais de PPG aquiridos de pontos distintos para serem utilizados em um método chamado PWV (*pulse wave velocity*). Embora factíveis, estes métodos apresentam certa complexidade de implementação devido à necessidade de sincronização entre os diferentes sinais, além da própria dificuldade de aquisição de mais um sinal, o que poderá aumentar a instrumentação do projeto. Nesse contexto, outros autores procuram desenvolver algoritmos utilizando apenas parâmetros extraídos dos sinais de PPG. Desta forma, métodos que utilizam apenas um sinal de PPG podem ser embasados em algoritmos de regressão e características de domínio tempo e ou frequência do sinal conforme demonstrado nos trabalhos (7–10). Dentre estes trabalhos, a referência (7) destaca-se, por seu resultado ficar compreendido dentro dos padrões propostos por (11). Contudo, em trabalhos similares como em (10,12,13) os resultados obtidos ficam fora desses padrões.

Neste contexto esse trabalho busca reproduzir a rede neural e o método desenvolvido por (7) comparando seu desempenho com a rede neural proposta neste trabalho para estimar a pressão sanguínea.

Nas seções seguintes são detalhados os processos de desenvolvimento e teste da proposta. Na seção 2 é apresentada a metodologia geral do trabalho. Na seção 3 são descritos os resultados alcançados. Por fim, na seção 4 são apresentadas as discussões e na seção 5 as conclusões.

## 2. Materiais e Métodos

### 2.1. Metodologia de teste

Para a realização dos testes e a comparação dos algoritmos foram utilizadas características do sinal de PPG no domínio do tempo treinando essas redes sobre toda a faixa de pressão (80 a 180 mmHg) ou subdividindo os dados em mais de uma faixa (80 a 100 mmHg, 100 a 140 mmHg e 140 a 180 mmHg) para aplicar os algoritmos de regressão.

### 2.2. Base de dados

Os dados foram extraídos da base apresentada em (5), que é uma versão pré-processada e validada da base MIMIC II disponibilizada pela organização *PhysioNet*, formada por milhares de sinais amostrados a 125Hz com resolução mínima de 8 bits. Foram extraídos da base MIMIC II sinais de PPG captados na ponta do dedo, ECG do canal II e sinal de pressão arterial captado invasivamente de milhares de indivíduos. Muitos sinais possuíam trechos deteriorados devido a diferentes distorções e artefatos, sendo necessário um pré-processamento, realizado dividindo as amostras em blocos de tamanho fixo e executando as seguintes etapas em cada um desses blocos: filtragem com filtro de

médias móveis, remoção de blocos com valores irregulares e inaceitáveis de pressão arterial, remoção de blocos com taxa de batimento cardíaco inaceitável, remoção de blocos com grandes descontinuidades mesmo após a filtragem por médias móveis, cálculo de autocorrelação do sinal de PPG e remoção de blocos com alta dissimilaridade.

Alguns poucos sinais dessa base possuíam artefatos de movimento. Por inspeção visual, esses trechos foram identificados e foi descartado todo o trecho desde o início do artefato de movimento até o fim do sinal. Um total de 147 trechos foi descartado nesta etapa.

Por último foi feita a detecção de picos e vales utilizando o algoritmo apresentado em (14) com seguimentos constantes de 8 amostras (janela de 64 ms). Esse algoritmo foi escolhido devido à simplicidade de implementação em dispositivos embarcados. A detecção dos picos e vales é importante para extração das características no domínio do tempo.

### 2.3. Características extraídas

Foram extraídas dos sinais de PPG as características temporais descritas em (7), conforme ilustrado na Figura 2.

Em (7) são utilizadas 21 características temporais do sinal de PPG para o treinamento de redes MLP. O número elevado de características é utilizado para contornar a variabilidade dos dados entre indivíduos diferentes para um mesmo valor de pressão devido a características fisiológicas de cada indivíduo.

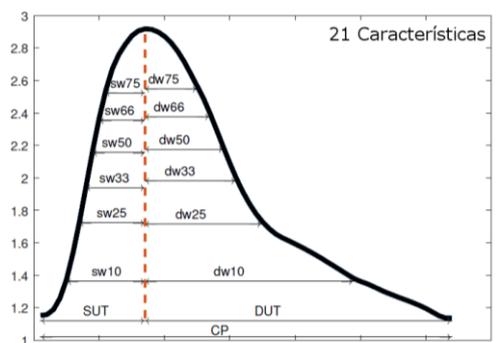


Figura 2. Características temporais extraídas do sinal de PPG.

### 2.4. Faixas de pressão

Os testes realizados foram feitos treinando os algoritmos utilizando dados em toda a faixa de pressão disponível do banco de dados, já nos outros casos seguiu-se a metodologia descrita em (9), em que os dados foram divididos em três categorias de acordo com o valor de pressão arterial sistólica - hipotensivos (80 a 100 mmHg), normotensivos (100 a 140 mmHg) e hipertensivos (140 a 180 mmHg) - e os algoritmos foram treinados em cada uma dessas faixas.

### 2.5. Redes neurais

Para estimar a pressão arterial sistólica (SBP) e diastólica (DBP) a partir das características do sinal

de PPG foram utilizadas duas redes neurais uma rede MLP e outra LSTM.

A rede proposta por (7), a qual foi reproduzida neste trabalho foi uma *perceptron* multicamadas (MLP - *multilayer perceptron*) com a primeira camada oculta contendo 35 neurônios e a segunda camada com 20 neurônios. A camada de saída foi composta por dois neurônios, sendo um para a SBP e outro para a DBP (Figura 3).

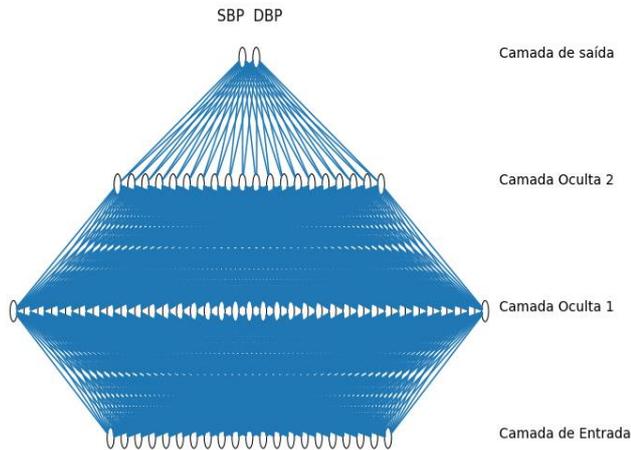


Figura 3. Estrutura da rede proposta por (7) (RNA-MLP).

A rede LSTM proposta neste trabalho para realizar a predição da pressão sanguínea foi composta por duas camadas. A primeira camada foi composta por 64 unidades, já a segunda camada foi constituída por 32 unidades. Além disso, assim como a rede anterior a camada de saída da rede foi construída com dois neurônios um para cada pressão sanguínea, o primeiro para a SBP e o segundo para a DBP (Figura 4).

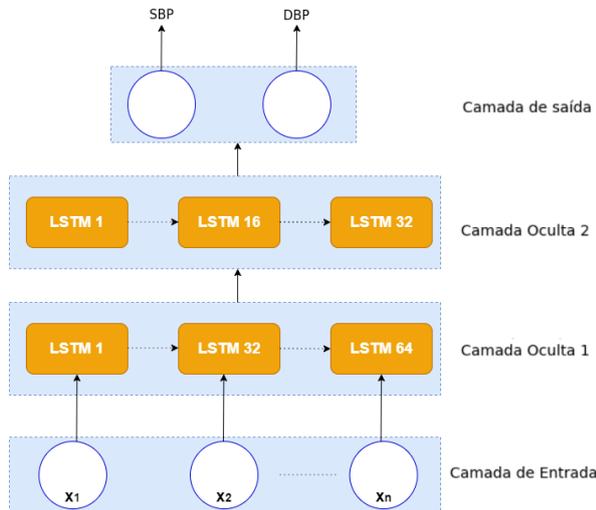


Figura 4. Estrutura da rede proposta neste trabalho (LSTM).

### 2.6. Experimentos

O desenvolvimento do experimento se deu por meio de um conjunto de avaliações realizadas sobre as redes neurais descritas anteriormente. Ao todo foram realizados dois testes variando diferentes parâmetros da rede proposta em (7) e dois testes para a rede proposta neste trabalho. As avaliações realizadas sobre estes dois casos estão ilustradas na Figura 5 pelo diagrama de fluxo de testes.



Figura 5. Diagrama de fluxo de testes para rede proposta por (7) (RNA-MLP) e pela rede proposta neste trabalho (LSTM).

### 3. Resultados

As avaliações dos resultados obtidos apresentados nesta seção empregam como métrica de desempenho o erro médio absoluto (MAE - *mean absolute error*) e o desvio padrão (SD - *standard deviation*) dos erros de pressão. Como já mencionado, para que o erro e o desvio padrão satisfaçam os requisitos propostos por (11), os mesmos devem permanecer abaixo de  $5 \pm 8$  mmHg, respectivamente.

Inicialmente foram realizados testes sobre a rede neural proposta por (7). A Tabela 1 apresenta os erros obtidos nos testes com esta rede. Os ensaios foram realizados conforme o diagrama de fluxo de testes descritos na Figura 5. Dentre estes ensaios foram realizados treinamentos da rede MLP para toda a faixa de pressão e para três distintas faixas de pressão separadamente com a finalidade de melhorar o desempenho desta rede.

Tabela 1. Erros para a rede neural proposta por (7) de acordo com a faixa de pressão escolhida para o treinamento.

Faixa	DBP (mmHg)	SBP (mmHg)
Geral	7,34 ± 7,05	15,58 ± 14,78
80 a 100 mmHg	5,36 ± 6,29	5,63 ± 3,75
100 a 140 mmHg	6,49 ± 5,78	8,49 ± 6,19
140 a 180 mmHg	7,63 ± 6,57	8,78 ± 5,50

Fonte: O autor (2021).

Posteriormente foram feitos testes sobre a rede neural proposta por este trabalho. A Tabela 2 ilustra os erros para este caso. Assim como na rede anterior os ensaios foram realizados conforme o diagrama de fluxo de testes descritos na Figura 3. Desta maneira a rede foi treinada para toda a faixa de pressão do banco de dados e também para as três faixas distintas de pressão sanguínea ilustradas na Figura 5.

Tabela 2. Erros para rede neural LSTM proposta neste trabalho de acordo com a faixa de pressão escolhida para o treinamento.

Faixa	DBP (mmHg)	SBP (mmHg)
Geral	7,53 ± 7,34	12,57 ± 10,33
80 a 100 mmHg	6,14 ± 6,89	5,32 ± 3,92
100 a 140 mmHg	5,08 ± 5,96	4,97 ± 5,21
140 a 180 mmHg	6,65 ± 7,90	6,32 ± 4,70

Fonte: O autor (2021).

### 4. Discussão

Observa-se na Tabela 1 que os resultados obtidos para a rede neural e metodologia proposta por (7), a qual foi reproduzida neste trabalho, divergem dos resultados obtidos no trabalho original, exibindo

erros mais elevados. Essa divergência pode ser observada também nos trabalhos (12) e (13), que também reproduziram a rede e o método descrito em (7) e apresentaram erros comparáveis aos encontrados neste trabalho (Tabela 3). Uma possível explicação para os melhores resultados observados em (7) é a de que os sinais de PPG foram segmentados em trechos contendo apenas um batimento. Ao dividir os trechos obtidos em conjuntos de treino e validação, diversos segmentos de um mesmo sinal acabam em ambos os conjuntos, podendo dar origem a um sobreajuste do modelo treinado em (7), explicando os melhores resultados obtidos.

**Tabela 3.** Erros obtidos para as reproduções da rede neural e do método que foram propostos em (7).

Artigo	DBP (mmHg)	SBP (mmHg)
(7)	2,21 ± 2,09	3,80 ± 3,46
(12)	7,7 ± 6,6	15,1 ± 13,3
(13)	6,63 ± 6,22	13,30 ± 9,41
Reprodução neste trabalho	7,34 ± 7,05	15,58 ± 14,78

Fonte: O autor (2021).

Os resultados apresentados na Tabela 1 ainda indicam que o desempenho pode ser melhor quando desenvolvido uma rede por cada faixa de pressão sanguínea do que quando se faz o treinamento de uma única rede neural para toda a excursão da SBP e da DBP. Embora o desempenho melhore para este caso, em nenhuma das ocasiões as redes MLP produzem resultados dentro dos padrões propostos por (11).

Com relação aos resultados apresentados na Tabela 2 relativos à rede neural proposta neste trabalho, destaca-se a substancial melhora sobre o erro que cai 3 mmHg em relação a rede proposta por (7) para o treinamento feito sobre a faixa geral da SBP. Por outro lado, nota-se uma pequena piora na predição de DBP para este caso, mas que é ínfima quando comparado à melhora da predição de SBP.

Ainda comparando os resultados obtidos pela proposta deste trabalho é possível averiguar que o treinamento das redes por faixas distintas também originou melhores resultados com a rede LSTM. Comparando a Tabela 1 com a Tabela 2 para este caso, observa-se que apenas o erro estimado sobre a faixa de 80 a 100 mmHg sofre um pequeno aumento no erro para as estimativas da DBP. Embora ocorra uma leve piora sobre o erro da DBP neste caso, observa-se a redução dos erros para as demais faixas. Além disso, na faixa de 100 a 140 mmHg a rede proposta produziu erros praticamente dentro dos limites aceitáveis por (11). Para este caso cabe destacar a SBP que para esta faixa fica dentro do limite aceitável.

## 5. Conclusões

Este trabalho apresenta a avaliação de duas redes neurais utilizadas para a predição da pressão sanguínea. O trabalho em questão reproduz o método e a rede neural proposta em (7) e propõe a arquitetura de uma rede neural com duas camadas

LSTM ocultas, uma contendo 64 unidades e outra contendo 32 unidades.

A partir dos resultados obtidos conclui-se que em geral a arquitetura da rede neural proposta neste trabalho estima melhor a pressão sanguínea do que a rede MLP (7).

Os resultados relativos à reprodução do método e da arquitetura MLP proposta em (7) vão ao encontro dos resultados obtidos nos trabalhos (12,13) que constata o desempenho deficiente desta rede.

No geral, a rede proposta neste trabalho produziu um erro de  $7,53 \pm 7,34$  mmHg para a DBP e  $12,57 \pm 10,33$  para a SBP na faixa geral de pressão arterial, mostrando melhor desempenho que a rede MLP do trabalho (7). Além disso, em comparação a rede MLP a arquitetura proposta produziu resultados muito próximos aos limites de erro quando treinada para distintas faixas de pressão.

Por fim, em trabalhos futuros existem potenciais melhoras que devem ser realizadas como, por exemplo, o uso de características temporais em conjunto com as características espectrais do sinal. Além disso, o uso de redes convolucionais para a extração das características do sinal de PPG em detrimento da extração a prior destas características temporais também deve ser avaliado.

## Referências

- Malachias MV, Plavnik FL, Machado CA, Malta D, Scala LC, Fuchs S. 7ª Diretriz Brasileira de Hipertensão Arterial: Capítulo 1-Conceituação, Epidemiologia e Prevenção Primária. Arquivos Brasileiros de Cardiologia. 2016 Sep;107(3):1-103.
- Brasil. Ministério da Saúde. Cadernos de Atenção Básica – nº 15: Hipertensão Arterial Sistêmica. Brasil: 2006.
- Hall JE. Guyton e Hall: Tratado de Fisiologia Médica. 13th ed Rio de Janeiro: Elsevier Editora Ltda. 2017:227-41.
- Shioya K, Dohi T. Blood pressure measurement device based on the arterial tonometry method with micro triaxial force sensor. In 2013 Transducers & Eurosensors XXVII: The 17th International Conference on Solid-State Sensors, Actuators and Microsystems (TRANSDUCERS & EUROSENSORS XXVII) 2013 Jun 16 (pp. 2389-2392). IEEE.
- Kachuee M, Kiani MM, Mohammadzade H, Shabany M. Cuffless high-accuracy calibration-free blood pressure estimation using pulse transit time. In 2015 IEEE international symposium on circuits and systems (ISCAS) 2015 May 24 (pp. 1006-1009). IEEE.
- Nabeel PM, Jayaraj J, Mohanasankar S. Single-source PPG-based local pulse wave velocity measurement: a potential cuffless blood pressure estimation technique. Physiological measurement. 2017 Nov 28;38(12):2122.
- Kurylyak Y, Lamonaca F, Grimaldi D. A Neural Network-based method for continuous blood pressure estimation from a PPG signal. In 2013 IEEE International instrumentation and measurement technology conference (I2MTC) 2013 May 6 (pp. 280-283). IEEE.
- Xing X, Sun M. Optical blood pressure estimation with photoplethysmography and FFT-based neural networks. Biomedical optics express. 2016 Aug 1;7(8):3007-20.
- Khalid SG, Zhang J, Chen F, Zheng D. Blood pressure estimation using photoplethysmography only: comparison between different machine learning approaches. Journal of healthcare engineering. 2018 Oct 23;2018.
- Slapničar G, Mlakar N, Luštrek M. Blood pressure estimation from photoplethysmogram using a spectro-temporal deep neural network. Sensors. 2019 Jan;19(15):3420.
- Association for the Advancement of Medical Instrumentation. American national standards for electronic or automated sphygmomanometers. ANSI/AAMI SP 10-1987. 1987.
- Liu M, Po LM, Fu H. Cuffless blood pressure estimation based on photoplethysmography signal and its second derivative.

International Journal of Computer Theory and Engineering.  
2017 Jun 1;9(3):202.

13. Bersano N, Sanson H. Non-invasive blood pressure estimation from photoplethysmography signals using artificial neural networks. In 2018 20th International Conference on Advanced Communication Technology (ICACT) 2018 Feb 11 (pp. 29-35). IEEE.
14. Kavsaoglu AR, Polat K, Bozkurt MR. An innovative peak detection algorithm for photoplethysmography signals: an adaptive segmentation method. Turkish Journal of Electrical Engineering & Computer Sciences. 2016 Mar 23;24(3):1782-96.

**Contato:**

Gustavo dos Santos Cardoso  
UNICAMP  
Av. Albert Einstein, 400 – Campinas, SP  
g264375@dac.unicamp.br