

## USO DE APRENDIZAGEM DE MÁQUINA PARA DETECÇÃO DE ARRITMIA CARDÍACA EM SINAIS DE ELETROCARDIOGRAMA

João Vitor Mendes Pinto dos Santos<sup>1</sup>; Thamiles Rodrigues de Melo<sup>2</sup>

<sup>1</sup> Graduando em Engenharia de Computação; Iniciação científica – CNPq; joao.v.m.p.santos@ieee.org

<sup>2</sup> Centro Universitário SENAI CIMATEC; Salvador - BA; thamiles.melo@doc.senaicimatec.edu.br

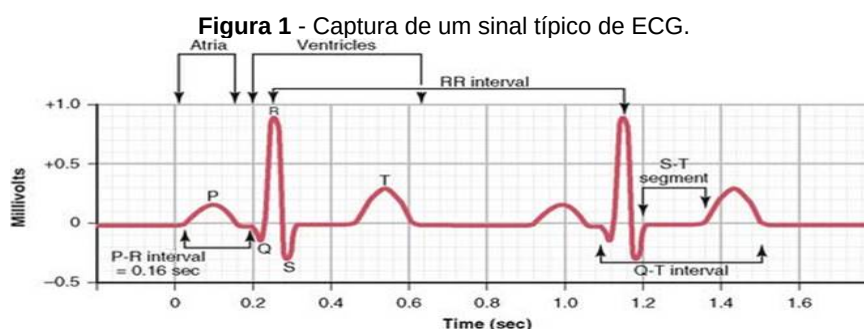
### RESUMO

O sistema cardiovascular é essencial para a fisiologia humana, regulando a circulação sanguínea no corpo. Doenças Cardiovasculares (DCVs), como as arritmias cardíacas, podem alterar o ritmo dos batimentos cardíacos, afetando assim a circulação sanguínea. A modelagem computacional de caixa-preta desse sistema pode facilitar o desenvolvimento de novos métodos e dispositivos para auxiliar no diagnóstico e tratamento de DCVs. As Redes Neurais Artificiais (RNA) são uma abordagem tipo caixa-preta eficaz. Para implementá-las, seleciona-se uma base de dados, separam-se os conjuntos de treinamento e teste e define-se a estrutura do modelo. A base de dados MIT-BIH é amplamente utilizada para o treinamento de modelos computacionais na detecção de arritmias cardíacas. Os resultados preliminares com o modelo de RNA treinado com dados da MIT-BIH não alcançaram os objetivos esperados, apresentando diversos problemas. No entanto, sendo este um modelo inicial, ainda há potencial para otimizações, podendo eventualmente se tornar uma ferramenta valiosa para o diagnóstico de arritmias cardíacas.

**PALAVRAS-CHAVE:** Eletrocardiograma; Arritmias Cardíacas; Inteligência Artificial; Machine Learning

### 1. INTRODUÇÃO

O sistema cardiovascular é essencial para a fisiologia humana, regulando a circulação sanguínea no organismo. Um funcionamento inadequado desse sistema compromete a pressão e o fluxo sanguíneo, além de dificultar a distribuição adequada de oxigênio e nutrientes por todo o corpo, essenciais para manter bons níveis fisiológicos. Alterações fisiológicas podem ser causadas por doenças cardiovasculares (DCVs), que representam uma das principais causas de morte mundialmente, contabilizando um total de 17,9 milhões de óbitos, o que representa 31% das mortes globais<sup>1</sup>. O sistema elétrico do coração pode ser representado por um eletrocardiograma (ECG) ilustrado na Figura 1, no qual contém todas as informações das ondas que atuam no ciclo cardíaco. Entre as DCVs, as arritmias cardíacas são alterações elétricas que modificam o intervalo de tempo entre os complexos QRS do sinal de ECG, ocasionando modificações no ritmo dos batimentos cardíacos e, por consequência, desregulando todo o sistema cardiovascular<sup>2</sup>.



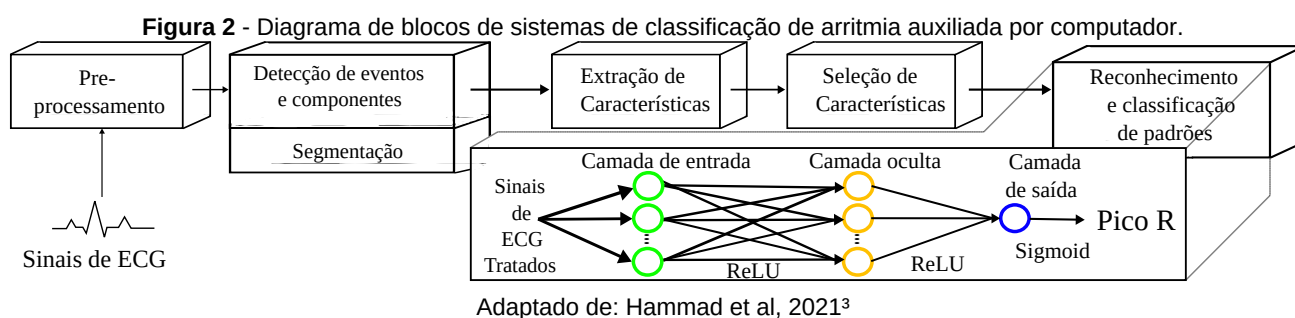
Fonte: Guyton, 2011<sup>2</sup>

A modelagem computacional do sistema cardiovascular humano possibilita a compreensão da fisiologia do coração, bem como viabilizam o desenvolvimento de métodos ou dispositivos destinados ao diagnóstico e à terapia de doenças cardiovasculares. O sistema cardiovascular como a maior parte dos fenômenos físicos são sistemas Não Lineares e Variantes no Tempo (NLVT), o que dificulta a aplicação de métodos analíticos clássicos de modelagem e controle para se trabalhar nesta situação. A modelagem de caixa-preta é um método de identificação de sistemas cuja premissa baseia-se no trabalho com um conjunto de entradas e saídas de forma heurística, visando chegar a um modelo matemático aproximado sem necessidade de modelar o comportamento físico real do sistema. A Inteligência Artificial (IA) tem sido adotada como uma ferramenta poderosa para construir soluções usando o método de modelagem de caixa-preta, principalmente porque o *Machine Learning* (ML), uma de suas subáreas, possibilita a criação de modelos computacionais conhecidos como redes neurais artificiais (RNA). Essas redes passam por um processo de treinamento utilizando conjuntos de dados, e o resultado desse treinamento é a geração de um modelo computacional capaz de realizar a função desejada<sup>3</sup>.

Dentro do contexto apresentado, o objetivo desta pesquisa é construir um modelo de rede neural que possa identificar localização dos picos R do sinal de ECG para avaliar o ritmo cardíaco do paciente e auxiliar no diagnóstico de arritmias cardíacas.

## 2. METODOLOGIA

Na Figura 2 ilustra-se o processo comum de treinamento dos modelos matemáticos das arquiteturas de redes neurais de ML. Para seguir o processo indicado, a base de dados de ECG escolhida foi a MIT-BIH<sup>4</sup>, reconhecida como uma das bases de dados mais utilizadas em artigos científicos<sup>5</sup>. A arquitetura de RNA selecionada foi o classificador de perceptron multicamadas (MLP). A configuração do MLP, demonstrada na Figura 2, foi definida com três camadas: a camada de entrada, com 20 neurônios, utiliza a função de ativação *rectified linear unit* (ReLU) e está conectada à camada oculta, que possui 10 neurônios também ativados pela função ReLU. Esta, por sua vez, está ligada à camada de saída, que utiliza a função de ativação sigmoid, e cujo resultado é o desfecho esperado. A implementação do classificador MLP será feito nas bibliotecas TensorFlow e scikit-learn do ambiente de desenvolvimento da linguagem de programação python.




As etapas de treinamento e validação do modelo computacional são feitas com o uso de um conjunto de registros da base de dados<sup>4</sup> para o treinamento e um segundo conjunto para realizar os testes e validar o modelo. Para o treinamento inicial, utilizou-se um conjunto unitário que contém o registro 100, escolhido porque o sinal apresenta boa qualidade e seu ritmo sinusal está dentro da faixa esperada para um coração saudável<sup>4</sup>. Para o conjunto de testes, foram selecionados 6 registros de forma aleatória. Isso visa verificar a eficácia do modelo em reconhecer padrões em qualquer registro, independentemente de sua condição ser previamente desconhecida. Para avaliar o desempenho do modelo, foram utilizadas as médias das métricas de Precisão (PRC), Revocação (RV), Pontuação F1 (F1) e Exatidão (EX), obtidos através dos valores de Verdadeiro Positivo (Vp), Verdadeiro Negativo (Vn), Falso Positivo (Fp) e Falso Negativo (Fn), métricas conforme descritas na literatura<sup>6</sup>.

## 3. RESULTADOS E DISCUSSÃO

Na Figura 3 exibem-se os resultados das previsões obtidas pelo modelo de RNA treinado, os resultados apresentaram três comportamentos: a identificação de um único pico por onda R na figura 3(a), a marcação de vários picos na mesma onda R na figura 3(b) e a não identificação de nenhum pico R na figura(c)

**Figura 3** - Gabarito temporal da predição dos picos R: (a) marcação correta; (b) várias marcações no mesmo pico; (c) ausência de marcação



Fonte: Elaborado pelo autor

Os resultados da Tabela 1 apresentam que as previsões do modelo possuem uma baixa taxa de valores Fp, entretanto uma alta taxa de Fn; isso explica a alta precisão e a baixa revocação do modelo na ISSN 0805-2010 - Anuário de resumos expandidos apresentados no IX SAPCT - SENAI CIMATEC, 2024

escala de 0 a 1, respectivamente. A média da pontuação F1 nos permite afirmar que o desempenho do modelo é mediano, pois a revocação é muito baixa. O modelo treinado é ineficaz para o registro 114, pois nenhum pico R detectado era um Vp, e por isso apenas possui exatidão. No geral, a exatidão do modelo é alta, porque essa métrica considera todos os resultados e o desequilíbrio da quantidade entre as classes de picos R e não picos R, onde sinais de pico R são mais difíceis de obter.

**Tabela 1** - Métricas adotadas para avaliar o desempenho do modelo de RNA treinado.

| Registro de teste | $PRC = \frac{Vp}{Vp + Fp}$ | $RV = \frac{Vp}{Vp + Fn}$ | $F1 = \frac{2 * PRC * RV}{PRC + RV}$ | $Ex = \frac{Vp + Vn}{Vp + Vn + Fp + Fn}$ |
|-------------------|----------------------------|---------------------------|--------------------------------------|--|
| 105               | 0,83                       | 0,66                      | 0,73                                 | 0,99                                     |
| 114               | 0                          | 0                         | 0                                    | 0,99                                     |
| 121               | 0,89                       | $4,26 * 10^{-3}$          | $8,48 * 10^{-3}$                     | 0,99                                     |
| 200               | 0,90                       | 0,38                      | 0,53                                 | 0,99                                     |
| 215               | 0,93                       | 0,67                      | 0,77                                 | 0,99                                     |
| 228               | 0,78                       | 0,36                      | 0,49                                 | 0,99                                     |
| Média             | 0,72                       | 0,35                      | 0,42                                 | 0,99                                     |

Fonte: Elaborado pelo autor

Um fator contribuinte para estes resultados pode ser o uso de apenas um registro para o treinamento do modelo, ocasionando em uma base de dados insuficiente. Além disso, outros aspectos que podem estar afetando o desempenho incluem ruídos no sinal de ECG, bem como a precisão das posições dos picos R utilizadas no treinamento. Estes desafios são pertinentes, respectivamente, às etapas de pré-processamento e detecção de eventos e ondas do sinal de ECG. Como alternativas para solucionar esses problemas, Hammad et al.<sup>3</sup> e Xiao et al.<sup>5</sup>, em suas revisões sistemáticas da literatura, recomendam o uso de filtros tradicionais e wavelets para a remoção de ruídos, o algoritmo de Pan-Tompkins e o filtro Savitzky-Golay.

#### 4. CONSIDERAÇÕES FINAIS

Neste trabalho foi proposto um sistema de identificação de arritmias cardíacas usando RNA para auxiliar nos diagnósticos médicos. O modelo de RNA construído no ambiente de desenvolvimento de python conseguiu identificar picos R do sinal de ECG. Os resultados obtidos até o momento não alcançaram os objetivos desejados da pesquisa; no entanto, o desenvolvimento do modelo encontra-se em estágio inicial, com diversas otimizações pendentes. Além disso, existem várias arquiteturas de RNA mais modernas que podem ser exploradas no futuro, incluindo, *Convolutional Neural Network*, *Long Short-Term Memory* e até mesmo arquiteturas híbridas.

#### Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro na realização dessa pesquisa.

#### 5. REFERÊNCIAS

- <sup>1</sup> OPAS, Organização Pan-Americana da Saúde. **Doenças Cardiovasculares**. 2017. Disponível em: <<https://www.paho.org/pt/topicos/doencas-cardiovasculares>>. Acesso em: 29 set. 2023.
- <sup>2</sup> GUYTON, A. C.; HALL, J. E. Tratado de fisiologia médica. 12. ed. São Paulo, SP: Elsevier, 2011.
- <sup>3</sup> HAMMAD, Mohamed; KANDALA, Rajesh N.V.P.S.; ABDELATEY, Amira; et al. Automated detection of shockable ECG signals: A review. **Information Sciences**, v. 571, p. 580–604, 2021.
- <sup>4</sup> MOODY, George B; MARK, Roger G. MIT-BIH Arrhythmia Database. Disponível em: <<https://physionet.org/content/mitdb/>>. Acesso em: 15 mar. 2024.
- <sup>5</sup> XIAO, Qiao; LEE, Khuan; MOKHTAR, Siti Aisah; et al. Deep Learning-Based ECG Arrhythmia Classification: A Systematic Review. **Applied Sciences**, v. 13, n. 8, p. 4964, 2023.
- <sup>6</sup> NAHIDUZZAMAN, Md.; NAYEEM, Md. Julker; AHMED, Md. Toukir; et al. Prediction of Heart Disease Using Multi-Layer Perceptron Neural Network and Support Vector Machine. In: **2019 4th International Conference on Electrical Information and Communication Technology (EICT)**. [s.l.: s.n.], 2019, p. 1–6. ISSN 0805-2010 - Anuário de resumos expandidos apresentados no IX SAPCT - SENAI CIMATEC, 2024