



## SISTEMA COMPUTACIONAL PARA AUXILIAR A ANÁLISE DE ELETROCARDIOGRAMA VIA SEGMENTAÇÃO DAS ONDAS

Marcos Rafael Nogueira Moreira

<http://lattes.cnpq.br/4817557925131604>

João Victor da Silva Alves

<http://lattes.cnpq.br/083379529992506>

Yonara Costa Magalhães

<http://lattes.cnpq.br/8188763596503654>

Jonathan Araujo Queiroz

<http://lattes.cnpq.br/7145102625820184>

### RESUMO

O seguinte trabalho apresenta uma releitura e aplicação sobre diversos algoritmos desenvolvidos no campo de pesquisa em análise de eletrocardiogramas e detecção de arritmias, tendo em vista a utilização destes para desenvolvimento de tecnologias que sejam integradas no futuro, resultando em um sistema completo e inteligente de análise e segmentação de eletrocardiogramas utilizando aprendizado de máquina e outras técnicas estatísticas de alta ordem, com o objetivo de determinar, identificar e classificar possíveis arritmias em usuários. Sua motivação parte da necessidade crescente de prestar assistência a regiões onde se observa um desfalque significativo no que diz respeito à realização de exames cardiológicos, seja pela escassez de profissionais qualificados, limitações tecnológicas ou até mesmo pela ausência do aparato necessário para um diagnóstico preciso. O trabalho não visa remover a atuação protagonista do médico cardiologista na área, mas sim auxiliar com ferramentas que facilitem e atinjam essas regiões citadas, integrando o paciente com o profissional em casos de não disponibilidade de tais profissionais na área de residência do paciente.

**Palavras-chave:** Saúde; Estatística; Computação; Arritmias; Processamento de dados

### 1 INTRODUÇÃO

As doenças cardiovasculares (DCVs) representam a principal causa de morte no Brasil e no mundo. Segundo o Ministério da Saúde, após o pico da pandemia de Covid-19 em 2021, as DCVs voltaram a ocupar o primeiro lugar entre as causas de óbito no país, com cerca de 400 mil mortes registradas em 2022 (BRASIL, 2023).

Esse cenário é ainda mais preocupante em regiões com baixo Índice de Desenvolvimento Humano (IDH), onde o acesso a exames preventivos e tratamentos especializados é limitado. Fatores socioeconômicos como pobreza, alimentação

inadequada, escassez de profissionais da saúde e infraestrutura hospitalar precária contribuem significativamente para o agravamento das DCVs (OLIVEIRA et al., 2020).

Além do impacto direto na saúde da população, as DCVs geram custos financeiros elevados ao sistema público de saúde. Estima-se que o infarto do miocárdio, por exemplo, tenha acarretado um custo de R\$ 22,4 bilhões ao Brasil em um único ano, seguido por insuficiência cardíaca e hipertensão (STEVENS et al., 2018).

Este trabalho tem como objetivo propor o desenvolvimento de um sistema computacional capaz de auxiliar na análise de eletrocardiogramas (ECG) por meio da segmentação automatizada das ondas cardíacas. A proposta visa oferecer uma solução tecnológica de baixo custo, com potencial de aplicação em comunidades vulneráveis e regiões com infraestrutura limitada.

A solução será estruturada em duas etapas principais. A primeira consiste na criação de um software baseado em algoritmos de processamento digital de sinais e aprendizado de máquina, com foco na segmentação das ondas P, QRS e T dos traçados eletrocardiográficos. A segunda etapa prevê a integração do software a sistemas embarcados, como microcontroladores e sensores ECG portáteis, permitindo a coleta e análise dos sinais em tempo real.

O sistema será treinado com bases de dados públicas de ECG, como o MIT-BIH Arrhythmia Database, e validado por meio de métricas como acurácia, sensibilidade e especificidade. A segmentação precisa das ondas permitirá a detecção automatizada de arritmias, contribuindo para diagnósticos mais rápidos e confiáveis, especialmente em locais onde não há disponibilidade de cardiologistas.

A proposta apresentada busca aliar inovação tecnológica à promoção da saúde pública, oferecendo uma ferramenta acessível e eficaz para o diagnóstico de arritmias cardíacas. Ao focar em regiões de baixo IDH, o projeto contribui para a redução das desigualdades no acesso à saúde, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS), especialmente o ODS 3 (Saúde e Bem-estar) e o ODS 9 (Indústria, Inovação e Infraestrutura).

## **2 DESENVOLVIMENTO**

### **2.1 Referencial Teórico**

O objetivo dessa pesquisa se encontra em amenizar o impacto de arritmias em áreas de risco, onde os Determinantes Sociais da Saúde (SDoH) indicam um impacto maior dessas doenças cardiovasculares.

Conforme Powell-Wiley et al. (2022), os SDoH que abrangem fatores econômicos, sociais, ambientais e psicossociais, desempenham um papel fundamental no desenvolvimento e na mortalidade por doenças cardiovasculares (DCV). A pandemia de COVID-19 escancarou iniquidades em saúde pré-existentes na sociedade, impulsionadas por esses determinantes. O autor elabora uma pesquisa que corrobora fatos e dados com esses fatores determinísticos para o aumento de casos como esses, tal qual a mortalidade deles.

A carência de acesso a exames cardiológicos de qualidade, motivada por limitações econômicas e geográficas, não é um problema restrito ao Brasil. Como destacado por Farooq et al. (2022) em seu estudo sobre o Paquistão, áreas rurais subdesenvolvidas



enfrentam barreiras similares, onde a pobreza e a infraestrutura de transporte precária são os principais obstáculos para um tratamento suficiente. Os autores afirmam que 'a morte de muitos pacientes cardíacos se deve à falta de tratamento adequado ou à inacessibilidade de exames e tratamentos médicos caros' (FAROOQ et al., 2022, p. 8, tradução pelo autor). Esta realidade espelha a necessidade brasileira, explicitada pelos dados de Alves (2022), e justifica a busca por soluções tecnológicas acessíveis em ambos os contextos.

A aplicação de sistemas computacionais na análise de sinais eletrocardiográficos tem se mostrado uma abordagem promissora para o diagnóstico precoce de doenças cardiovasculares. Segundo Meneses (2023), técnicas matemáticas, estatísticas e de aprendizado de máquina podem ser integradas para classificar condições cardíacas com confiabilidade estatística, contribuindo para a triagem de pacientes e apoio ao diagnóstico clínico. O uso de bases de dados públicas, como PhysioNet, permite o treinamento de algoritmos com grande diversidade de sinais, aumentando a robustez dos modelos.

A segmentação de ondas cardíacas (P, QRS, T) é uma etapa crítica no processamento de ECG. Marinho (2021) propõe uma abordagem baseada em redes neurais convolucionais com regressão profunda para realizar a segmentação e classificação de arritmias em um único lote de processamento. Essa técnica permite a identificação precisa de eventos cardíacos, mesmo em sinais com ruído ou variações morfológicas, o que é essencial para aplicações em ambientes clínicos com recursos limitados.

Além disso, algoritmos de machine learning têm demonstrado alta acurácia na detecção de arritmias como fibrilação atrial e síndrome do QT longo. Nascimento et al. (2022) realizaram uma revisão sistemática que mostrou que modelos de aprendizado de máquina alcançam acurácia superior a 96%, com sensibilidade e especificidade elevadas, superando métodos convencionais em diversos cenários clínicos.

Esses estudos fundamentam a proposta de um sistema computacional acessível e eficaz para análise de ECG, especialmente voltado para regiões de baixo IDH, onde o acesso a especialistas é limitado. A combinação de técnicas de segmentação, classificação e inteligência artificial pode democratizar o diagnóstico cardiológico e reduzir a mortalidade por arritmias.

## 2.2 Metodologia

Para o desenvolvimento e validação dos algoritmos propostos neste estudo, foram utilizadas uma base de dados pública amplamente reconhecidas na literatura científica: MIT-BIH Normal Sinus Rhythm Database. A MIT-BIH Normal Sinus Rhythm Database contém 18 registros de ECG com duração aproximada de 24 horas cada. Os indivíduos incluídos nesta base não apresentavam arritmias significativas, sendo considerados saudáveis do ponto de vista cardiológico. A amostra é composta por cinco homens, com idades entre 26 e 45 anos, e treze mulheres, com idades entre 20 e 50 anos (GOLDBERGER et al., 2000).

Os sinais de ECG foram segmentados em ciclos cardíacos de um segundo, definidos por janelas de 400 ms antes e 600 ms após a ocorrência da onda R, conforme metodologia



descrita por Queiroz et al. (2017). Essa abordagem permite capturar as principais componentes do ciclo cardíaco, como as ondas P, QRS e T, com precisão temporal adequada para análise morfológica e espectral.

A etapa de pré-processamento é essencial para garantir a qualidade dos sinais utilizados na análise e no treinamento dos algoritmos. Neste estudo, foi adotado o algoritmo de Pan e Tompkins (1985), amplamente utilizado para detecção de complexos QRS em sinais ECG. Este algoritmo apresenta elevada eficiência, com taxa de acerto superior a 99,3% na identificação de complexos QRS na base de dados MIT-BIH.

O algoritmo é composto por uma sequência de operações que incluem:

- Filtragem passa-banda, combinando filtros passa-baixa e passa-alta para eliminar ruídos de baixa e alta frequência;
- Derivação temporal, para realçar as variações rápidas do sinal associadas ao complexo QRS;
- Função de quadratura, que eleva ao quadrado os valores do sinal para destacar os picos;
- Integração por janela móvel, que suaviza o sinal e facilita a detecção de eventos cardíacos;
- Limiar adaptativo e decisão lógica, para identificar a posição exata dos complexos QRS.

Durante o pré-processamento, foram removidos os seguintes tipos de ruído e artefatos:

- a) Ruído de linha de energia (60 Hz), comum em ambientes hospitalares e laboratoriais;
- b) Desvio da linha de base, causado por movimentos respiratórios e variações posturais;
- c) Ruído de contato do eletrodo, devido à má aderência entre o eletrodo e a pele;
- d) Artefatos de movimento, provocados por deslocamentos do eletrodo durante a coleta;
- e) Contrações musculares não cardíacas, que interferem na morfologia do sinal;
- f) Ruído eletrocirúrgico, gerado por equipamentos médicos operando em frequências entre 100 kHz e 1 MHz;
- g) Ruído de instrumentação, proveniente dos próprios dispositivos de aquisição de ECG.

Após a remoção dos ruídos, o sinal foi normalizado em amplitude e ajustado para uma frequência de amostragem de 256 Hz, com resolução de 12 bits e faixa de medição de até 10 milivolts. Os primeiros e últimos 1% de cada registro foram descartados, devido à presença de erros de medição comuns no início e fim da coleta.

Com os dados devidamente organizados, iniciou-se a etapa de extração dos sinais ECG, posteriormente transformados em arrays numéricos. Tais arrays consistem em estruturas de dados compostas por variáveis homogêneas, adequadas para representar sinais digitais de forma compacta e eficiente.

No pré-processamento, foram aplicados filtros de passagem alta e baixa. O objetivo foi eliminar ruídos de baixa frequência, como os relacionados a movimentos respiratórios, e de alta frequência, como interferências eletromagnéticas, preservando apenas as componentes relevantes do sinal cardíaco.

A validação dos algoritmos será realizada por meio de métricas de desempenho amplamente reconhecidas, como acurácia, sensibilidade, especificidade e F1-score. Essas métricas serão obtidas comparando os resultados fornecidos pelo sistema com as anotações de referência do MIT-BIH. Adicionalmente, pretende-se utilizar outros bancos de dados públicos que contenham ECGs classificados por tipo de arritmia. Essa estratégia permitirá avaliar a capacidade de generalização e predição do sistema em diferentes cenários clínicos, ampliando sua robustez e aplicabilidade.

O ambiente de desenvolvimento foi construído utilizando a linguagem de programação Python, apoiada por um conjunto robusto de bibliotecas, incluindo:

- NumPy: manipulação de arrays numéricos;
- SciPy: processamento de sinais;
- Matplotlib: visualização gráfica;
- Pandas: manipulação de dados em dataframes;
- WFDB: leitura e manipulação de dados de fisiologia da plataforma PhysioNet.

O processamento foi realizado em servidores locais configurados com suporte a processamento paralelo, garantindo maior eficiência computacional durante as etapas de pré-processamento, segmentação e validação.

As etapas descritas constituem a base metodológica para o desenvolvimento do sistema proposto. As especificações detalhadas de hardware, bem como os resultados obtidos nas simulações, serão apresentadas e discutidas na seção de Resultados e Discussões deste trabalho, onde se avaliará a efetividade da metodologia adotada.

## 2.3 Resultados

Os resultados discutidos a seguir foram alcançados em uma infraestrutura de máquina baseada composta por Macbook Air M1, 256 gigabytes de armazenamento e 8 gigabytes de memória RAM. Este foi o computador utilizado para processamento e segmentação dos sinais de eletrocardiograma, evidenciando um uso otimizado e de baixo custo computacional para a tarefa.

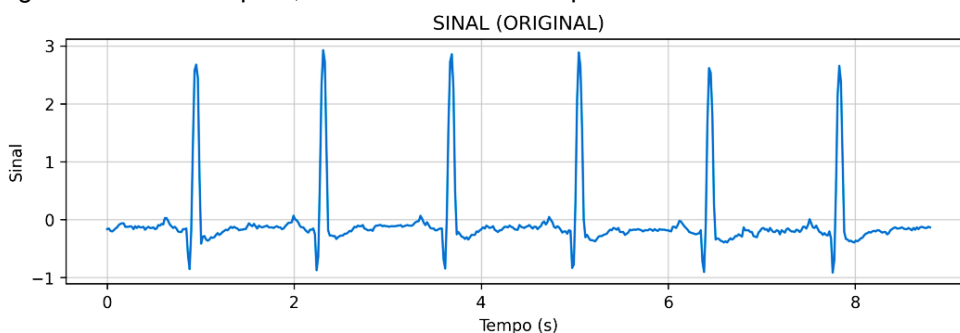
A infraestrutura do software utilizou-se de ferramentas gratuitas, tendo sua linguagem principal o Python, com as bibliotecas: Numpy, Pandas, Matplotlib, WFDB e Scipy. Para transformar o algoritmo em uma API, necessária para as próximas integrações do sistema, foi preciso do framework FastAPI, para python, que também é de uso gratuito. Utilizando-se das mesmas tecnologias aqui citada é possível atingir os resultados aqui citados.

Os procedimentos necessários para desenvolver posteriormente o algoritmo de segmentação já foram alcançados, com os resultados sendo discutidos nesse trecho. Para discutir a eficiência de limpeza e segmentação do sinal, gráficos, gerados pelo próprio sistema utilizando a biblioteca Matplotlib, serão exibidos.

As figuras dispostas nesse artigo contêm apenas um intervalo do eletrocardiograma analisado, facilitando a visualização. Este comportamento permeará pelo resto do trabalho. As figuras geradas foram retiradas de uma amostra de Arritmia Sinusal. Confira-os abaixo.

O primeiro gráfico demonstra o sinal ECG da forma que é recebido pelo sistema, isto é, sem processamento prévio para limpeza.

Figura 1. Sinal ECG puro, sem interferências ou processamento.



Fonte: Gerada pelo algoritmo de segmentação, 2025.

O sinal, indicado acima, é processado pelo algoritmo para extrair 1% de suas extremidades, descartando interferências que podem ter sido geradas tanto pelo ligar, quanto desligar da máquina. Após essa extração, ele é submetido a filtros de limpeza.

A extração das extremidades pode ser descrita como o seguinte pseudocódigo:

```
signal = ecgSignal;  
signalStart = int(round(len(signal) * 0.01))  
signalEnd = len(signal) - int(signal) * 0.01))  
finalSignal = signal[signalStart:signalEnd]
```

E a etapa seguinte, onde ocorre os filtros de limpeza, pode ser descrita como:

```
finalSignal = (finalSignal - sum(finalSignal)/len(signal)) / std(finalSignal) //onde std é o desvio padrão do sinal.
```

O resultado do processamento descrito acima pode ser medido por uma *SNR* (Signal Noise Ratio), onde se registrou-se uma *SNR* de 10.05db.



$$\text{SNR}_{\text{db}} = 10 \log_{10} \left( \frac{P_{\text{sinal}}}{P_{\text{ruído}}} \right) \quad (1)$$

onde:

SNR = Relação Sinal-ruído

$P_{\text{sinal}}$  = Potência do Sinal Útil

$P_{\text{ruído}}$  = Potência do Ruído

Onde, a potência média  $P$  pode ser calculada como:

$$P = \frac{1}{N} \sum_{n=1}^N x[n]^2 \quad (2)$$

onde:

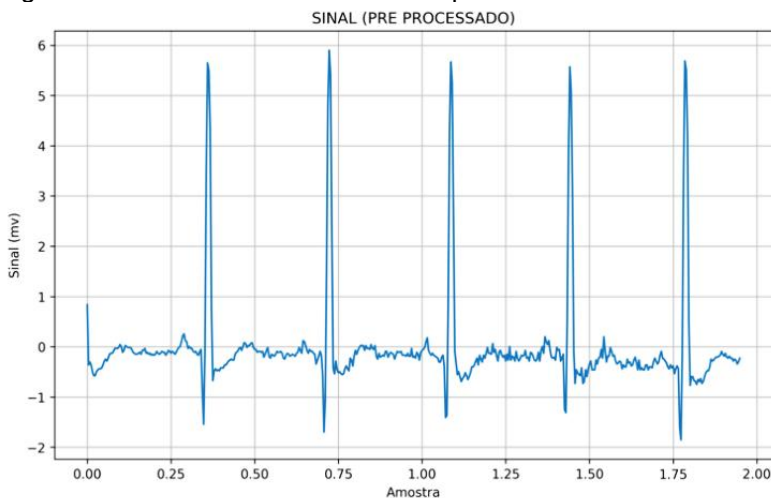
$P$  = Potência Média

$N$  = Número total de amostras do sinal

$x[n]$  = Valor do sinal na amostra  $n$

$x[n]^2$  = Energia instantânea da amostra  $n$

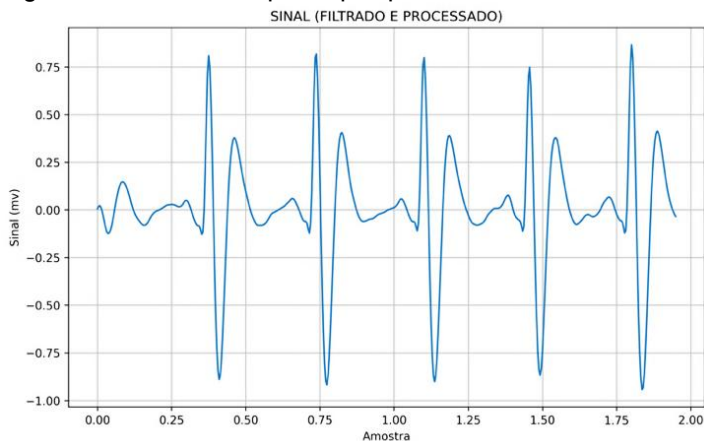
Figura 2. Sinal ECG com o filtro de limpeza.



Fonte: Gerada pelo algoritmo de segmentação, 2025.

Após o pré-processamento, pode-se iniciar a etapa mais importante: *Janelamento* do complexo QRS, englobando desde a onda P até a T, e segmentação deles. Essa etapa também conta com o último filtro de ruídos, filtros estes de passagem (baixa e alta). O resultado da filtragem pode ser encontrado na figura abaixo:

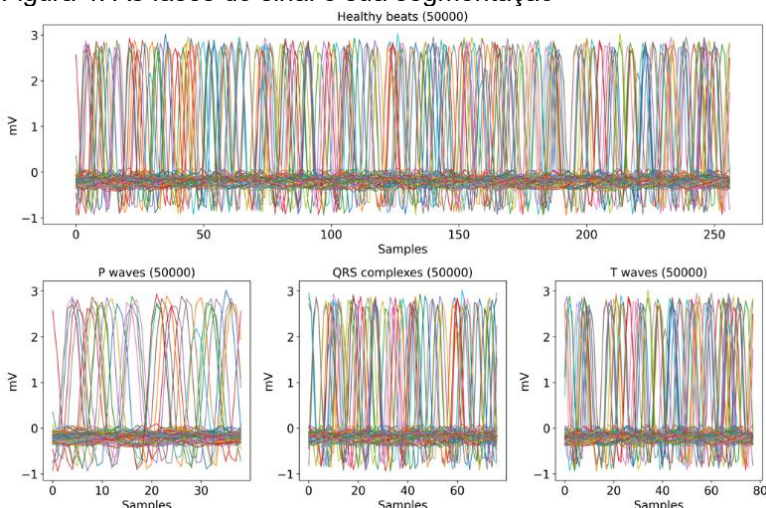
Figura 3. Sinal ECG após a pré-processamento e filtros de baixa e alta passagem.



Fonte: Gerada pelo algoritmo de segmentação, 2025.

A etapa de segmentação é realizada após a última filtragem de ruído, a fim de gerar uma eficácia computacional maior, evitando desperdício de processamento em ruído. Este atualmente tem sido o ponto de maior atenção do projeto, pois serve de base para o que é de objetivo nos ciclos futuros. Abaixo é possível visualizar o resultado da segmentação e o detalhamento do processo.

Figura 4. As fases do sinal e sua segmentação



Fonte: Gerada pelo algoritmo de segmentação, 2025.

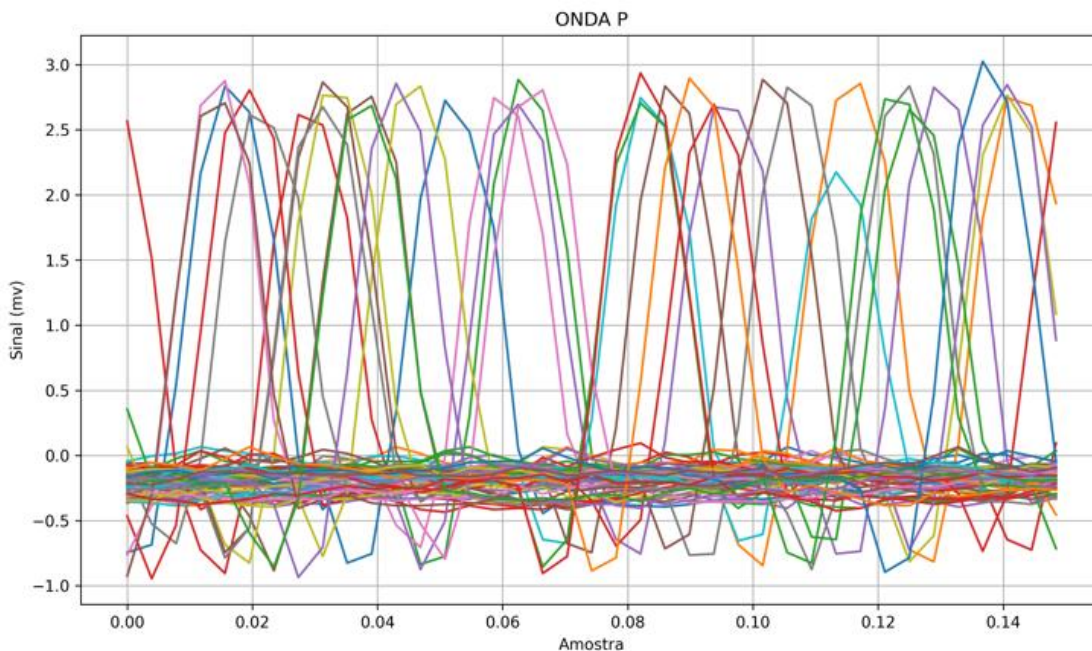
De primeira vista, os gráficos podem parecer confusos e com uma visualização dificultada, contudo, o objetivo deste processamento é visto em uma forma computacional, sendo a figura acima uma representação visual do necessário para a tomada de decisão computacional, isto é, compõe o que o algoritmo utiliza como sua base para tomada de



decisões. A figura representa a transposição das janelas extraídas de intervalos QRS, de onda P a T.

Com o foco desse trabalho depositado em arritmias, onde nem sempre se mostram de fácil identificação por meio de análises manuais, como a FA (Fibrilação Atrial), que possui presença na onda P gerando ausência de sinais elétricos periódicos, as técnicas descritas acima servem para evidenciar e classificar tais variações. Esse exemplo de arritmia, a FA, não dispõe de um fácil diagnóstico a partir do intervalo R-R, que é a metodologia mais utilizada por profissionais quando estão examinando um ECG manualmente. Com isso em mente, a transposição das ondas acima uma das técnicas desse sistema, que se baseia em comparar pequenas variações de tensão a partir de quadros extraídos dessa tomada de decisão no QRS. Abaixo segue uma visão mais ampla da transposição, extraídos da onda P.

Figura 5. Transposição da Onda P, ampliada.



Fonte: Gerada pelo algoritmo de segmentação, 2025.

### 3 CONCLUSÃO

De acordo com o apresentado nos tópicos acima, podemos concluir que foi possível atingir um resultado satisfatório na limpeza e pré-processamento dos sinais de eletrocardiograma da base MIT-BIH, utilizando o algoritmo de Pan e Tompkins. Esta etapa, de suma importância para a fidelidade dos dados, demonstrou ser robusta o suficiente para

eliminar ruídos comuns e preparar os sinais para as fases subsequentes de segmentação e classificação, que são o cerne desta pesquisa.

Os próximos passos deste trabalho, já em desenvolvimento, envolvem a aplicação de técnicas de aprendizado de máquina sobre os sinais pré-processados para realizar a segmentação automatizada das ondas P, QRS e T e a detecção de arritmias. O sucesso na etapa inicial de pré-processamento, validado por métricas de acurácia superiores a 99,3% na detecção de complexos QRS, fornece uma base sólida e confiável para o treinamento desses modelos.

O trabalho permanece com sua visão em integrar os algoritmos em um sistema embarcado de hardware de baixo custo, capaz de coletar e processar exames de ECG em tempo real. Esta solução tem o potencial de democratizar o acesso ao diagnóstico cardiológico preliminar, visando especificamente comunidades em áreas remotas e com baixo IDH, onde a escassez de profissionais e equipamentos é uma barreira crítica à saúde. Dessa forma, este projeto posiciona-se não apenas como uma contribuição tecnológica, mas também como uma ferramenta de impacto social, alinhada com os ODS 3 (Saúde e Bem-Estar) e 9 (Indústria, Inovação e Infraestrutura).

Uma limitação a ser considerada em implementações futuras, também abordada por Farooq et al. (2022) em seu contexto, é a instabilidade no fornecimento de energia elétrica em áreas remotas. Enquanto a solução paquistanesa cogita o uso de sistemas de energia renovável acoplados, soluções para o hardware brasileiro poderiam incluir o desenvolvimento de uma versão com bateria de longa duração ou com eficiência energética otimizada, assegurando a funcionalidade contínua do dispositivo em cenários de infraestrutura limitada.

Para trabalhos futuros, além do desenvolvimento do *hardware*, planeja-se a expansão da validação do algoritmo para outras bases de dados públicas que incluam uma gama mais variada de arritmias, testando assim a capacidade de generalização do sistema. Adicionalmente, a criação de uma interface acessível, talvez um aplicativo móvel que centralize os dados e os relatórios, será crucial para a usabilidade da solução por profissionais de saúde da atenção básica, fechando o ciclo entre a coleta do sinal, a análise computacional e o laudo médico final.

## REFERÊNCIAS

BRASIL. Ministério da Saúde. Cerca de 400 mil pessoas morreram em 2022 no Brasil por problemas cardiovasculares. Biblioteca Virtual em Saúde. Disponível em:

<https://bvsmms.saude.gov.br/cerca-de-400-mil-pessoas-morreram-em-2022-no-brasil-por-problemas-cardiovasculares>. Acesso em: 12 set. 2025.

OLIVEIRA, G. M. M. et al. Estatística Cardiovascular – Brasil 2020. Arquivos Brasileiros de Cardiologia, v. 115, n. 3, 2020. Disponível em:

<https://pressreleases.scielo.org/blog/2020/11/06/estudo-apresenta-dados-e-impactos-das-doencas-cardiovasculares-no-brasil>. Acesso em: 12 set. 2025.

STEVENS, B. et al. Os custos das doenças cardíacas no Brasil. Arquivos Brasileiros de Cardiologia, v. 111, n. 1, p. 29–36, jul. 2018. Disponível em:

<https://bvsmms.saude.gov.br/doencas-cardiovasculares-10>. Acesso em: 12 set. 2025.

GARIKAPATI, K. et al. The Role of Contemporary Wearable and Handheld Devices in the Diagnosis and Management of Cardiac Arrhythmias. Heart, Lung and Circulation, v. 31, n. 11, p. 1432–1449, 1 nov. 2022.

POWELL-WILEY, T. M. et al. Social Determinants of Cardiovascular Disease. Circulation Research, v. 130, n. 5, p. 782–799, 4 mar. 2022.

FAROOQ, Adil et al. Low-Cost Portable ECG Monitoring Device for Inaccessible Areas in Pakistan. Sir Syed Research Journal of Engineering & Technology, v. 12, p. 8, 23 jul. 2022.

MENESSES, Uéilton de Brito. AutoBeat: Classificação de Arritmias Cardíacas em Eletrocardiogramas de 12 Derivações Usando Redes Neurais Convolucionais em um Ambiente Web. Lages: Centro Universitário Unifacvest, 2023. Disponível em:

[https://www.unifacvest.edu.br/assets/uploads/files/arquivos/7318a-ueliton\\_autobeat-classificacao-de-arritmias-cardiacas-em-eletrocardiogramas-de-12-derivacoes-usando-redes-neurais-convolucionais-em-um-ambiente.pdf](https://www.unifacvest.edu.br/assets/uploads/files/arquivos/7318a-ueliton_autobeat-classificacao-de-arritmias-cardiacas-em-eletrocardiogramas-de-12-derivacoes-usando-redes-neurais-convolucionais-em-um-ambiente.pdf). Acesso em: 12 set. 2025.

MARINHO, Leandro Bezerra. Segmentação de Batimentos Cardíacos em Eletrocardiograma e Identificação de Arritmia Cardíaca em um Único Lote de Processamento por Aprendizado Profundo Usando uma Abordagem de Regressão em uma Rede Neural Convolucional. Fortaleza: Universidade Federal do Ceará, 2021. Tese (Doutorado em Engenharia de Teleinformática). Disponível em:

[https://repositorio.ufc.br/bitstream/riufc/69014/3/2021\\_tese\\_lbmarinho.pdf](https://repositorio.ufc.br/bitstream/riufc/69014/3/2021_tese_lbmarinho.pdf). Acesso em: 12 set. 2025.

NASCIMENTO, Paulo Cainan Guimarães do et al. Aplicabilidade de algoritmos de machine learning no diagnóstico de fibrilação atrial e SQT por interpretação de eletrocardiograma: uma revisão sistemática. Arquivos Brasileiros de Cardiologia, São Paulo, v. 118, n. 2, p. 1–10, 2022. Disponível em:

<https://www.scielo.br/j/abc/a/jfHKLyXZyKN937FyqvCZB5h/?format=pdf>. Acesso em: 12 set. 2025

RAHMAN, S. et al. Robustness of electrocardiogram signal quality indices. Journal of the Royal Society Interface, v. 19, n. 189, p. 20220012, [s.d.].

THE BETH ISRAEL DEACONESS MEDICAL CENTER, T. A. L. The MIT-BIH Normal Sinus Rhythm Database. physionet.org, 1990. Disponível em:  
<https://physionet.org/content/nsrdb/>.

PAN, J.; TOMPKINS, W. J. **A real-time QRS detection algorithm**. IEEE Transactions on Biomedical Engineering, v. 32, n. 3, p. 230–236, 1985. Disponível em:  
<https://ieeexplore.ieee.org/document/4122029>. Acesso em: mai. 2025.

QUEIROZ, J. A.; JUNIOR, A.; LUCENA, F.; BARROS, A. K. **Diagnostic decision support systems for atrial fibrillation based on a novel electrocardiogram approach**. Journal of Electrocardiology, 2017. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/29187299/>. Acesso em: abr. 2025.