

- Edital: [Novos Editais - PIBIC, PIBIC-AF e PIBITI 2025/2026](#) (Clicar no link 1. [Edital PIBIC 2025/2026](#) para o edital completo)

- **Veja no item 4.1 do Edital os requisitos que devem ser atendidos pelo aluno de graduação.**

Seguem as propostas dos planos de trabalho que serão submetidas pela profa. Flavia Maria Guerra. S. A. Oliveira ao PIBIC.

Caso você se interesse por algum destes planos de trabalho, por favor entre em contato com a profa. Flavia Oliveira por email (flavia@ene.unb.br) **até, no máximo, o dia 16/05/2025.** Neste email, apresente-se, indique em que semestre do curso se encontra, enviando em anexo o seu histórico e indique por qual plano de trabalho se interessou.

Além disso, um item que também precisa constar do plano de trabalho é um resumo “**das competências e habilidades do aluno para desenvolver as atividades do plano de trabalho**”. Assim, inclua também em seu email informações a este respeito (como matérias cursadas, habilidades de programação, etc) - **Texto com no máximo 1000 caracteres.**

Aguardo o seu contato!

Planos de trabalhos propostos:

- **Plano 1: Introdução ao processamento digital de sinais fisiológicos: aplicações em saúde cardiovascular**

Resumo e justificativa:

O processamento digital de sinais biomédicos, como o eletrocardiograma (ECG) e o sinal de pressão arterial contínua, desempenha um papel crucial na análise de disfunções do sistema nervoso autônomo (SNA), que regula funções involuntárias como frequência cardíaca e pressão arterial. Alterações no SNA estão associadas a diversas condições clínicas, como o diabetes, onde a neuropatia autonômica, uma complicação grave associada ao diabetes, pode levar a complicações importantes, incluindo risco cardiovascular elevado. A análise precisa desses sinais permite monitorar, diagnosticar e gerenciar tais disfunções, contribuindo para a melhoria da qualidade de vida dos pacientes. Nesse contexto, a formação de profissionais capacitados em processamento de sinais biomédicos é essencial para avançar a pesquisa e a prática clínica na área de engenharia biomédica.

Qualquer estudo na área de modelamento e identificação de sistemas fisiológicos inclui, necessariamente, etapas relativas ao processamento digital de registros fisiológicos, como o ECG e o sinal de pressão arterial. O objetivo deste trabalho é apresentar ao aluno de graduação em Engenharia, que ainda não tenha cursado disciplinas específicas de

processamento de sinais, as principais técnicas de processamento digital por meio de sua aplicação a registros biomédicos, com ênfase em sinais cardiorrespiratórios (por exemplo, ECG, pressão arterial e respiração). Serão realizados: (1) estudos de conceitos fundamentais de sinais e sistemas; (2) implementação prática no MATLAB de operações como convolução, correlação e análise espectral; (3) aplicação dos conceitos a registros fisiológicos públicos; (4) desenvolvimento de habilidades científicas e computacionais voltadas à engenharia biomédica.

Este plano visa contribuir para a formação inicial do aluno na área de processamento de sinais biomédicos, despertar seu interesse desde cedo no curso, integrá-lo ao grupo de pesquisa em engenharia biomédica e incentivá-lo a realizar pesquisas na área.

O trabalho será desenvolvido por meio de estudos e tarefas semanais, abordando sinais biomédicos desde sua origem, medição, digitalização e armazenamento. O software Matlab será empregado, devido à sua robustez, relevância e confiabilidade na área. Os livros de apoio principais serão [1], [2] e [3], e o aluno será incentivado a buscar materiais adicionais, como artigos científicos, para complementar seus estudos.

Além de aprender os fundamentos de processamento digital de sinais biomédicos, o aluno desenvolverá habilidades como a aplicação do método científico, a organização do tempo entre atividades acadêmicas e de pesquisa, a utilização de bases de dados disponibilizadas pela UnB, o domínio do Matlab — uma ferramenta essencial em diversas áreas da Engenharia — e a elaboração de relatórios científicos para registro e divulgação de resultados. Essas competências são fundamentais para a formação de um pesquisador na área de engenharia biomédica.

É importante destacar que os sinais fisiológicos estudados já estão disponíveis em bases de dados públicas, não sendo necessário realizar experimentos com seres humanos.

Bibliografia básica do plano de trabalho:

- [1] E. N. Bruce, Biomedical signal processing and signal modeling, Wiley-Interscience, 2000.
- [2] W. van Drongelen, Signal processing for neuroscientists: an introduction to the analysis of physiological signals, Academic Press, 2006.
- [3] S. W. Smith, The scientist and engineer's guide to digital signal processing, California Technical Pub, 1997.

Cronograma inicial

Mês	Atividades
1	Estudo teórico: conceito de sinal, amostragem, quantização
2	Introdução ao MATLAB, manipulação de sinais simulados
3	Conceitos de convolução, correlação e sistemas LTI
4	Aplicação a registros reais de ECG

5	Análise espectral e modelagem por somas de senóides
6	Redação de relatório técnico parcial
7-8	Sinais de pressão arterial e respiração, sincronização com ECG
9	Organização e avaliação dos resultados obtidos
10	Escrita inicial da metodologia e resultados obtidos e revisões com o orientador
11	Pesquisa e escrita da introdução e revisão da literatura, das discussões dos resultados e das conclusões do trabalho; revisões com o orientador
12	Finalização do relatório completo

- **Plano 2: Monitoramento do controle glicêmico em indivíduos com diabetes tipo 2 a partir de sinais fisiológicos e explainable AI**

Resumo e justificativa:

O diabetes mellitus tipo 2 (DM2) é uma condição crônica que afeta milhões de indivíduos globalmente e com forte impacto na saúde pública. Indivíduos com diabetes tipo 2 apresentam risco significativamente aumentado de desenvolver doenças cardiovasculares, como infarto do miocárdio, acidente vascular cerebral e insuficiência cardíaca, independentemente de fatores de risco convencionais como hipertensão ou dislipidemia.

O controle glicêmico eficaz em pacientes com diabetes mellitus tipo 2 (DM2) é fundamental para prevenir complicações micro e macrovasculares. Tradicionalmente, a hemoglobina glicada (HbA1c) é utilizada como marcador padrão para avaliar o controle glicêmico a longo prazo. Sabe-se, contudo, que alterações precoces na função do sistema nervoso autônomo (SNA) – responsável por regular funções involuntárias como frequência cardíaca e pressão arterial – podem preceder alterações laboratoriais detectáveis.

Parâmetros derivados de sinais fisiológicos, como a variabilidade da frequência cardíaca (HRV), da pressão arterial (BPV) e da sensibilidade barorreflexa (BRS), têm mostrado relação com o estado metabólico e oferecem um caminho promissor para um monitoramento não invasivo do controle glicêmico. Contudo, o uso clínico desses sinais ainda é limitado por dificuldades de interpretação e falta de ferramentas acessíveis para sua análise integrada.

Este projeto propõe o uso de modelos de inteligência artificial interpretável para superar este desafio, oferecendo uma via prática para utilizar esses dados fisiológicos na estimação não invasiva do controle glicêmico. A proposta tem forte potencial de impacto, ao sugerir uma nova forma de monitoramento complementar, acessível e contínuo da saúde de

pessoas com DM2. Além disso, envolve o aluno em uma experiência formativa interdisciplinar em saúde, engenharia biomédica e ciência de dados.

Este projeto tem como objetivo geral desenvolver e avaliar modelos computacionais baseados em inteligência artificial para estimar o nível de HbA1c a partir de variáveis fisiológicas obtidas de forma não invasiva, com foco em pacientes com diabetes tipo 2. Os objetivos específicos deste trabalho incluem: (1) processar sinais fisiológicos e extrair medidas de HRV, BPV e BRS; (2) aplicar algoritmos de regressão não-lineares baseados em aprendizado de máquina (SVR e Random Forest) para estimar os níveis de HbA1c; (3) utilizar métodos de explainable AI como SHAP (Shapley Additive Explanations) e permutação para identificar os preditores mais relevantes; (4) avaliar o desempenho preditivo dos modelos com validação cruzada; (5) propor o uso dessas técnicas como ferramenta complementar para monitoramento clínico.

O aluno utilizará bases de dados públicas e validadas contendo sinais fisiológicos de pacientes com DM2. O software MATLAB será utilizado como ambiente principal para o processamento dos sinais (como ECG e pressão arterial), para extrair variáveis que representam o funcionamento do sistema nervoso autônomo, para a implementação dos algoritmos e para a visualização dos dados, proporcionando ao aluno uma formação aplicada e prática, com ênfase na análise de dados reais e reproduzíveis. Os resultados serão analisados quanto à acurácia (RMSE) e interpretabilidade, com foco em aplicações práticas no monitoramento de pacientes.

O estudo será conduzido inteiramente com sinais previamente adquiridos, disponíveis no repositório PhysioNet, dispensando a coleta de novos dados.

Relevância para a formação do aluno

O projeto permite ao aluno trabalhar com tecnologias emergentes de ciência de dados, aprendizado de máquina e processamento de sinais biomédicos. Também estimula a compreensão crítica de problemas reais de saúde pública e prepara o(a) estudante para atuação interdisciplinar em pesquisa, desenvolvimento tecnológico e inovação. Os resultados podem fornecer informações relevantes para profissionais de saúde, auxiliando na identificação de pacientes com maior risco cardiovascular e no planejamento de intervenções preventivas. Ao integrar dados fisiológicos, aprendizado de máquina e interpretação clínica, este projeto propõe não apenas um avanço tecnológico, mas uma contribuição concreta para a personalização do cuidado em diabetes.

Bibliografia básica do plano de trabalho:

- [1] Michel-Chávez et al., "Variabilidade da frequência cardíaca e da pressão arterial sistólica em diabéticos com diagnóstico recente". Arq Bras Cardiol., vol. 105, no. 3, pp. 276-284, 2015.
- [2] Silva-e-Oliveira et al., "Variabilidade da frequência cardíaca com base na estratificação de risco para diabetes mellitus tipo 2", Journal Einstein, vol. 15, no. 2, pp. 141-147, 2017.

- [3] Mohanty, P. K. et al. "Leveraging Shapley additive explanations for feature selection in ensemble models for diabetes prediction". Bioengineering, v. 11, n. 12, p. 1215, 2024..
- [4] M. Sakamoto, D. Matsutani e Y. Kayama, 'Clinical implications of baroreflex sensitivity in type 2 diabetes,' Int Heart J, vol. 60, n. 2, pp. 241-246, 2019.
- [5] M. C. Irigoyen, "Controle cardiovascular: regulação reflexa e papel do sistema nervoso simpático," Revista Brasileira de Hipertensão, vol. 8, pp. 55-62, 2001.

Cronograma inicial

Mês	Atividades
1-2	Revisão bibliográfica; familiarização com sinais fisiológicos e ferramentas de processamento
3	Seleção da base de dados
4	Extração de variáveis de HRV, BPV e BRS a partir dos sinais ECG e pressão arterial
5-6	Implementação dos modelos de regressão não-linear (SVR e Random Forest)
7-8	Aplicação de SHAP e importância por permutação
9-10	Análise dos resultados, ajustes e testes de robustez
11	Organização dos resultados, documentação dos scripts e escrita do relatório.
12	Finalização do relatório completo e revisão final.

● **Plano 3: Engenharia aplicada à saúde cardiovascular: decifrando o ritmo cardíaco por detecção automatizada de batimentos ectópicos**

Resumo e justificativa:

O ritmo de batimentos do coração humano não é perfeitamente regular — há pequenas variações no tempo entre um batimento e outro, mesmo em repouso. Essas variações, conhecidas como variabilidade da frequência cardíaca (HRV, do inglês heart rate variability), refletem a interação dinâmica entre os sistemas que regulam o funcionamento do coração, como o sistema nervoso e o sistema respiratório. O estudo da HRV tem se tornado uma ferramenta importante na engenharia biomédica, pois fornece informações valiosas sobre o estado funcional do organismo, podendo indicar desde o nível de estresse até a presença de disfunções cardiovasculares ou metabólicas.

Para extrair a HRV, é comum trabalhar com a série de tempos entre os picos R do eletrocardiograma (ECG), chamados de intervalos RR. No entanto, essa análise pode ser severamente comprometida pela presença de batimentos ectópicos, que são batimentos

cardíacos que ocorrem fora da cadência normal, como impulsos elétricos gerados em locais atípicos do coração. Esses batimentos não seguem o compasso habitual do sistema de condução cardíaco e, por isso, distorcem os intervalos RR. A consequência disso é que índices matemáticos e estatísticos comumente usados para quantificar a HRV ficam enviesados e podem levar a interpretações erradas sobre o estado fisiológico do paciente.

Como demonstrado por Acar et al. (2000), mesmo poucos batimentos ectópicos em um segmento de ECG curto (por exemplo, de 5 minutos) já são suficientes para causar distorções significativas nas medidas de HRV — como aumento artificial da variância dos intervalos RR ou inserção de picos espúrios no espectro de frequência. Tais distorções são problemáticas porque podem mascarar sinais clínicos reais ou criar a falsa impressão de alterações fisiológicas. Por isso, a detecção e correção dos batimentos ectópicos é considerada uma etapa crítica no processamento automático de sinais cardíacos.

Neste contexto, o objetivo deste projeto é desenvolver e testar métodos automáticos para a detecção de batimentos ectópicos, utilizando apenas a série de intervalos RR. A escolha por usar apenas o vetor de RR, sem informações morfológicas do traçado do ECG, se justifica por razões práticas: muitos equipamentos e bancos de dados públicos já disponibilizam essa série como dado de entrada, e algoritmos baseados unicamente nos intervalos RR são mais simples, menos custosos computacionalmente e mais apropriados para uso em tempo real ou em dispositivos com recursos limitados.

A primeira etapa consistirá em uma revisão técnica do problema e dos métodos propostos na literatura, com foco especial na abordagem descrita por Tsipouras et al. (2005), que utilizam regras simples aplicadas a janelas deslizantes de três intervalos RR para classificar os batimentos em normais ou arritmias.

A segunda etapa será a implementação de dois algoritmos principais:

1. Um algoritmo baseado em limiares adaptativos de desvio, inspirado na proposta de Acar et al. (2000), que compara a diferença entre intervalos consecutivos com desvios padrão locais para identificar batimentos anômalos.
2. Um algoritmo baseado em regras determinísticas sobre janelas de três batimentos, conforme proposto por Tsipouras et al. (2005), que realiza a classificação de batimentos com base em relações temporais simples entre RR anteriores, centrais e seguintes.

Em seguida, os métodos serão avaliados em dados anotados da base MIT-BIH Arrhythmia Database, disponível publicamente via PhysioNet, que oferece traçados de ECG e anotações feitas por especialistas indicando a presença e tipo de arritmias. A performance dos algoritmos será avaliada usando métricas clássicas de classificação, como acurácia, sensibilidade, especificidade e valor preditivo positivo, comparando os batimentos detectados automaticamente com os rotulados por especialistas.

Bibliografia básica do plano de trabalho:

- [1] Acar, E., Malik, M., et al. (2000). Automatic ectopic beat elimination in short-term heart rate variability measurement. *Computer Methods and Programs in Biomedicine*, 63(2), 123–131.
- [2] Tsipouras, M. G., Fotiadis, D. I., & Sideris, D. (2005). An arrhythmia classification system based on the RR-interval signal. *Artificial Intelligence in Medicine*, 33(3), 237–250.
- [3] Nabil, D., & Bereksi-Reguig, F. (2015). Ectopic beats detection and correction methods: A review. *Biomedical Signal Processing and Control*, 18, 228–244..
- [4] Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Eng. in Medicine and Biology Magazine*, 20(3), 45–50.
- [5] Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology, “Heart rate variability: standards of measurement, physiological interpretation, and clinical use,” *Eur Heart J*, 14: 354-381, 1996.
- [6] M. C. Irigoyen, “Controle cardiovascular: regulação reflexa e papel do sistema nervoso simpático,” *Revista Brasileira de Hipertensão*, 8: 55-62, 2001.
- [7] F. Oliveira, “Autonomic and metabolic effects of OSA in childhood obesity,” em *Proceedings, 32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Buenos Aires, 2010.
- [8] Goldberger, A. L., et al. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource. *Circulation*, 101(23), e215–e220.

Cronograma inicial

Mês	Atividades
1	Planejamento e preparação: definição do escopo, metas, e cronograma detalhado; início da revisão de literatura.
2	Revisão bibliográfica.
3	Revisão bibliográfica (continuação).
4	Seleção da base de dados: familiarização com o MIT-BIH Arrhythmia Database.
5	Pré-processamento dos dados: extração de séries RR, organização dos registros.
6	Implementação do algoritmo baseado em limiares adaptativos (Acar et al.).
7	Implementação do algoritmo baseado em regras de janela (Tsipouras et al.).
8	Validação dos algoritmos com métricas de desempenho.
9	Aplicação de métodos de correção: remoção, interpolação linear, spline cúbico.
10	Avaliação do impacto das correções nas medidas de HRV.
11	Organização dos resultados, documentação dos scripts e escrita do relatório.

- **Plano 4: Detecção Automática de Arritmias: Métodos Estatísticos para Intervalos RR**

Resumo e justificativa:

A variabilidade da frequência cardíaca (HRV) é uma ferramenta essencial para avaliar o funcionamento do sistema cardiovascular e do sistema nervoso autônomo. No entanto, batimentos ectópicos — batimentos cardíacos anômalos que ocorrem fora do ritmo normal — podem distorcer as métricas de HRV, levando a interpretações incorretas. Métodos tradicionais de detecção de ectópicos frequentemente dependem da análise morfológica do eletrocardiograma (ECG), o que exige recursos computacionais significativos e nem sempre é viável em sistemas portáteis ou em tempo real. Este projeto propõe a implementação e avaliação de dois métodos estatísticos que utilizam apenas os intervalos RR para detectar e corrigir batimentos ectópicos: o **método de correlação de tendência**, descrito em [Shin et al. \(2011\)](#), e o **filtro automático recursivo**, apresentado em [Schmidt et al. \(2012\)](#).

O método de correlação de tendência identifica batimentos ectópicos comparando a série de intervalos RR com uma tendência suavizada, enquanto o filtro automático recursivo remove outliers de forma iterativa com base em limites estatísticos adaptativos. Ambos os métodos são vantajosos por sua simplicidade e independência de informações morfológicas do ECG, sendo ideais para cenários onde apenas os intervalos RR estão disponíveis. Este plano visa implementar esses algoritmos e compará-los usando dados reais, oferecendo uma solução prática e eficiente para a análise de HRV.

Os objetivos deste trabalho são: (1) Implementar o método de correlação de tendência para detectar e corrigir batimentos ectópicos em séries de intervalos RR; (2) Implementar o filtro automático recursivo para identificar e remover outliers em séries de intervalos RR; (3) Avaliar o desempenho dos dois métodos utilizando dados anotados da base MIT-BIH Arrhythmia Database; (4) Comparar a eficácia e robustez dos métodos em diferentes condições, como alta variabilidade natural ou presença de múltiplos ectópicos consecutivos.

A metodologia deste projeto está dividida em três etapas principais: revisão técnica, implementação dos algoritmos e avaliação comparativa. A **revisão técnica** consiste em um estudo detalhado dos artigos de referência, especificamente o método de correlação de tendência descrito por Shin et al. (2011) e o filtro automático recursivo apresentado por Schmidt et al. (2012). Isso inclui a análise dos fundamentos teóricos e das etapas algorítmicas de cada método para garantir uma implementação fiel.

A **implementação dos algoritmos** será realizada em duas partes. Primeiro, o método de correlação de tendência será implementado, que envolve calcular uma série de tendência suavizada a partir da série de intervalos RR usando uma janela deslizante, como a média móvel. Em seguida, a correlação entre os intervalos RR e a série de tendência será computada, e intervalos RR com baixa correlação serão identificados como possíveis

batimentos ectópicos. Finalmente, esses intervalos ectópicos serão corrigidos interpolando valores com base na tendência suavizada. Em segundo lugar, o filtro automático recursivo será implementado. Isso inclui estabelecer limites iniciais de aceitação com base em estatísticas da série RR, como a mediana e o desvio absoluto mediano. Em seguida, intervalos fora desses limites serão identificados iterativamente como outliers (potenciais ectópicos) e removidos ou corrigidos. Os limites serão atualizados com base na série filtrada, e o processo será repetido até que não haja mais outliers ou um critério de parada seja atingido.

A **avaliação e comparação dos métodos** serão realizadas utilizando a base de dados MIT-BIH Arrhythmia Database, que contém registros de ECG com anotações de especialistas sobre batimentos ectópicos. As séries de intervalos RR serão extraídas dos registros, e os dois métodos serão aplicados para detectar ectópicos. Métricas de desempenho, como sensibilidade, especificidade, acurácia e valor preditivo positivo, serão calculadas para avaliar a eficácia de cada método. Além disso, o desempenho será analisado em cenários variados, como a presença de artefatos, múltiplos ectópicos consecutivos ou alta variabilidade fisiológica.

Para o pré-processamento do sinal de ECG, será utilizado o programa CRSIDLab 2.0. A primeira versão foi implementada por minha orientanda Luisa Silva em seus trabalhos de [TCC](#) e [mestrado](#). Para este trabalho, familiaridade com o programa Matlab ou similar é desejável, mas não obrigatório. O mais importante é ter disposição e estar motivado(a) em aprender novas competências.

Ao longo do projeto, o aluno irá desenvolver competências essenciais em processamento de sinais biomédicos e análise estatística, áreas fundamentais para a engenharia biomédica. O aluno terá a oportunidade de adquirir experiência prática ao implementar os algoritmos e validar seus resultados com bases de dados reais, como a MIT-BIH Arrhythmia Database. Adicionalmente, o projeto permitirá uma compreensão mais profunda dos desafios relacionados à análise de variabilidade da frequência cardíaca (HRV) e da relevância da detecção precisa de batimentos ectópicos para assegurar a confiabilidade das métricas de HRV, habilidades e conhecimentos que serão valiosos tanto para a continuidade de estudos acadêmicos quanto para atuações profissionais na área de saúde cardiovascular.

Bibliografia Básica

1. Shin, H. S., Lee, C., & Lee, M. (2011). Adaptive threshold method for the peak detection of photoplethysmographic waveform. *Computers in Biology and Medicine*, 41(12), 1145-1152. Disponível em: [PMC](#).
2. Schmidt, M., Schumann, A., Müller, J., Bär, K. J., & Rose, G. (2012). Automatic filtering of outliers in RR intervals before analysis of heart rate variability in Holter recordings: a comparison between two methods. *Biomedical Engineering Online*, 11, 2. Disponível em: [Biomedical Engineering Online](#).
3. Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45–50.

Cronograma inicial

Mês	Atividade
1	Estudos introdutórios sobre ECG, intervalos RR e HRV.
2	Estudo teórico do método de Shin et al. (2011).
3	Estudo teórico do método de Schmidt et al. (2012).
4	Implementação do método de correlação de tendência em MATLAB.
5	Validação inicial com dados reais.
6	Implementação do filtro automático recursivo.
7	Validação inicial do filtro com séries reais.
8	Extração de séries RR da base MIT-BIH; pré-processamento com CRSIDLab 2.0.
9	Aplicação dos métodos aos dados reais; cálculo de métricas de desempenho.
10	Comparação dos métodos em diferentes cenários de variabilidade.
11	Análise de resultados; elaboração de gráficos e tabelas; texto inicial da metodologia, resultados e discussão dos resultados.
12	Redação do relatório final.

- **Plano 5: Aplicação de modelos de previsão clínica na avaliação da estabilidade para a prevenção e manejo de diabetes**

Resumo e justificativa:

O manejo eficaz do diabetes depende significativamente da capacidade de prever e prevenir complicações a longo prazo. Com base [no artigo de Riley et al.](#), que discute a importância de avaliar a estabilidade de modelos preditivos clínicos, este projeto visa adaptar a metodologia proposta por Riley para desenvolver e validar modelos de previsão de diabetes que sejam robustos e confiáveis, considerando diversas métricas de estabilidade.

Neste sentido, o objetivo principal deste estudo consiste no desenvolvimento e na avaliação da estabilidade de modelos preditivos de risco de diabetes utilizando métodos estatísticos e de aprendizado de máquina.

O diabetes é uma doença crônica com múltiplas etiologias e uma ampla gama de complicações que podem afetar significativamente a qualidade de vida e a longevidade. A aplicação de modelos preditivos na prática clínica pode ajudar a identificar indivíduos em risco de desenvolver diabetes ou suas complicações mais cedo, permitindo intervenções mais direcionadas e personalizadas. No entanto, a estabilidade desses modelos em diferentes subgrupos de pacientes ainda é pouco explorada e crítica para a sua eficácia e confiança clínica.

Espera-se que os modelos desenvolvidos sejam não apenas preditivos, mas também estáveis em várias subpopulações de pacientes, fornecendo uma ferramenta confiável para o manejo preventivo do diabetes. Além disso, a identificação de variáveis que contribuem para a instabilidade dos modelos pode oferecer insights para futuras pesquisas e desenvolvimento de diretrizes clínicas.

Bibliografia básica:

[1] RILEY, R. D. et al. Stability of clinical prediction models developed using statistical or machine learning methods. *Oxford University Research Archive*, Oxford, 2023. Disponível em: <https://ora.ox.ac.uk/objects/uuid:8c82f137-d720-4947-81fc-41296e62578e>. Acesso em: 13 abr. 2025.

Cronograma inicial

Mês	Atividade
1-2	Revisão bibliográfica sobre modelos preditivos para diabetes e estabilidade (baseada em Riley et al., 2019, 2020). Definição das métricas de estabilidade conforme Seção 2.2 do artigo. Seleção de base de dados
3-4	Preparação dos dados, definição e implementação de métricas de estabilidade
5	Desenvolvimento de modelos preditivos, conforme Seção 4. Ajuste de hiperparâmetros com validação cruzada (ex.: 10-fold, como em Seção 4.2). Avaliação inicial de desempenho.
6-8	Avaliação de estabilidade com bootstrap
9-10	Validação e utilidade clínica
11	Análise de resultados; elaboração de gráficos e tabelas; texto inicial da metodologia, resultados e discussão dos resultados.
12	Redação do relatório final.

- **Plano 6: Detecção automática das ondas PQRST no ECG**

Objetivo geral: Desenvolver e validar algoritmos de análise de sinais eletrocardiográficos utilizando o ambiente MATLAB, visando facilitar a detecção de anomalias cardíacas através da identificação das ondas P, QRS e T.

Artigo de referência: [PQRST wave detection on ECG signals](#)

Resumo e justificativa:

Os problemas cardíacos representam uma das principais causas de morbidade e mortalidade em todo o mundo, e a detecção precoce dessas condições é crucial para o tratamento eficaz. O eletrocardiograma (ECG) é uma ferramenta fundamental para a avaliação da saúde do coração, permitindo a detecção de diversas anomalias cardíacas. No entanto, a interpretação precisa dos sinais de ECG requer conhecimento especializado em fisiologia cardíaca e habilidades em processamento de sinais.

A detecção precoce e precisa de anomalias cardíacas é essencial para o tratamento eficaz e a prevenção de complicações graves. As ondas P, QRS e T no eletrocardiograma (ECG) fornecem informações cruciais sobre a saúde do coração, permitindo a identificação de condições como arritmias, isquemia miocárdica e hipertrofia ventricular. No entanto, a interpretação manual dessas ondas pode ser demorada e sujeita a erros, especialmente em casos de alta carga de trabalho médico. Portanto, o desenvolvimento de algoritmos automatizados para a detecção e análise dessas ondas é fundamental para melhorar a eficiência do diagnóstico cardíaco e garantir intervenções oportunas para pacientes em risco.

Objetivos Gerais:

Este projeto tem como objetivo desenvolver e validar algoritmos de análise de sinais eletrocardiográficos utilizando o ambiente MATLAB, visando facilitar a detecção de anomalias cardíacas através da identificação das ondas P, QRS e T. Esses algoritmos automatizados podem auxiliar no diagnóstico precoce de condições cardíacas, melhorando assim a eficiência e precisão dos procedimentos médicos.

Metodologia:

O projeto será dividido em quatro fases, cada uma com duração de três meses:

- Meses 1-3 (Fase de Aprendizado): Introdução aos conceitos básicos de fisiologia cardíaca e familiarização com o ambiente MATLAB, incluindo tutoriais básicos de programação.
- Meses 4-6 (Desenvolvimento de Pré-processamento): Desenvolvimento de algoritmos MATLAB para pré-processamento de sinais de ECG, incluindo filtragem e remoção de artefatos.

- Meses 7-9 (Extração de Características): Implementação de algoritmos para extração de características dos sinais de ECG, como ondas P, QRS e T, utilizando técnicas de processamento de sinais.
- Meses 10-12 (Validação e Análise): Validação dos algoritmos desenvolvidos utilizando bases de dados de ECG existentes e análise dos resultados obtidos em comparação com diagnósticos médicos convencionais.