

Rodrigo Luís de Faria

**Detecção Automática de AVNRT em Pacientes
Pediátricos Utilizando Aprendizado de Máquina
e Sinais de ECG**

Itajubá

Março de 2026

Rodrigo Luís de Faria

**Detecção Automática de AVNRT em Pacientes
Pediátricos Utilizando Aprendizado de Máquina e Sinais
de ECG**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e Tecnologia da Computação da UNIFEI (área de concentração: Matemática da Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência e Tecnologia da Computação.

Universidade Federal de Itajubá – UNIFEI

Programa de Pós-Graduação em Ciência e Tecnologia Computação

Orientador: João Paulo R. R. Leite

Itajubá

Março de 2026

*Dedico este trabalho à minha esposa e às minhas filhas,
que me motivam a ser melhor a cada dia.*

Agradecimentos

Agradeço a Deus pelo dom da vida e por todas as maravilhas que Ele criou e nos concedeu para serem desfrutadas na Terra. Em especial, agradeço-Lhe pela capacidade dada ao ser humano de pensar, criar, aprender e ensinar uns aos outros, o que nos possibilitou partir de condições quase inexistentes e alcançar o nível de desenvolvimento e tecnologia que hoje permeia o mundo.

Registro um agradecimento especial à minha esposa, Juliana, que diariamente me apoia e me ajuda a realizar os sonhos que compartilhamos. Às minhas filhas, Maria Lívia e Maria Luiza, que me inspiram e me motivam a ser melhor a cada dia. Aos meus pais, Eugênio e Cleonice, por tudo o que me ensinaram ao longo da vida, especialmente a fé e a perseverança.

Registro meu agradecimento ao professor e orientador João Paulo, que foi peça fundamental na minha trajetória acadêmica na UNIFEI. Sempre acreditou no meu trabalho e me incentivou a continuar, mesmo nos momentos em que ainda não havia dados ou resultados a serem apresentados. Agradeço também ao coordenador Adler que, mesmo sem saber, foi uma fonte de motivação ao longo do meu percurso no Mestrado, contribuindo para que eu não desistisse.

*“Vós sois o sal da terra, mas se o sal perder o sabor, com que lhe será restituído o sabor?
Não serve mais para nada, senão para ser jogado fora e pisado pelos homens.
Vós sois a luz do mundo, não se pode esconder uma cidade situada sobre um monte.
Nem se acende uma lâmpada para colocá-la debaixo do alqueire, mas sobre o candeeiro,
onde brilha para todos os que estão em casa.
(Bíblia Sagrada, Mateus 5, 13-16)*

Resumo

Este trabalho propõe uma abordagem computacionalmente eficiente e reproduzível para a detecção automática de batimentos com indícios de AVNRT em eletrocardiogramas de pacientes pediátricos. A identificação automática de AVNRT em pacientes pediátricos é um assunto praticamente inexplorado pela literatura, mas possui muitos benefícios, incluindo agilidade em triagens, apoio para decisões clínicas de emergência e viabilização de soluções de monitorização contínua em dispositivos vestíveis. Para a técnica proposta, os batimentos foram segmentados com base na detecção dos picos R e, em cada batimento, foram extraídas características temporais e morfológicas, incluindo descritores clássicos (amplitudes e intervalos RR) e parâmetros de Hjorth (Atividade, Mobilidade e Complexidade), que sintetizam informações de amplitude, frequência aproximada e variação temporal com baixo custo computacional. A avaliação foi conduzida utilizando a base de dados pública *Leipzig Heart Center ECG Database*, contendo registros de 13 pacientes pediátricos com diagnóstico de AVNRT. Três modelos de aprendizado de máquina supervisionado foram treinados e comparados: *Support Vector Machine (SVM)*, *Random Forest* e *LightGBM*. As métricas obtidas nos testes indicaram desempenho compatível ou superior ao estado da arte em termos de discriminação e equilíbrio entre precisão e sensibilidade, com *F1-score* de 0,983 e *AUC* de 0,989 na *SVM*; o *LightGBM* apresentou *F1-score* comparável (0,986) com menor latência de predição, sugerindo vantagem operacional para aplicações em tempo real. Em comparação com estudos prévios, os resultados obtidos foram semelhantes ou superiores aos relatados em tarefas análogas em populações predominantemente adultas, o que indica o potencial da metodologia de baixa complexidade proposta como alternativa eficiente aos modelos profundos, especialmente em cenários com escassez de dados.

Palavras-chave: AVNRT, Eletrocardiograma, ECG, SVM, Random Forest, LightGBM.

Abstract

This work proposes a computationally efficient and reproducible approach for the automatic detection of beats indicative of AVNRT in electrocardiograms of pediatric patients. The automatic identification of AVNRT in pediatric patients is a subject practically unexplored in the literature, but it has many benefits, including faster triage, support for emergency clinical decisions, and enabling continuous monitoring solutions in wearable devices. For the proposed technique, beats were segmented based on the detection of R peaks, and temporal and morphological characteristics were extracted from each beat, including classic descriptors (amplitudes and RR intervals) and Hjorth parameters (Activity, Mobility, and Complexity), which synthesize information on amplitude, approximate frequency, and temporal variation with low computational cost. The evaluation was conducted using the public database Leipzig Heart Center ECG Database, containing records of 13 pediatric patients diagnosed with AVNRT. Three supervised machine learning models were trained and compared: Support Vector Machine (SVM), Random Forest, and LightGBM. The metrics obtained in the tests indicated performance comparable to or superior to the state of the art in terms of discrimination and balance between precision and sensitivity, with an F1-score of 0.983 and an AUC of 0.989 in SVM; LightGBM presented a comparable F1-score (0.986) with lower prediction latency, suggesting an operational advantage for real-time applications. Compared to previous studies, the results obtained were similar to or superior to those reported in analogous tasks in predominantly adult populations, indicating the potential of the proposed low-complexity methodology as an efficient alternative to deep models, especially in data-scarce scenarios.

Keywords: AVNRT, Electrocardiogram, ECG, SVM, Random Forest, LightGBM.

Lista de ilustrações

Figura 1 – Nó Sinóatrial (adaptado de (Queensland Cardiovascular Group, 2026))	16
Figura 2 – Posição dos eletrodos (ECGbook, 2024)	17
Figura 3 – Derivações ECG (Cables and Sensors, LLC, 2026)	17
Figura 4 – ECG (adaptado de Klabunde (2026))	18
Figura 5 – Características do AVNRT no ECG (adaptado de CardVasc (2023))	20
Figura 6 – Etapas da metodologia para detecção de AVNRT	27
Figura 7 – Pico R.	30
Figura 8 – Batimento cardíaco.	30
Figura 9 – Ondas P-QRS-T.	31
Figura 10 – Curva ROC para os modelos de aprendizado de máquina supervisionados	40
Figura 11 – Matriz de confusão para os modelos de aprendizado de máquina	40
Figura 12 – Ranking de comparação de importância das características	41

Lista de tabelas

Tabela 1 – Resumo demográfico dos 13 pacientes pediátricos com AVNRT.	28
Tabela 2 – Distribuição dos registos entre treino e teste.	28
Tabela 3 – Distribuição dos batimentos por classe nos conjuntos de treino e teste.	29
Tabela 4 – Características extraídas por batimento e fórmulas	31
Tabela 5 – Matriz de confusão para classificação binária (rótulo positivo = AVNRT).	35
Tabela 6 – Comparação das métricas de desempenho	42
Tabela 7 – Precisão e sensibilidade por classe (conjunto de teste)	43
Tabela 8 – Hiperparâmetros ótimos identificados pelo GridSearchCV	44
Tabela 9 – Tempo computacional de treinamento e predição (segundos).	45
Tabela 10 – Comparação com estado da arte para diferenciação de SVT.	46

Lista de abreviaturas e siglas

AV	Nó atrioventricular
AVNRT	Taquicardia por reentrada nodal atrioventricular
AVRT	Taquicardia por reentrada atrioventricular
CNN	Rede neural convolucional
ECG	Eletrocardiograma
FA	Fibrilação atrial
IA	Inteligência artificial
LGPD	Lei Geral de Proteção de Dados
LightGBM	Light Gradient Boosting Machine
SA	Nó sinoatrial
SVM	Support Vector Machine
SVT	Taquicardia supraventricular
VT	Taquicardia ventricular

Sumário

1	INTRODUÇÃO	12
1.1	Objetivo	13
1.2	Contribuições	13
1.3	Organização do trabalho	14
2	O SINAL CARDÍACO	15
2.1	Eletrocardiograma	15
2.2	Arritmia Cardíaca	18
2.3	AVNRT	19
3	REVISÃO BIBLIOGRÁFICA	22
3.1	Modelos Tradicionais	23
3.2	Parâmetros de Hjorth	25
3.3	Considerações Finais	26
4	MATERIAIS E MÉTODOS	27
4.1	Fonte de Dados	27
4.2	Extração de Batimentos	29
4.3	Modelos de Aprendizado de Máquina	32
4.3.1	Ajuste de Modelos	32
4.3.1.1	SVM	33
4.3.1.2	Random Forest	33
4.3.1.3	LightGBM	33
4.4	Avaliação de Desempenho	34
4.4.1	Métricas e fórmulas	36
4.4.1.1	Precisão (Valor preditivo positivo, VPP)	36
4.4.1.2	Sensibilidade (Revocação ou Taxa de Verdadeiros Positivos, TVP)	37
4.4.1.3	Especificidade (Taxa de Verdadeiros Negativos, TVN)	37
4.4.1.4	Acurácia	37
4.4.1.5	F1-score	37
4.4.1.6	AUC-ROC (Área sob a curva ROC)	37
5	RESULTADOS	39
5.1	Curva ROC	39
5.2	Matriz de Confusão	39
5.3	Importância das Características	41

5.4	Métricas Quantitativas	42
5.5	Desempenho dos modelos e compensações operacionais	46
5.6	Comparação com o estado da arte	46
5.7	Limitações	47
6	CONCLUSÃO	48
6.1	Limitações	49
6.2	Direções futuras e recomendações	49
6.3	Considerações finais	50
	REFERÊNCIAS	51

1 Introdução

A aplicação de técnicas de inteligência artificial (IA) ao eletrocardiograma (ECG) tem apresentado avanços rápidos, com resultados promissores na classificação de ritmos cardíacos e na detecção de alterações estruturais em populações adultas (OSE et al., 2024). Esses métodos têm demonstrado capacidade não só de replicar a interpretação humana em tarefas clássicas, mas também de modelar relações não lineares entre características do ECG que são de difícil avaliação por inspeção visual isolada. Entretanto, grande parte da literatura concentra-se em bases de dados e populações adultas, havendo escassez de estudos e repositórios padronizados para populações pediátricas. Essa lacuna é relevante: diferenças fisiológicas entre crianças e adultos (variação de morfologia das ondas, intervalos dependentes da idade, maior ocorrência de ruído em coletas ambulatoriais pediátricas) podem comprometer a aplicabilidade direta de modelos treinados em adultos, exigindo investigações específicas para o contexto pediátrico (TAN et al., 2025a).

Do ponto de vista clínico, a identificação correta e precoce de taquicardias supraventriculares (SVT), em particular da taquicardia por reentrada nodal atrioventricular (AVNRT), tem impacto direto no manejo do paciente, desde a triagem em serviços de urgência até a decisão por procedimentos terapêuticos definitivos como a ablação por cateter. Em crianças, a apresentação pode ser atípica e o custo/risco de exames invasivos justifica ferramentas não invasivas que auxiliem na priorização e no encaminhamento clínico. Por outro lado, soluções que dependam de grande capacidade computacional ou de equipamentos de ECG com 12 derivações podem limitar a implantação em ambientes com poucos recursos ou em dispositivos vestíveis; há, portanto, demanda por abordagens que equilibrem desempenho, interpretabilidade e eficiência computacional.

Nesse cenário, descritores de baixo custo computacional, como os parâmetros de Hjorth (Atividade, Mobilidade e Complexidade), e estratégias de segmentação batimento-a-batimento surgem como alternativas atraentes para representar informação morfológica e tempo-frequencial de forma eficiente (HJORTH, 1970). Modelos de complexidade moderada (por exemplo, *Support Vector Machine (SVM)*, *Random Forest*, *Light Gradient Boosting Machine (LightGBM)*) podem aproveitar essas representações para alcançar discriminação competitiva, ao mesmo tempo em que mantêm latência e requisitos de memória compatíveis com aplicações embarcadas. Apesar de alguns trabalhos terem explorado redes neurais na diferenciação de mecanismos de SVT em adultos (SAU et al., 2023; HIGUCHI et al., 2023; VALDES et al., 2024), há escassez de estudos validados especificamente em coortes pediátricas com rótulos robustos e está é a lacuna que este trabalho busca reduzir.

Em resumo, a motivação central deste trabalho é investigar se uma abordagem

centrada em engenharia de características de baixo custo e em classificadores leves pode detectar sinais eletrocardiográficos indicativos de AVNRT em ECGs pediátricos, preservando interpretabilidade e viabilidade operacional para aplicações clínicas e de monitoramento contínuo.

1.1 Objetivo

O objetivo principal deste trabalho é o desenvolvimento e validação de um método computacionalmente eficiente e reprodutível para a detecção automática de batimentos com indicativos de AVNRT em exames de ECG realizados em pacientes pediátricos.

Além disso, há alguns objetivos específicos:

- Implementar segmentação de batimento-a-batimento baseada na marcação dos picos R;
- Extrair representações temporais e morfológicas, incluindo intervalos RR, amplitudes e parâmetros de Hjorth (Atividade, Mobilidade, Complexidade);
- Treinar e comparar modelos supervisionados de complexidade moderada (*SVM*, *Random Forest*, *LightGBM*), otimizando hiperparâmetros por validação cruzada estratificada por paciente;
- Avaliar o desempenho dos modelos utilizados utilizando métricas estabelecidas na literatura como *F1-score*, *AUC-ROC*, acurácia e tempos de treino/predição.

1.2 Contribuições

Este trabalho apresenta a primeira investigação sistemática sobre a detecção automática de batimentos com indicativos de AVNRT em ECGs pediátricos utilizando aprendizado de máquina. Apesar da relevância clínica da AVNRT, a literatura sobre métodos automatizados para sua identificação é escassa, especialmente no contexto pediátrico, sendo a maior parte dos estudos existentes concentrada em outras arritmias mais prevalentes e em populações adultas. Além disso, a interpretação do ECG apresenta limitações importantes, pois a análise visual pode ser influenciada por variações morfológicas sutis, ruído no sinal e pela própria experiência do observador, o que reforça a necessidade de métodos computacionais capazes de apoiar uma avaliação mais objetiva e reprodutível. Assim, o estudo contribui para o preenchimento de uma lacuna específica e pouco explorada na interseção entre cardiologia pediátrica e aprendizado de máquina.

Do ponto de vista metodológico, os sinais usados neste estudo provêm da base de dados *Leipzig Heart Center ECG Database* e foram obtidos a partir de estudos eletro-

fisiológicos realizados no laboratório de eletrofisiologia. As gravações foram registradas com *CardioLab®* (*GE Medical Systems*) a 977 Hz, incluem eletrogramas intracavitários além dos traçados de 12 derivações e foram anotadas manualmente batimento a batimento por especialistas usando o software *LightWAVE®* (KLEHS et al., 2025). A avaliação dos modelos é conduzida com separação entre treino e teste por paciente, evitando vazamento de informação entre batimentos do mesmo indivíduo e proporcionando uma estimativa mais realista da capacidade de generalização intra-base. Essa estratégia reforça a validade metodológica dos resultados, mesmo diante do número limitado de pacientes.

Outra contribuição relevante consiste na proposição de um fluxo de trabalho completo e de baixo custo computacional para a detecção automática de AVNRT, baseado em segmentação batimento-a-batimento, extração de características no domínio do tempo e classificação supervisionada. A escolha por modelos clássicos de aprendizado de máquina e atributos simples, como os parâmetros de Hjorth, permite a execução do método em hardware modesto, sem necessidade de grandes volumes de dados ou aceleração por GPU, favorecendo sua aplicação em ambientes clínicos com recursos computacionais limitados.

Por fim, os resultados demonstram que a abordagem proposta alcança elevado desempenho, com métricas de *F1-score* e *AUC* próximas de 1, comparáveis aos reportados na literatura para abordagens mais complexas aplicadas a outras arritmias. Além do desempenho, o estudo contribui ao relacionar os atributos extraídos a aspectos fisiológicos do ECG, oferecendo maior interpretabilidade aos resultados e indicando a viabilidade do método como ferramenta de apoio à decisão clínica e triagem automatizada em cardiologia pediátrica.

1.3 Organização do trabalho

O documento está estruturado da seguinte forma: no Capítulo 2 são apresentados os fundamentos fisiológicos do coração, a base do ECG e noções gerais sobre arritmias, com ênfase em AVNRT; o Capítulo 3 traz a revisão bibliográfica sobre detecção de arritmias por métodos computacionais e estudos relevantes em pediatria; o Capítulo 4 detalha os materiais e métodos (base de dados, pré-processamento, extração de características e desenho experimental); o Capítulo 5 apresenta os resultados experimentais (métricas, análises e visualizações); e o Capítulo 6 discute as implicações, limitações e perspectivas futuras, finalizando com as conclusões.

2 O Sinal Cardíaco

O ritmo cardíaco normal resulta de um padrão organizado de geração e propagação de impulsos elétricos pelo sistema de condução cardíaco. O potencial de ação inicial é gerado pelo nó sinoatrial (SA), que atua como marcapasso primário; o sinal segue então pela musculatura atrial, alcança o nó atrioventricular (AV), que impõe um atraso fisiológico crucial, e prossegue pelo feixe de His e pela rede de Purkinje para ativar os ventrículos de forma coordenada (SATTAR; CHHABRA, 2023; LI et al., 2024). Essa sequência garante que a contração atrial preceda a ventricular, otimizando o enchimento diastólico ventricular e a eficiência do débito cardíaco. Do ponto de vista eletrofisiológico, cada região (SA, átrios, AV, His-Purkinje, ventrículos) apresenta propriedades celulares e moleculares distintas. Por exemplo, diferenças nos tipos de canais iônicos, na densidade de junções *gap* e no acoplamento eletromecânico determinam a frequência, a velocidade de condução e a refratariedade regionais (LI et al., 2024).

A Figura 1 ilustra o sistema de condução elétrica do coração, mostrando a geração do impulso no SA (marcapasso natural), sua propagação pelos átrios, o atraso fisiológico imposto pelo AV e a rápida distribuição do sinal pelo feixe de His e pelas fibras de Purkinje até os ventrículos. As setas indicam a direção típica da despolarização que sincroniza a contração atrial e ventricular.

A atividade elétrica registrada no corpo, através de exames como o ECG, é a projeção somada desses eventos celulares sincronizados; as ondas e intervalos clássicos (P, QRS, T, como podem ser observados na Figura 4) correspondem, respectivamente, à despolarização atrial, despolarização ventricular e repolarização ventricular, bem como ao tempo de condução entre estruturas (por exemplo, PR reflete atraso AV) (SATTAR; CHHABRA, 2023). Importante para a compreensão clínica e para métodos computacionais, átrios e ventrículos diferem não apenas na função mecânica, mas também em arquitetura elétrica: o tecido atrial tende a ter condução mais lenta e é mais suscetível a conduções heterogêneas e remodelamento (fibrose), mecanismos centrais em arritmias atriais (supraventriculares); já o sistema His-Purkinje proporciona condução rápida e altamente sincronizada necessária para a ativação ventricular eficiente (CUNHA et al., 2022; LI et al., 2024).

2.1 Eletrocardiograma

O ECG é a representação temporal da atividade elétrica cardíaca capturada por eletrodos de superfície, sendo a principal ferramenta não invasiva para identificação de ritmos e alterações eletrofisiológicas em clínica e pesquisa (STRACINA et al., 2022; SATTAR; CHHABRA, 2023).




Figura 1 – Nó Sinoatrial (adaptado de (Queensland Cardiovascular Group, 2026))

No ECG de 12 derivações (ou *leads*, em inglês), que é o padrão em investigação diagnóstica, os doze sinais são obtidos por combinações de eletrodos de membros e pré-cordiais, oferecendo visões complementares do vetor de despolarização e repolarização cardíacas, o que permite localizar alterações regionais e caracterizar padrões de arritmia (STRACINA et al., 2022; SATTAR; CHHABRA, 2023). A Figura 2 apresenta o posicionamento dos eletrodos no corpo durante a aquisição de um ECG de 12 derivações. Já a Figura 3 ilustra a orientação espacial das derivações do ECG no plano frontal (derivações de membro I, II, III e as derivadas aumentadas aVR, aVL, aVF) e as projeções das derivações pré-cordiais (V1–V6). As setas representam os vetores de registro elétrico e mostram como cada derivação observa a atividade elétrica cardíaca sob diferentes ângulos, o que explica a variabilidade morfológica dos complexos P, QRS e T entre as derivações. Essa representação é útil para entender por que alterações regionais da despolarização ou repolarização (por exemplo, originadas por mecanismos de reentrada ou por alterações estruturais) se manifestam de modo distinto nas várias derivações, fundamentando a interpretação diagnóstica do ECG.

O traçado típico apresenta ondas e intervalos bem definidos: a onda P (despolarização atrial), o complexo QRS (despolarização ventricular) e a onda T (repolarização ventricular), além de intervalos clínicos de interesse como PR, QT e ST; cada componente traduz eventos celulares e de condução que têm interpretação fisiológica direta (SATTAR; CHHABRA, 2023; SINGH; KRISHNAN, 2023). A identificação e a delimitação precisas




Figura 2 – Posição dos eletrodos (ECGbook, 2024)




Figura 3 – Derivações ECG (Cables and Sensors, LLC, 2026)

desses marcos fiduciais (pico/início/fim de P, QRS, T) são essenciais para medidas como frequência, ritmo, duração de intervalos e morfologia, que orientam o diagnóstico de blocos, isquemia, sobrecarga atrial/ventricular e praticamente todas as arritmias conhecidas (SATTAR; CHHABRA, 2023; SINGH; KRISHNAN, 2023).

A Figura 4 apresenta um ciclo cardíaco típico registrado por meio de um ECG

(*lead II*), destacando suas principais componentes morfológicas: a onda P, associada à despolarização atrial; o complexo QRS, correspondente à despolarização ventricular; e a onda T, relacionada à repolarização ventricular. Também é ilustrada a escala temporal do sinal, evidenciando a duração típica dos eventos elétricos cardíacos. A identificação precisa dessas ondas e intervalos é fundamental para a análise clínica do ECG e serve de base para a extração de características temporais e morfológicas utilizadas em métodos automáticos de detecção de arritmias.




Figura 4 – ECG (adaptado de [Klabunde \(2026\)](#))

A detecção automática do QRS é robusta na maioria dos casos, mas a identificação de ondas de baixa amplitude como a P continua sendo desafiadora em sinais patológicos, o que motiva métodos avançados de delimitação e verificação baseados em transformadas tempo-frequência e regras fisiológicas ([SACLOVA et al., 2022](#)).

Além do uso clássico em ambiente hospitalar, o ECG tem sido adotado em dispositivos vestíveis (como relógios inteligentes e anéis) e em aplicações de IA para monitoramento contínuo e triagem remota; essa expansão traz novas oportunidades (monitorização prolongada, detecção precoce) e limitações (número reduzido de derivações, ruído de movimento), exigindo avaliação cuidadosa da validade clínica das predições automatizadas ([STRACINA et al., 2022](#); [NERI et al., 2023](#)). Assim, entender os fundamentos fisiológicos do ECG, suas fontes de variabilidade e as limitações técnicas é essencial para projetar métodos computacionais confiáveis, interpretáveis e clinicamente aplicáveis.

2.2 Arritmia Cardíaca

As arritmias cardíacas correspondem a qualquer alteração na frequência, regularidade ou sequência normal dos impulsos elétricos do coração, resultando em batimentos mais rápidos (taquiarritmias), mais lentos (bradiarritmias) ou irregulares. Entre as arritmias sustentadas, a fibrilação atrial (FA) é a mais comum na prática clínica, sua prevalência na população adulta é da ordem de 1–2% e aumenta substancialmente com a idade, sendo responsável por grande parte das internações e eventos tromboembólicos relacionados a

ritmos cardíacos. Paralelamente, as SVT paroxísticas têm prevalência menor na população geral (estimada em cerca de 2,25 por 1.000 habitantes), mas representam uma parcela importante das apresentações agudas por palpitações ([European Society of Cardiology \(ESC\), 2019](#); [MICHAUD; STEVENSON, 2021](#)).

Em adultos, a FA é a arritmia cardíaca mais comum em nível populacional. Entre as SVT regulares, incluem-se AVNRT, AVRT, taquicardia atrial e flutter atrial; em séries clínicas de pacientes submetidos a estudo eletrofisiológico, a AVNRT é o mecanismo mais frequente, correspondendo a cerca de 60% dos casos. As arritmias ventriculares são menos prevalentes na população geral, mas têm grande relevância prognóstica em pacientes com doença cardíaca estrutural ([European Society of Cardiology \(ESC\), 2019](#); [KOTADIA; WILLIAMS; O'NEILL, 2020](#); [TARANTINO et al., 2022](#)).

A identificação das arritmias apoia-se primordialmente no traçado de 12 derivações e em registros ambulatoriais (*Holter*, monitor de eventos): na FA, observa-se tipicamente irregularidade dos intervalos RR, com ausência de ondas P organizadas; as SVT clássicas manifestam-se como taquicardias de QRS estreito e ritmo regular com início e término súbitos, sendo a análise do intervalo RP/PR útil para diferenciar subtipos (p.ex. AVNRT tende a apresentar RP curto e ondas P retrógradas frequentemente pouco visíveis); a VT tipicamente aparece como taquicardia de QRS largo, podendo mostrar dissociação atrioventricular, batimentos de captura ou fusão — sinais que orientam o diagnóstico diferencial entre VT e SVT com aberrância. Além do traçado, algoritmos clínicos e regras de ECG validadas (e, quando necessário, estudo eletrofisiológico) são empregados para aumentar a acurácia diagnóstica e guiar condutas terapêuticas emergenciais e eletivas ([KOTADIA; WILLIAMS; O'NEILL, 2020](#); [MICHAUD; STEVENSON, 2021](#); [NETO et al., 2021](#)).

2.3 AVNRT

A AVNRT é um tipo de SVT paroxística causado por um circuito de reentrada que inclui o AV ou tecido adjacente; na sua forma típica (lenta-rápida), existe um caminho de condução lento para ir e um rápido para voltar, produzindo episódios de início e término súbitos de taquicardia regular com QRS estreito. Do ponto de vista eletrocardiográfico, o mecanismo corresponde à ativação atrial muito próxima ao QRS (ondas P retrógradas muitas vezes ocultas) e, eletrofisiologicamente, está associado à presença de vias duplas (lenta/rápida) no entorno do nó AV ([KATRISSIS et al., 2010](#)). A Figura 5 sintetiza os subtipos eletrocardiográficos clássicos da AVNRT e suas manifestações em ECG. Na forma típica (lenta-rápida), responsável por cerca de 90% dos casos, a onda P costuma ficar oculta no complexo QRS ou aparecer como um “pseudo-s” na derivação II e um “pseudo-r” em V1, resultando em RP curto. A AVNRT atípica (rápida-lenta), menos comum ($\approx 10\%$),

tende a apresentar onda P visível antes do QRS (RP mais longo). Formas muito atípicas (lenta–lenta) são raras (< 1%) e podem mostrar a onda P sobreposta ao segmento ST. Essas diferenças morfológicas e temporais são úteis na suspeita diagnóstica inicial e orientam a necessidade de confirmação por estudo eletrofisiológico e a decisão terapêutica (manobras vagais, adenosina ou ablação por cateter).

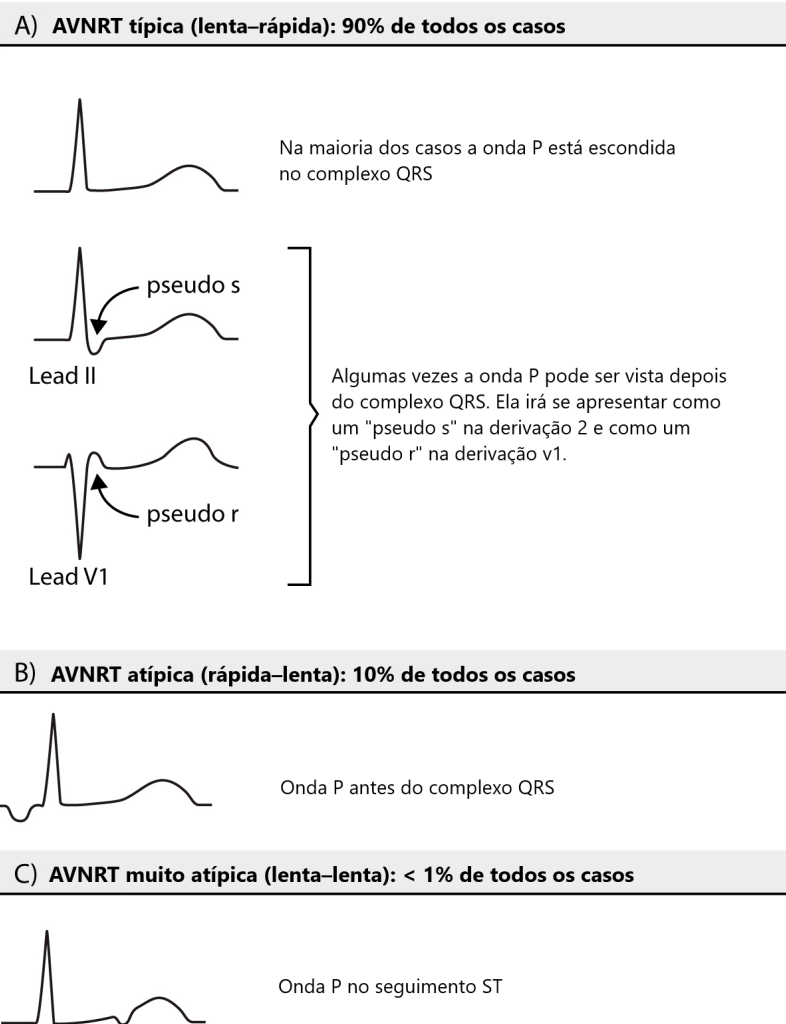


Figura 5 – Características do AVNRT no ECG (adaptado de [CardVasc \(2023\)](#))

Em termos de frequência na população geral, estudos populacionais e séries de pacientes descrevem AVNRT como uma das causas mais comuns de SVT; estimativas sugerem uma prevalência na ordem de dezenas por 10.000 habitantes. Por exemplo, um estudo relatou $\approx 22,5$ casos por 10.000 na população estudada (0,225%) ([MICHOWITZ et al., 2017](#)). Em crianças, a distribuição difere: a SVT como grupo é a arritmia mais comum na pediatria (estimada entre $\approx 1/250$ a $1/1000$ crianças), mas a proporção específica de AVNRT é menor em lactentes e aumenta com a idade. Múltiplas séries pediátricas e revisões mostram que AVNRT representa tipicamente uma fração variável dos SVTs pediátricos (relatos clínicos descrevem valores entre $\approx 12\%$ até $\approx 25 - 30\%$ dependendo da coorte e da faixa etária), sendo mais rara em recém-nascidos e mais frequente em

pré-adolescentes/adolescentes. Ou seja, AVNRT é relativamente comum entre os SVTs em adolescentes e adultos, mas tem menor participação relativa nas populações pediátricas mais jovens (MICHOWITZ et al., 2017; OZAKI et al., 2018; PONNUSAMY et al., 2020; STRANGIO et al., 2025).

A identificação de AVNRT apoia-se na combinação de história clínica (palpitações de início/término súbitos, sensação de batimentos rápidos, sintomas vagais) e em achados eletrocardiográficos e eletrofisiológicos. No ECG, durante o episódio, costuma-se observar taquicardia regular de QRS estreito com frequência tipicamente elevada, e a medida do intervalo RP é útil: na maioria dos AVNRT típicos o RP é curto (P retrógrada dentro ou imediatamente após o QRS) — entretanto, ondas P retrógradas podem ser sutis ou invisíveis em derivações convencionais; por isso, a resposta a manobras vagais ou a bolus de adenosina (que terminam o circuito nodal) é também um critério diagnóstico prático em contexto agudo. Para confirmação definitiva e subclassificação (típico vs atípico), o estudo eletrofisiológico invasivo demonstra a presença de dupla via nodal e induz o circuito reentrante (JABBOUR, 2024; HARVEY et al., 2024).

Quanto ao manejo, a abordagem aguda começa por manobras vagais (por exemplo, manobra de Valsalva modificada) e, se ineficazes, a adenosina em bolus intravenoso para terminar o episódio; em pacientes hemodinamicamente instáveis está indicada cardioversão elétrica. Para o tratamento definitivo, a ablação por cateter do ramos lento tem alta eficácia e baixo índice de complicações: séries e diretrizes reportam taxas de sucesso agudo $\approx 95 - 97\%$ e baixas taxas de recorrência/complicações; em pediatria a ablação também é efetiva, com trabalhos e consensos (PACES/HRS, revisões e séries pediátricas) relatando sucesso agudo elevado (tipicamente 87–98% conforme coorte e técnica), e preferência por estratégias que minimizem risco de bloqueio AV (p.ex. crioablação em lactentes/idiomas de anatomia delicada). Assim, para pacientes sintomáticos e/ou com repetidos episódios, a ablação por cateter é a solução curativa de primeira linha em muitos centros especializados (SAUL et al., 2016; European Society of Cardiology (ESC), 2019; DRAGO et al., 2024).

3 Revisão Bibliográfica

A aplicação de técnicas de aprendizado de máquina ao ECG tem se intensificado nas últimas décadas devido à capacidade desses métodos de automatizar tarefas de interpretação, aumentar a sensibilidade diagnóstica e possibilitar monitorização contínua em larga escala (OSE et al., 2024). No contexto pediátrico, contudo, essa promessa encontra desafios adicionais: diferenças morfológicas dependentes da idade, frequências cardíacas mais altas e maior suscetibilidade a artefatos tornam a transferência de modelos treinados em adultos pouco direta, exigindo estudos específicos para populações infantis (TAN et al., 2025a).

Historicamente, os primeiros esforços para automatizar a interpretação do ECG utilizavam modelos estatísticos e de série temporal. Em 1970, Gersch e colaboradores aplicaram cadeias de Markov à classificação de arritmias a partir de intervalos R–R, mostrando que representações sequenciais quantitativas podiam capturar padrões diagnósticos (GERSCH; EDDY; DONG, 1970). Nas décadas seguintes, e sobretudo a partir da década de 1990, surgiram as primeiras aplicações de redes neurais ao ECG: Edenbrandt, Devine e Macfarlane (1992) avaliaram arquiteturas neurais para classificação de segmentos ST–T com desempenho competitivo na identificação de alterações isquêmicas, enquanto Chow, Moody e Mark (1992) demonstraram a viabilidade prática de redes neurais para detectar batimentos ventriculares ectópicos em registros clínicos. Estudos subsequentes de maior impacto clínico, como Hedén et al. (1997), treinaram redes neurais em ECGs de 12 derivações para detectar infarto agudo do miocárdio, evidenciando ganhos de sensibilidade e discriminabilidade em relação a algoritmos tradicionais e consolidando o uso de aprendizado automático em tarefas diagnósticas complexas.

Ao longo dos últimos anos, o campo passou a incorporar arquiteturas convolucionais e, mais recentemente, modelos *Transformer* baseados em mecanismos de atenção além de estratégias híbridas que combinam aprendizado profundo com etapas clássicas de pré-processamento e extração de características (ANSARI et al., 2023; WU; GUO; AL., 2025). Revisões recentes sintetizam que, quando disponíveis conjuntos de dados volumosos e bem anotados, modelos de aprendizado profundo alcançam métricas elevadas em tarefas bem definidas e até preveem condições que não são trivialmente captadas pela inspeção visual do traçado (por exemplo, disfunção ventricular subclínica) (OSE et al., 2024; KALMADY et al., 2024; WU; GUO; AL., 2025). Paralelamente, cresceu o interesse em métodos que apresentem boa relação entre desempenho e custo computacional, como classificadores de complexidade moderada treinados sobre vetores de características extraídas. Em geral, essas abordagens facilitam a validação experimental, permitem uma análise mais direta das variáveis de entrada e tendem a ser mais viáveis de implementar em dispositivos de

baixa potência.

Especificamente para a detecção de AVNRT, a literatura ainda é relativamente incipiente, mas apresenta trabalhos recentes que mostram avanços metodológicos relevantes. [Sau et al. \(2023\)](#) treinaram uma rede neural para diferenciar mecanismos de SVT (AVRT vs. AVNRT) a partir de ECGs de 12 derivações, utilizando o estudo eletrofisiológico como padrão-ouro; apesar dos resultados promissores, os autores ressaltaram limitações importantes, principalmente o tamanho reduzido da coorte e a necessidade de validação externa para avaliar generalização clínica. Além disso, iniciativas translacionais começam a explorar integração de algoritmos em fluxos procedimentais, como suporte em tempo real durante ablação, o que evidencia um interesse prático em migrar técnicas de reconhecimento de padrões nodais do laboratório para a prática clínica ([TAM et al., 2023](#)).

3.1 Modelos Tradicionais

Entre as abordagens clássicas que continuam sendo úteis em cenários com amostras moderadas e vetores de características, destacam-se o *SVM*, o *Random Forest* e implementações de *boosting* como o *LightGBM*. O *SVM* busca maximizar a margem de separação entre classes e, via *kernels*, representa fronteiras não lineares; em aplicações ao ECG é comumente empregado após extração de características (p.ex. coeficientes *wavelet*, medidas morfológicas), mostrando robustez e boa capacidade de generalização quando a dimensão das características é controlada ([KUMAR; SHARMA; GUPTA, 2023](#)). *Random Forest*, por sua vez, agrega múltiplas árvores para reduzir variância, fornece estimativas de importância de atributos e se mostra resiliente a ruídos; é largamente usado em fluxos de trabalho tabulares derivados do ECG ([SILVA et al., 2022](#)). O *LightGBM* destaca-se pela rapidez e baixo consumo de memória e por opções específicas para tratar desbalanceamento, sendo adequado para cenários onde latência de inferência e uso de recursos são restrições ([WANG et al., 2023](#)). Estudos comparativos recentes indicam que, em muitas tarefas com características tabulares de qualidade, esses métodos de menor complexidade chegam a desempenho competitivo frente a redes profundas, com vantagem operacional em termos de tempo de treino e inferência.

O *SVM* é um classificador baseado em teoria da margem que busca encontrar a fronteira de decisão que maximiza a separação entre classes no espaço de características, podendo ser estendido via funções *kernel* para aprender fronteiras não lineares; por essa razão, *SVMs* são frequentemente adotados em problemas biomédicos com vetores de características de dimensão moderada e amostras limitadas, oferecendo boa capacidade de generalização quando corretamente regularizados. Em aplicações com sinais de ECG, o uso de *SVM* costuma ser associado a etapas de extração de características, como coeficientes *wavelet*, descritores tempo-morfológicos e estatísticas de batimento. Essa estratégia reduz

a complexidade do problema e pode aumentar a interpretabilidade do modelo. Como exemplo recente, Kumar, Sharma e Gupta (2023) aplicaram uma transformada *wavelet* 3-D para pré-processamento e extração de coeficientes, seguida de classificação por *SVM* no conjunto de dados da China *Physiological Signal Challenge* 2018 (CPSC-2018), uma base pública de ECG de 12 derivações, obtendo precisão média elevada ($\approx 99\%$) na discriminação de múltiplos tipos de batimentos. Esses e outros estudos indicam que, em cenários com curadoria adequada de *features* e pré-processamento robusto, *SVMs* permanecem uma alternativa competitiva e computacionalmente eficiente para a detecção de anomalias eletrocardiográficas. Ainda assim, seu desempenho depende fortemente da escolha do *kernel*, da normalização das variáveis e da seleção de hiperparâmetros, o que reforça a necessidade de busca e validação sistemáticas, por exemplo, por meio de validação cruzada estratificada por paciente.

O *Random Forest* é um método *ensemble* que constrói múltiplas árvores de decisão independentes sobre subconjuntos amostrais e de atributos, agregando as predições por votação majoritária (classificação) ou média (regressão). Essa estratégia mitiga o sobreajuste típico de árvores únicas e confere robustez a ruídos e *outliers*, além de permitir avaliação direta da importância das características, propriedade valiosa em estudos biomédicos onde a interpretabilidade é desejada. Em aplicações ao ECG, o *Random Forest* é frequentemente empregado após etapas de engenharia de características (por exemplo, medidas tempo-morfológicas, coeficientes *wavelet*, parâmetros de Hjorth), mostrando-se competitivo em cenários com vetores de características de dimensão moderada e disponibilidade limitada de dados rotulados. Um estudo recente demonstrou o uso eficaz do *Random Forest* para classificação de batimentos e detecção de anomalias em registros eletrocardiográficos, combinando boa discriminabilidade com baixo custo de inferência e facilidade de implementação em fluxos de trabalho clínicos (SILVA et al., 2022). Apesar dessas vantagens, a performance do método depende da qualidade dos atributos e do balanceamento da amostra; assim, práticas como validação estratificada por paciente, ajuste cuidadoso de hiperparâmetros e análises de importância de atributos são recomendadas para garantir generalização e compreensão clínica dos resultados.

O *LightGBM* é uma implementação eficiente de Gradient Boosting Decision Trees desenvolvida pela Microsoft, que se destaca por seu algoritmo de crescimento em folha (*leaf-wise*) e pelo uso de histogramas para discretização dos valores, características que o tornam particularmente rápido e com baixo consumo de memória em comparação a implementações clássicas de *boosting*. Essas propriedades o tornam muito adequado para tarefas de classificação baseadas em vetores de características extraídas do ECG, onde há um conjunto tabular de medidas tempo-morfológicas (ex.: amplitudes, intervalos, parâmetros de Hjorth, coeficientes *wavelet*) e a necessidade de inferência em tempo real ou embarcada. Além da eficiência, o *LightGBM* oferece mecanismos úteis para problemas desbalanceados (ex.: *scale_pos_weight*), regularização robusta e geração direta

de importâncias de características, o que auxilia a interpretabilidade clínica do modelo. Em aplicações ao ECG, um estudo recente reportou que o *LightGBM*, ao combinar engenharia de características e balanceamento de classes, alcança desempenho competitivo com baixos tempos de predição: por exemplo, Wang et al. (2023) aplicaram o *LightGBM* a um conjunto de dados de ECG (PTB-XL) utilizando descritores tempo-morfológicos e obtiveram alta precisão e baixa latência de inferência, destacando o potencial dessa família de modelos para implantação em cenários de monitoramento contínuo e dispositivos com recursos limitados (WANG et al., 2023).

3.2 Parâmetros de Hjorth

No campo da engenharia de características, os parâmetros de Hjorth (Atividade, Mobilidade e Complexidade) merecem atenção por sua simplicidade e eficiência computacional (HJORTH, 1970). Neste trabalho, os parâmetros foram calculados separadamente sobre os segmentos do ECG correspondentes às ondas P, ao complexo QRS e à onda T de cada batimento cardíaco. A Atividade pode ser definida como a variância do segmento de sinal, conforme a Equação 3.1, onde o $y(t)$ representa o sinal de ECG amostrado no intervalo temporal correspondente à onda analisada.

$$\text{Atividade} = \text{var}(y(t)) \quad (3.1)$$

A Mobilidade é a raiz quadrada da razão entre a variância da primeira derivada e a variância do sinal, funcionando como uma medida aproximada da frequência média, como pode ser visto na Equação 3.2

$$\text{Mobilidade} = \sqrt{\frac{\text{var}(y'(t))}{\text{var}(y(t))}} = \sqrt{\frac{\text{Atividade}(y'(t))}{\text{Atividade}(y(t))}} \quad (3.2)$$

A Complexidade compara a mobilidade da derivada com a mobilidade do próprio sinal; valores elevados indicam a presença de componentes com diferentes escalas temporais, conforme a definição apresentada na Equação 3.3.

$$\text{Complexidade} = \frac{\text{Mobilidade}(y'(t))}{\text{Mobilidade}(y(t))} \quad (3.3)$$

Por serem calculados no domínio do tempo e envolverem operações elementares, esses parâmetros são especialmente atraentes para processamento em tempo real e para implementação em hardware embarcado. Leite (2018) aplicou parâmetros de Hjorth por batimento, combinando-os a descritores temporais e de amplitude, e relatou discriminação competitiva para classificação de batimentos com vantagem operacional frente a métodos

mais complexos, o que justifica considerar Hjorth quando a restrição de recursos for crítica (LEITE; MORENO, 2018).

3.3 Considerações Finais

Apesar dos progressos, limitações metodológicas recorrentes permeiam a literatura e dificultam a comparação e a generalização dos resultados: muitas séries são pequenas e não multicêntricas, há risco de contaminação quando particionamentos são feitos por segmento em vez de por sujeito, e existe ampla heterogeneidade nas taxas de amostragem, número de derivações e procedimentos de pré-processamento entre estudos, todos fatores que podem inflacionar métricas internas e comprometer a validade externa (OSE et al., 2024; KALMADY et al., 2024). Por isso, revisões de método enfatizam práticas recomendadas como particionamento por paciente, relatório de intervalos de confiança (por exemplo, via *bootstrap*), uso de métricas robustas ao desbalanceamento (*F1-score*, *AUC-PR*, *MCC*) e validação externa quando possível.

Adicionalmente, questões éticas e legais assumem papel central na pesquisa com ECG pediátrico: a obtenção de consentimento informado por responsáveis, a anonimização adequada dos sinais e metadados, e a conformidade com legislações locais de proteção de dados (por exemplo, LGPD) são pré-requisitos para curadoria e eventual compartilhamento de bases, bem como condicionantes para a reprodutibilidade e aceitação clínica dos estudos. Finalmente, embora novos repositórios pediátricos em larga escala comecem a surgir (por exemplo, o *ZZU pECG dataset* com mais de 11 mil pacientes (TAN et al., 2025b)), a literatura revisada sugere que ainda há espaço substancial para estudos que combinem coletas pediátricas rotuladas de forma robusta com metodologias de validação rigorosas. Diante dessas lacunas, investigações que explorem engenharia de características de baixo custo (como os parâmetros de Hjorth), validação estratificada por paciente e classificadores leves e interpretáveis se mostram justificadas e promissoras para avançar a detecção automática de AVNRT em populações pediátricas.

4 Materiais e Métodos

A Figura 6 apresenta as etapas do método proposto: inicialmente, a partir do Sinal de ECG (entrada), procede-se à Segmentação dos Batimentos (realizada com base nos picos R) que isola janelas correspondentes a cada batimento cardíaco para análise individual. Em seguida, a etapa de Extração de Características computa descritores temporais e morfológicos (ex.: intervalos RR, amplitudes, parâmetros de Hjorth, estatísticas do P/QRS/T etc.), gerando um vetor de atributos por batida. Esses vetores alimentam a fase de Treinamento do Modelo (*SVM*, *Random Forest* e *LightGBM* neste trabalho), na qual os classificadores aprendem a distinguir batimentos normais dos com indicativos de AVNRT, por meio de validação cruzada e ajuste de hiperparâmetros. Finalmente, na etapa de Classificação, o modelo treinado recebe batimentos novos e produz previsões (rótulo, probabilidade) e métricas de desempenho (*F1-score*, *AUC*, matriz de confusão) que suportam avaliação e interpretação.

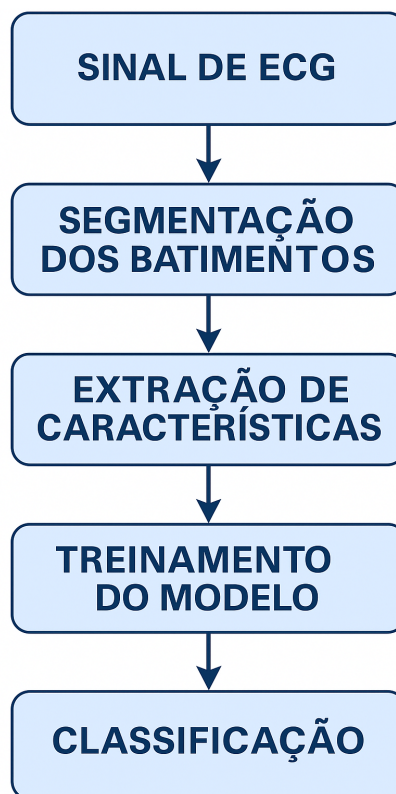


Figura 6 – Etapas da metodologia para detecção de AVNRT

4.1 Fonte de Dados

Para este estudo, foi utilizada a base de dados pública *Leipzig Heart Center ECG Database* (KLEHS et al., 2025). A base de dados contém, ao todo, 39 pacientes,

dos quais 29 são pediátricos e 10 adultos. Dos 29 registros pediátricos, 13 apresentam diagnóstico consistente de AVNRT, e apenas estes foram selecionados para a análise. Para esclarecer, foi realizada uma busca dirigida nas principais bases públicas de ECG e na literatura técnica disponível até a data deste estudo. Das coleções públicas mais utilizadas (por exemplo, *MIT-BIH Arrhythmia Database* e PTB-XL) não há registro de conjuntos especificamente compostos por ECGs pediátricos rotulados para AVNRT. Em contrapartida, a base de dados escolhida é atualmente a única base pública conhecida que documenta registros pediátricos com anotações explícitas de AVNRT. Assim, a seleção dos 13 pacientes pediátricos com AVNRT decorre da ausência de outras bases públicas rotuladas para essa condição e não apenas de uma limitação local da amostra. Para transparência e para valorizar a limitação como informação clínica relevante, apresentamos na Tabela 1 as características demográficas básicas e a duração das gravações desses 13 pacientes (faixa etária, distribuição por sexo e tempo médio de gravação).

Tabela 1 – Resumo demográfico dos 13 pacientes pediátricos com AVNRT.

Característica	Valor
Número de pacientes	13
Faixa etária (anos)	5.0 – 17.8
Idade média (σ)	13.2 ± 4.1 anos
Sexo (M / F)	4 / 9
Duração média das gravações (σ)	23.7 ± 44.1 minutos

Para garantir uma avaliação realista da capacidade de generalização do método, a separação entre conjuntos de treino e teste foi realizada por paciente, e não por amostragem aleatória de batimentos. Na Tabela 2 é apresentada a divisão entre os registros que foram utilizados no treinamento e os registros utilizados no teste. Com isso, a divisão por registros selecionados resultou em um conjunto de treino com 21.260 batimentos (correspondendo a 80,8% do total de 26.329 batimentos) e em um teste com 5.069 batimentos (19,2% do total). Essa estratégia evita vazamento de informação entre batimentos do mesmo indivíduo (efeito *patient-specific*), que poderia inflacionar artificialmente as métricas se batimentos do mesmo paciente aparecessem simultaneamente em treino e teste. As características foram extraídas batimento a batimento e, antes da separação por registro, garantimos que cada instância no conjunto final mantivesse a referência ao seu registro de origem.

Tabela 2 – Distribuição dos registros entre treino e teste.

Conjunto	Registros
Treino	x002, x006, x0016, x0021
Teste	x0010, x0013, x0014, x0015, x0017, x0018, x0019, x0024, x0026

A Tabela 3 apresenta a distribuição das classes nos conjuntos de treino e teste, evidenciando a composição de cada subconjunto em termos de batimentos normais e de

AVNRT.

Tabela 3 – Distribuição dos batimentos por classe nos conjuntos de treino e teste.

Classe	Treino	Treino (%)	Teste	Teste (%)
NORMAL	16.437	77,3%	1.412	27,9%
AVNRT	4.823	22,7%	3.657	72,1%

Essa distribuição reforça que a separação foi feita por paciente e por registro, preservando a independência entre os conjuntos e evitando vazamento de informação entre batimentos do mesmo indivíduo.

4.2 Extração de Batimentos

Embora a detecção automática de picos R seja um passo comum, o foco deste trabalho não foi desenvolver ou otimizar um detector de picos R. Existem diversos algoritmos bem estabelecidos que, quando avaliados em bases padrão (MIT-BIH, AHA), apresentam sensibilidade e precisão muito altas (KIM; SHIN, 2016). Ao invés disso, foram utilizadas anotações realizadas previamente por especialistas em cada batida, e disponíveis no próprio *dataset*.

Os registros de ECG foram processados utilizando a biblioteca *WFDB (WaveForm DataBase)* em Python (XIE et al., 2023). As batidas foram segmentadas utilizando um conceito chamado de “segmentação dinâmica”, que é baseada no comprimento médio dos intervalos entre batidas adjacentes e no fato de que existe uma proporção típica entre os comprimentos das ondas que as compõem (LEITE; MORENO, 2018). Ou seja, para cada batida, foram observados os picos R atual, anterior e próximo (Figura 7). O comprimento da batida atual foi finalmente calculado através da média simples entre os intervalos RR imediatamente anterior e posterior ao seu pico R.

Após o cálculo do comprimento da batida, uma janela fixa com este comprimento é posicionada em torno do pico R, com 35% da janela alocada antes do pico e 65% após, valores típicos que aumentam a chance de captura completa das ondas P-QRS-T conforme ilustrado na Figura 8.

Em seguida, cada batimento já segmentado é subdividido em suas componentes típicas (Figura 9), ou seja, onda P, complexo QRS e onda T, seguindo a proporção de 25% para onda P, 25% para o complexo QRS e 50% para a onda T proposta por (LEITE; MORENO, 2018). Na metodologia proposta, características individuais são calculadas para cada segmento de cada batida, para servir como vetor de entrada para o modelo de classificação. As características morfológicas e temporais extraídas de cada segmento da batida estão listadas na Tabela 4, onde $x[n]$ é o vetor de amostras do segmento (onda P,




Figura 7 – Pico R.




Figura 8 – Batimento cardíaco.

QRS ou T) com N pontos e Δ denota a primeira diferença (aproximação numérica da derivada).

Além das características calculadas por segmento de onda, é calculado também o *NormalizedRR* para cada batida completa a partir da Equação 4.1. O valor obtido quantifica a variação percentual entre dois intervalos RR adjacentes em relação ao ritmo passado recente, e tem como objetivo indicar de maneira clara mudanças de ritmo no sinal, que podem representar condições clínicas.



Figura 9 – Ondas P-QRS-T.

Tabela 4 – Características extraídas por batimento e fórmulas

Característica	Fórmula
Amplitude mínima	$\min x[n]$
Amplitude máxima	$\max x[n]$
Amplitude média	$\bar{x} = \frac{1}{N} \sum_{n=0}^{N-1} x[n]$
Atividade	$\text{Atividade} = \sigma_x^2 = \frac{1}{N-1} \sum_{n=0}^{N-1} (x[n] - \bar{x})^2$
Mobilidade	$\text{Mobilidade} = \sqrt{\frac{\sigma_{\Delta x}^2}{\sigma_x^2}}$, com $\sigma_{\Delta x}^2 = \text{var}(\Delta x)$ e $\sigma_x^2 = \text{var}(x)$.
Complexidade	$\text{Complexidade} = \frac{\text{Mobilidade}(\Delta x)}{\text{Mobilidade}(x)} = \frac{\sqrt{\sigma_{\Delta^2 x}^2 / \sigma_{\Delta x}^2}}{\sqrt{\sigma_{\Delta x}^2 / \sigma_x^2}}$, onde $\Delta^2 x[n] = \Delta x[n+1] - \Delta x[n]$.

$$\text{NormalizedRR}_n = \frac{((R_{n+1} - R_n) - (R_n - R_{n-1})) \cdot 100}{\frac{1}{5} \sum_{i=1}^5 (R_{n-i+1} - R_{n-i})}, \quad (4.1)$$

Na Equação 4.1, o numerador corresponde à diferença entre o intervalo RR posterior e o intervalo RR anterior imediato, isto é, a variação absoluta entre intervalos consecutivos e o denominador é a média dos cinco intervalos RR imediatamente anteriores ao ponto avaliado, que representa o ritmo local recente. A multiplicação por 100 converte a razão em

percentagem, de modo que valores positivos de NormalizedRR_n indicam prolongamento percentual do próximo RR em relação ao ritmo recente e valores negativos indicam encurtamento percentual. Para implementação reprodutível, salienta-se que a métrica não é definida para os primeiros cinco instantes do traçado (faltam cinco RR anteriores) e, portanto, essas batidas são descartadas (sem prejuízo para o modelo).

O conjunto de características extraído de cada batida segmentada serve como vetor de entrada para os modelos de classificação supervisionados e recebe um rótulo de acordo com as anotações originais da base de dados, identificando se a mesma é uma batida de AVNRT (classe positiva) ou não (classe negativa).

4.3 Modelos de Aprendizado de Máquina

Por motivos pragmáticos e metodológicos, foram selecionados três algoritmos de classificação supervisionada amplamente empregados na literatura: *SVM*, *Random Forest* e *LightGBM*. O *SVM* (com *kernel RBF*) tem elevada capacidade discriminativa em problemas com número moderado de amostras e dimensão intermediária de características; o *Random Forest* oferece robustez a ruído, resistência ao *overfitting* e interpretabilidade via importância de variáveis; e o *LightGBM*, representante moderno de métodos de *boosting*, costuma apresentar excelente desempenho em dados tabulares, com treino rápido, boa capacidade de capturar interações não lineares e mecanismos nativos de regularização que ajudam na generalização. Essas escolhas permitem comparar modelos com perfis complementares de complexidade, interpretabilidade e custo computacional (DHYANI; KUMAR; CHOUDHURY, 2023).

A escolha de iniciar a comparação por esses métodos foi por possibilitarem uma avaliação clara do fluxo de trabalho proposto com custo computacional contido, o que é um fator importante para aplicação em ambientes clínicos com recursos limitados e por fornecerem bases interpretáveis para inspeção clínica.

4.3.1 Ajuste de Modelos

Os modelos foram implementados na linguagem Python 3.13.2, utilizando a biblioteca *Scikit-learn*, em um fluxo de trabalho simples composto por uma etapa de padronização das variáveis (*StandardScaler*), seguida pela etapa de classificação. A padronização consiste na transformação linear apresentada na Equação 4.2, na qual cada variável é centralizada pela média e escalada pelo desvio-padrão calculados no conjunto de treinamento.

$$z = \frac{x - \mu}{\sigma} \quad (4.2)$$

Onde:

x valor original da variável;

μ média da variável calculada no conjunto de treinamento;

σ desvio-padrão da variável calculado no conjunto de treinamento;

z valor padronizado resultante da transformação.

4.3.1.1 SVM

Para a busca dos melhores hiperparâmetros do *SVM*, foi utilizada uma grade explícita em escala logarítmica, com valores de C distribuídos por ordens de magnitude, de modo a explorar diferentes níveis de regularização. Valores menores de C impõem maior regularização, permitindo mais violações da margem e uma fronteira de decisão mais suave; valores maiores de C reduzem a regularização e penalizam mais fortemente os erros de treinamento. Para o parâmetro γ do *kernel RBF*, foram avaliadas opções automáticas da biblioteca *Scikit-learn* (*scale* e *auto*) e valores manuais muito pequenos. Nesse contexto, γ controla o alcance da influência de cada amostra: valores altos tornam essa influência mais local e podem favorecer sobreajuste, enquanto valores baixos produzem fronteiras mais suaves e globais. Todas as configurações do *SVM* podem ser visualizadas no Código 1.

4.3.1.2 Random Forest

Para buscar o melhor desempenho do *Random Forest*, foi definida uma grade de hiperparâmetros que explora diferentes níveis de complexidade e robustez. Testou-se o número de árvores (100 e 200) para avaliar o ganho de estabilidade da predição em função do custo de treinamento; variou-se a profundidade máxima entre configurações livres e limitadas, de modo a controlar o sobreajuste sem eliminar padrões relevantes; ajustaram-se os parâmetros relacionados às divisões, tamanho mínimo de divisão e número mínimo de amostras por folha, para evitar partições em nós com poucos exemplos e assim favorecer folhas mais generalizadas. Finalmente, fixou-se `max_features='sqrt'` (seleciona a raiz quadrada do número total de atributos a cada divisão), prática apontada como boa heurística para classificação na literatura recente (PROBST; WRIGHT; BOULESTEIX, 2019) e documentada na implementação do pacote *Scikit-learn* (scikit-learn developers, 2024). Essa configuração inicial permite ao *GridSearchCV* encontrar automaticamente o melhor equilíbrio entre viés e variância para a tarefa de classificação de batimentos com AVNRT. Todas essas configurações podem ser visualizadas no Código 2.

4.3.1.3 LightGBM

O ajuste do *LightGBM* foi realizado por meio de uma busca em grade (*GridSearchCV*) aplicada a um fluxo de trabalho contendo um *LGBMClassifier* balanceado para

```
1
2 pipe = Pipeline([
3     ('scaler', StandardScaler()),
4     ('svm', SVC(
5         kernel='rbf',
6         class_weight='balanced',
7         probability=True))
8 ])
9
10 param_grid = {
11     'svm__C': [0.1, 1, 10, 100],
12     'svm__gamma':
13         ['scale', 'auto', 0.01, 0.001, 0.0001]
14 }
15
16 cv = StratifiedKfold(
17     n_splits=5,
18     shuffle=True,
19     random_state=42
20 )
21 grid = GridSearchCV(
22     pipe,
23     param_grid,
24     cv=cv,
25     scoring='f1',
26     n_jobs=-1,
27     verbose=2
28 )
```

Código 1 – Parâmetros do SVM

poder compensar o desbalanceamento entre classes. A grade avaliou combinações explícitas dos seguintes hiperparâmetros: número de árvores, número máximo de folhas, profundidade máxima, taxa de aprendizado, tamanho mínimo de amostras por folha e subamostragem. Esses valores correspondem às faixas mais utilizadas na literatura e permitem explorar tanto modelos mais simples quanto configurações com maior expressividade, sem inflar excessivamente o custo computacional. A validação utilizou *StratifiedKfold* com 5 dobras e o critério de avaliação foi o *F1-score*, adequado para cenários com classes desbalanceadas. A busca foi executada com paralelismo e reprodutibilidade garantida através do valor '42' que foi atribuído ao '*random_state*'. O modelo final corresponde ao estimador retornado pelo *GridSearchCV* com os melhores hiperparâmetros após este ter sido retreinado automaticamente em todo o conjunto de treinamento com a configuração ótima. Todas essas configurações podem ser visualizadas no Código 3.

4.4 Avaliação de Desempenho

O desempenho dos modelos foi avaliado com base na matriz de confusão e em métricas derivadas comumente utilizadas em problemas de classificação binária. A matriz de

```

1
2 pipe_rf = Pipeline([
3     ('scaler', StandardScaler()),
4     ('rf', RandomForestClassifier(
5         random_state=42,
6         class_weight='balanced'))
7 ])
8
9 param_grid_rf = {
10     'rf__n_estimators': [100, 200],
11     'rf__max_depth': [None, 10, 20],
12     'rf__min_samples_split': [2, 5],
13     'rf__min_samples_leaf': [1, 2],
14     'rf__max_features': ['sqrt']
15 }
16
17 cv = StratifiedKFold(
18     n_splits=5,
19     shuffle=True,
20     random_state=42
21 )
22
23 grid_rf = GridSearchCV(
24     pipe_rf,
25     param_grid_rf,
26     cv=cv,
27     scoring='f1',
28     n_jobs=-1,
29     verbose=2
30 )

```

Código 2 – Parâmetros do Random Forest

confusão, apresentada na Tabela 5, resume as contagens de predições corretas e incorretas, incluindo Verdadeiros Positivos, Verdadeiros Negativos, Falsos Positivos e Falsos Negativos, servindo como base para o cálculo das métricas quantitativas de avaliação.

Tabela 5 – Matriz de confusão para classificação binária (rótulo positivo = AVNRT).

	Predito = Positivo	Predito = Negativo
Real = Positivo	Verdadeiros Positivos (VP)	Falsos Negativos (FN)
Real = Negativo	Falsos Positivos (FP)	Verdadeiros Negativos (VN)

Em problemas médicos, cada informação da matriz é particularmente relevante, uma vez que os diferentes tipos de erro possuem impactos clínicos distintos. Em muitos cenários, a ocorrência de falsos negativos, isto é, casos patológicos não identificados pelo modelo, pode resultar em atrasos no diagnóstico ou no tratamento, enquanto falsos positivos podem gerar exames adicionais ou ansiedade desnecessária ao paciente. Assim, a matriz de confusão fornece uma base objetiva para avaliar a adequação do modelo ao contexto clínico específico.

```
1
2 pipe_lgb = Pipeline([
3     ('scaler', StandardScaler()),
4     ('lgbm', LGBMClassifier(random_state=42, class_weight='balanced', n_jobs=-1))
5 ])
6
7 param_grid_lgb = {
8     'lgbm__n_estimators': [100, 200],
9     'lgbm__num_leaves': [31, 63],
10    'lgbm__max_depth': [-1, 10, 20],
11    'lgbm__learning_rate': [0.1, 0.01],
12    'lgbm__min_child_samples': [5, 20],
13    'lgbm__subsample': [0.8, 1.0]
14 }
15
16 cv = StratifiedKFold(
17     n_splits=5,
18     shuffle=True,
19     random_state=42
20 )
21
22 grid_lgb = GridSearchCV(
23     pipe_lgb,
24     param_grid_lgb,
25     cv=cv,
26     scoring='f1',
27     n_jobs=-1,
28     verbose=0
29 )
30
```

Código 3 – Parâmetros do LightGBM

Além disso, a matriz de confusão permite interpretar de forma clara métricas derivadas amplamente utilizadas, como sensibilidade, especificidade, precisão e *F1-score*, evidenciando como esses indicadores se relacionam com os diferentes tipos de acerto e erro. Nas seções seguintes, serão apresentadas essas métricas: a fórmula, uma breve interpretação e observações práticas.

4.4.1 Métricas e fórmulas

As métricas apresentadas nesta subseção seguem a formulação clássica para tarefas de classificação binária (FAWCETT, 2006; SOKOLOVA; LAPALME, 2009).

4.4.1.1 Precisão (Valor preditivo positivo, VPP)

$$\text{Precisão (Prec.)} = \text{VPP} = \frac{\text{VP}}{\text{VP} + \text{FP}} \quad (4.3)$$

Interpretação: fração das predições positivas que estão corretas; mede a confiabilidade das predições de AVNRT (SOKOLOVA; LAPALME, 2009).

4.4.1.2 Sensibilidade (Revocação ou Taxa de Verdadeiros Positivos, TVP)

$$\text{Sensibilidade (Sens.)} = \text{Revocação} = \text{TVP} = \frac{\text{VP}}{\text{VP} + \text{FN}} \quad (4.4)$$

Interpretação: proporção dos casos positivos reais corretamente detectados; importante em triagem clínica para minimizar falsos negativos (SOKOLOVA; LAPALME, 2009).

4.4.1.3 Especificidade (Taxa de Verdadeiros Negativos, TVN)

$$\text{Especificidade (Esp.)} = \text{TVN} = \frac{\text{VN}}{\text{VN} + \text{FP}} \quad (4.5)$$

Interpretação: proporção dos negativos reais corretamente identificados; útil para avaliar a taxa de falsos alarmes (SOKOLOVA; LAPALME, 2009).

4.4.1.4 Acurácia

$$\text{Acurácia (Acc.)} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{FP} + \text{VN} + \text{FN}} \quad (4.6)$$

Observação: em conjuntos desbalanceados, esta métrica pode ser enganosa; por isso, é analisada juntamente com precisão, sensibilidade e outras medidas (SOKOLOVA; LAPALME, 2009).

4.4.1.5 F1-score

$$\text{F1} = 2 \cdot \frac{\text{Precisão} \cdot \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (4.7)$$

Interpretação: média harmônica entre precisão e sensibilidade; favorece modelos com bom equilíbrio entre falsos positivos e falsos negativos (SOKOLOVA; LAPALME, 2009).

4.4.1.6 AUC-ROC (Área sob a curva ROC)

A curva ROC relaciona a taxa de verdadeiros positivos (TVP) à taxa de falsos positivos (TFP) ao variar o limiar de decisão, e a AUC resume a capacidade discriminativa do classificador de forma independente do limiar escolhido (FAWCETT, 2006).

$$\text{AUC} = \int_0^1 \text{TVP}(\text{TFP}^{-1}(t)) dt \quad (4.8)$$

Interpretação: valores próximos de 1 indicam melhor separação entre classes ([FAW-CETT, 2006](#)).

5 Resultados

Para facilitar uma avaliação abrangente e intuitiva do desempenho dos modelos, foram geradas métricas quantitativas e representações gráficas que incluem curvas ROC, matrizes de confusão e gráficos de importância das características. Essas visualizações permitem a identificação de padrões nos dados, a avaliação da capacidade discriminativa dos classificadores e a análise da contribuição de cada característica para a detecção de batimentos indicativos de AVNRT.

5.1 Curva ROC

As curvas *ROC* dos modelos supervisionados estão apresentadas na Figura 10. A linha tracejada diagonal representa o comportamento de um classificador aleatório ($AUC = 0.5$) e serve como referência. Visualmente e numericamente, os três classificadores exibem boa capacidade discriminativa: o *SVM* alcançou a maior área sob a curva ($AUC = 0,989$), seguido pelo *LightGBM* ($AUC = 0,965$) e pelo *Random Forest* ($AUC = 0,926$). A forma das curvas fornece informação adicional além do valor do *AUC*: a curva do *SVM* (laranja) sobe muito rapidamente perto do eixo vertical, o que indica que ele obtém sensibilidade elevada mesmo para taxas de falsos positivos muito baixas — um comportamento desejável quando se quer detectar o máximo de casos verdadeiros sem gerar muitos alarmes. O *LightGBM* (azul) também apresenta perfil muito favorável, com curva próxima ao canto superior esquerdo, sinalizando forte discriminação; o *Random Forest* (verde) tem uma ascensão mais gradual, traduzindo menor sensibilidade para baixas taxas de falsos positivos em comparação com os outros dois modelos.

5.2 Matriz de Confusão

As matrizes de confusão apresentadas na Figura 11 permitem avaliar, de forma direta, como cada classificador distribui erros entre as classes “Normal” e “AVNRT”. Os números contidos em cada célula representam as contagens absolutas sobre o conjunto de teste: por exemplo, no *SVM* foram corretamente classificados 1.367 batimentos Normais (Verdadeiros Positivos para a classe Normal) e 3.482 batimentos AVNRT (Verdadeiros Positivos para a classe AVNRT), enquanto apenas 45 batimentos Normais foram classificados como AVNRT (Falsos Positivos) e 175 batimentos AVNRT foram classificados como Normais (Falsos Negativos).

A partir dessas contagens é possível derivar métricas por classe que esclarecem os pontos fortes e fracos dos modelos. Tomando o *SVM* como exemplo: a sensibilidade sobre

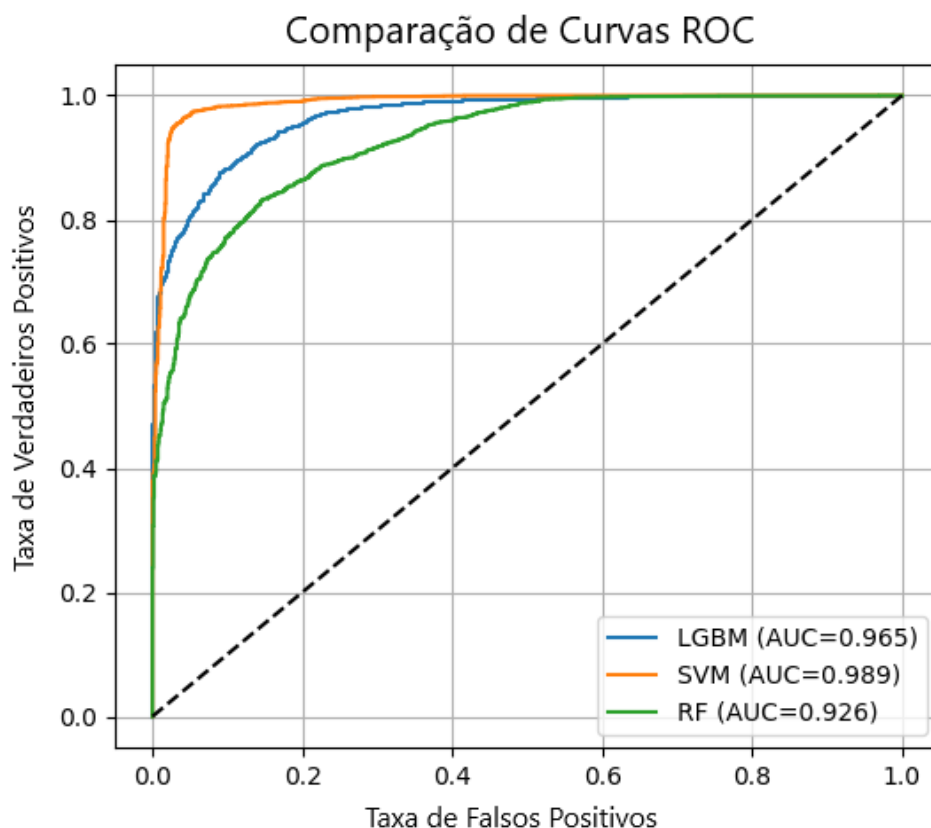


Figura 10 – Curva ROC para os modelos de aprendizado de máquina supervisionados




Figura 11 – Matriz de confusão para os modelos de aprendizado de máquina

a classe AVNRT é $3.482/3.657 = 0,952$, isto é, o *SVM* detectou $\approx 95,2\%$ dos batimentos de AVNRT e a precisão para AVNRT é $3.482/(3.482+45) = 0,987$, indicando que quando o *SVM* prevê AVNRT, a probabilidade de estar correto é muito alta. Comparativamente, o *Random Forest* apresenta sensibilidade de AVNRT menor ($3.031/3.657 = 0,829$) e o *LightGBM* fica entre os dois ($0,931$), o que explica parte das diferenças de *AUC* observadas nas curvas *ROC*. Para a classe Normal a análise é análoga: o *SVM* alcança sensibilidade de $0,968$ e precisão de $0,887$, enquanto *Random Forest* tem precisão mais baixa ($0,659$) devido ao grande número de batimentos AVNRT classificados incorretamente como Normais (626),

e o *LightGBM* mostra desempenho intermediário.

5.3 Importância das Características

A Figura 12 apresenta importâncias de características normalizadas (soma = 1 por modelo) atribuídas pelo *Random Forest* e pelo *LightGBM*.

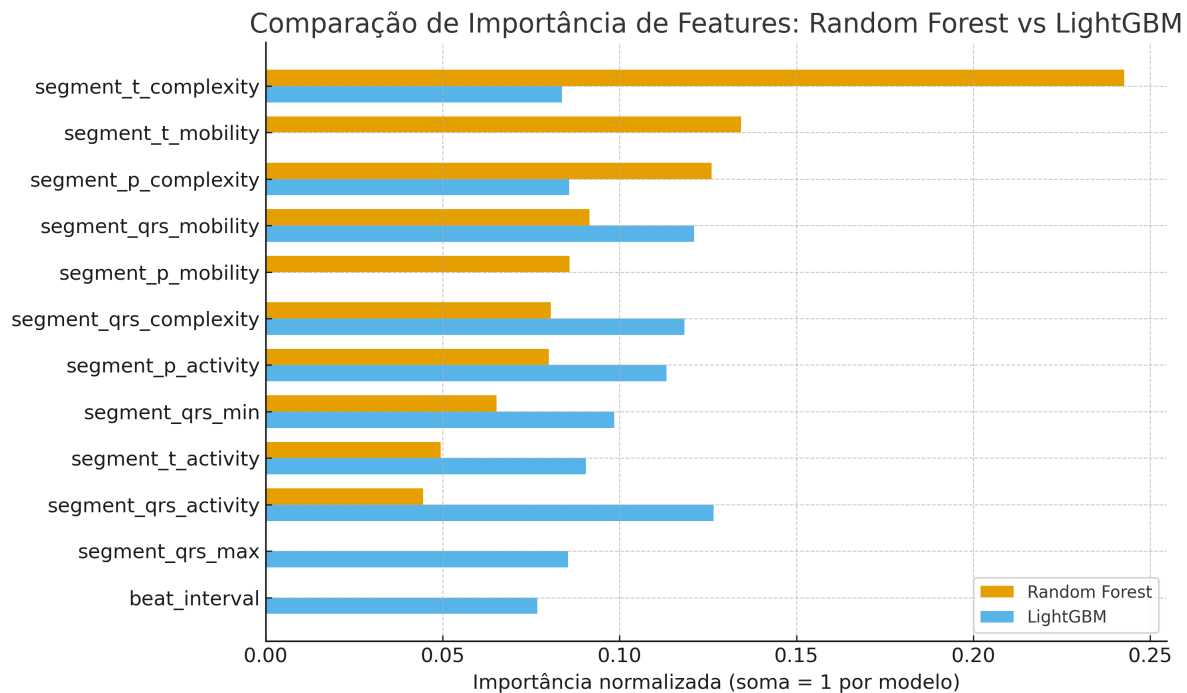


Figura 12 – Ranking de comparação de importância das características

A forte ênfase do *Random Forest* nas características *segment_t_complexity* e *segment_t_mobility* sugere que esse modelo extrai principalmente sinais de repolarização (dinâmica e heterogeneidade da onda T) para distinguir AVNRT de batimentos normais. Na prática, isso indica que o modelo está sensível a mudanças morfológicas e temporais mais sutis na T (aspectos que podem refletir variações na interação atrioventricular durante episódios de reentrada) e que exigem janelas de análise bem alinhadas e um pré-processamento eficaz para preservar a forma da T (remoção de *baseline wander*, rejeição de ruído de alta amplitude). Portanto, ao usar um classificador do tipo *Random Forest*, recomenda-se priorizar a qualidade do segmento T no fluxo de trabalho (filtragem, alinhamento de batimentos e verificação de presença/visibilidade da P/T).

Já o comportamento do *LightGBM*, que atribuiu maior importância às variáveis *segment_qrs_activity* e *segment_qrs_mobility*, sugere que esse algoritmo é particularmente sensível a variações locais e de maior conteúdo dinâmico no complexo QRS, como transições abruptas, assimetrias e mudanças rápidas de amplitude. Essas características estão associadas a informações temporais de curta duração, frequentemente relevantes na

caracterização da ativação ventricular. Do ponto de vista operacional, essa observação sugere que atributos derivados do complexo QRS podem apresentar maior estabilidade em janelas temporais curtas, uma vez que o QRS é uma porção do traçado com delimitação mais nítida. Em cenários práticos, isso pode ser vantajoso em aplicações com restrições de latência computacional. Em segundo lugar, a diferença observada no padrão de importância de atributos entre os modelos reforça a complementaridade entre abordagens: enquanto o *LightGBM* parece privilegiar informações do QRS, o *Random Forest* mostrou maior sensibilidade a características associadas ao segmento T. Dessa forma, a combinação dessas fontes de informação constitui uma direção promissora para trabalhos futuros, com potencial para capturar um conjunto mais abrangente de evidências eletrocardiográficas.

5.4 Métricas Quantitativas

A Tabela 6 mostra dois sinais consistentes: todos os três classificadores atingiram desempenho elevado ($F1\text{-score} \approx 0,98$), e os modelos diferem sobretudo no compromisso entre discriminação global (AUC) e equilíbrio entre precisão/sensibilidade ($F1\text{-score}$), além do impacto prático da acurácia absoluta. Numericamente, o *SVM* apresenta a maior AUC (0,9886) e a maior acurácia (0,9566), o que indica que, em termos de separação global entre classes e de proporção de predições corretas, ele é o mais discriminativo do grupo. Já o *LightGBM* alcança o maior $F1\text{-score}$ (0,9862), sinalizando o melhor equilíbrio imediato entre precisão e sensibilidade na escolha do limiar aplicado; na prática isso significa que o *LightGBM* tende a oferecer menos *trade-offs* entre falsos positivos e falsos negativos no limiar usado para gerar estas métricas. O *Random Forest* fica consistentemente atrás dos dois ($AUC = 0,9263$; $F1\text{-score} = 0,9814$; acurácia = 0,8361), confirmando o observado nas matrizes de confusão onde apresenta maior taxa de erros, especialmente falsos negativos para AVNRT.

Essas diferenças sugerem recomendações práticas distintas: quando o objetivo é maximizar a capacidade discriminativa, o *SVM* se destaca por apresentar maior AUC . Por outro lado, quando o objetivo é reduzir o tempo de inferência em cenários com restrição de latência, o *LightGBM* mostra-se mais adequado, pois apresentou $F1\text{-score}$ ligeiramente superior e menor tempo de predição nas medições realizadas. O *Random Forest*, apesar de robusto, apresentou necessidade de ajuste de limiar e/ou reponderação de classes para reduzir falsos negativos antes de ser indicado para triagem clínica.

Tabela 6 – Comparação das métricas de desempenho

Modelo	F1-score	ROC AUC	Acurácia
SVM	0.9831	0.9886	0.9566
LightGBM	0.9862	0.9647	0.9049
Random Forest	0.9814	0.9263	0.8361

A Tabela 7 revela diferenças claras no comportamento por classe entre os três modelos. Para a classe AVNRT, o *SVM* apresenta a melhor combinação de precisão e sensibilidade (Prec. = 0,987; Sens. = 0,952), indicando que quase todas as predições de AVNRT são corretas e que o modelo captura a grande maioria dos eventos patológicos. O *LightGBM* tem desempenho um pouco inferior, mas ainda consistente (Prec. = 0,937; Sens. = 0,931), enquanto o *Random Forest* mostra precisão semelhante (0,937) porém sensibilidade claramente menor (0,829), ou seja, tende a perder mais casos de AVNRT. Para a classe Normal, o *SVM* também alcança o melhor compromisso (Prec. = 0,886; Sens. = 0,968), enquanto *LightGBM* apresenta métricas intermediárias (0,823 / 0,839) e o *Random Forest* mostra precisão baixa (0,659) apesar de sensibilidade razoável (0,855), sinalizando que muitas predições de Normal feitas pelo mesmo são erradas (provavelmente confundindo AVNRT com Normal).

Do ponto de vista prático e clínico, essas diferenças têm implicações diretas: falsos negativos em AVNRT (baixa sensibilidade) são os erros mais críticos para uma ferramenta de triagem, pois eles representam eventos patológicos não detectados. Nesse aspecto, o *SVM* é o candidato preferível no conjunto de teste, por combinar alta sensibilidade com altíssima precisão para AVNRT, reduzindo tanto perdas quanto alarmes falsos. O *LightGBM* constitui uma alternativa robusta quando se busca compromisso entre desempenho e eficiência operacional (inferência mais rápida), pois oferece *F1-score* e sensibilidade próximos aos do *SVM*. Já o *Random Forest*, com sensibilidade menor para AVNRT e baixa precisão para Normais, exigiria reponderação de classes, ajuste de limiar ou seleção/engenharia adicional de atributos antes de ser indicado para triagem clínica.

Tabela 7 – Precisão e sensibilidade por classe (conjunto de teste)

Classe	SVM		LightGBM		Random Forest	
	Prec.	Sens.	Prec.	Sens.	Prec.	Sens.
Normal (0)	0.886	0.968	0.823	0.839	0.659	0.855
AVNRT (1)	0.987	0.952	0.937	0.931	0.937	0.829

De maneira geral, o desempenho superior da *SVM* e do *LightGBM* sugere que, no conjunto de características extraídas, as amostras com indicativos de AVNRT já apresentam separação suficiente para serem discriminadas por fronteiras de decisão bem definidas, sem exigir representações excessivamente complexas ou profundas. A *SVM* mostrou-se particularmente adequada ao cenário de base limitada, beneficiando-se da maximização de margem e da boa capacidade de generalização, o que sugere uma separação consistente entre as classes a partir dos atributos extraídos. Já o *LightGBM* destacou-se por explorar combinações não lineares entre atributos por meio de árvores de decisão em sequência, capturando interações locais entre variáveis associadas à morfologia e à dinâmica do complexo QRS, ao mesmo tempo em que mantém elevada eficiência

computacional. Em conjunto, esses resultados reforçam que modelos clássicos, quando alinhados às características do problema e à natureza fisiológica do ECG, podem alcançar desempenho elevado, robustez e viabilidade prática em aplicações clínicas.

A Tabela 8 apresenta os hiperparâmetros ótimos identificados via *GridSearchCV* para os três modelos avaliados. Esses valores representam as configurações que maximizaram o desempenho médio durante a validação cruzada, refletindo um ajuste sistemático do grau de complexidade e da capacidade de generalização de cada classificador. Como os modelos possuem mecanismos internos distintos de aprendizado, observa-se que o processo de otimização resultou em combinações diferentes de parâmetros, indicando que cada algoritmo encontrou uma forma específica de separar batimentos normais daqueles associados à AVNRT.

Tabela 8 – Hiperparâmetros ótimos identificados pelo GridSearchCV

Modelo	Hiperparâmetros
SVM	$C = 100$, $\text{gamma} = \text{'scale'}$
LightGBM	$\text{lgbm_learning_rate} = 0.1$, $\text{lgbm_max_depth} = 10$, $\text{lgbm_min_child_samples} = 5$, $\text{lgbm_n_estimators} = 200$, $\text{lgbm_num_leaves} = 31$, $\text{lgbm_subsample} = 0.8$
Random Forest	$\text{n_estimators} = 100$, $\text{max_depth} = 20$, $\text{min_samples_split} = 2$, $\text{min_samples_leaf} = 2$, $\text{max_features} = \text{'sqrt'}$

No caso do *SVM*, o valor elevado de regularização ($C = 100$) sugere que o modelo obteve melhor desempenho ao penalizar fortemente erros de classificação, buscando uma fronteira de decisão mais rígida e com menor tolerância a margens amplas. Esse comportamento é consistente com cenários em que as classes apresentam separabilidade razoável no espaço de características, permitindo ao modelo estabelecer uma superfície de decisão mais definida. Além disso, o uso de $\text{gamma} = \text{'scale'}$ implica que o parâmetro do *kernel* foi ajustado automaticamente em função da variância dos dados, contribuindo para estabilidade e reduzindo o risco de escolhas inadequadas de escala no espaço transformado.

Para o *LightGBM*, a configuração encontrada combina uma taxa de aprendizado moderada (0.1) com um número relativamente alto de estimadores (200), indicando que o modelo se beneficia de um processo de refinamento progressivo, no qual múltiplas árvores são adicionadas para reduzir o erro residual. O valor $\text{max_depth} = 10$ e $\text{num_leaves} = 31$ sugere que o modelo aprendeu relações não lineares relativamente complexas, explorando interações entre as características extraídas do ECG. O uso de $\text{subsample} = 0.8$ também é relevante, pois introduz aleatoriedade no treinamento e atua como mecanismo de regularização, reduzindo a probabilidade de sobreajuste e melhorando a capacidade de generalização.

Já no *Random Forest*, os parâmetros indicam um modelo com complexidade controlada: $max_depth = 20$ permite árvores expressivas, enquanto $min_samples_leaf = 2$ evita divisões excessivamente específicas. Além disso, $max_features = 'sqrt'$ favorece diversidade entre árvores, tornando o modelo mais robusto e menos sensível a ruídos ou redundâncias no conjunto de características.

A Tabela 9 quantifica o custo computacional observado neste experimento, exibindo os tempos totais de treinamento e de predição (segundos) medidos para cada classificador. Os resultados mostram um claro *trade-off* entre custo de treino e adequação operacional: o *SVM* exigiu tempo de treinamento substancialmente maior (761,72 s) e apresentou latência de predição também mais elevada (0,54 s), enquanto *Random Forest* e *LightGBM* treinaram em tempos muito menores (≈ 211 s e ≈ 208 s, respectivamente) e tiveram latência de predição quase nula em comparação (0,06s). Esses números indicam que, para o conjunto de dados e a configuração experimental adotados, os métodos de árvore agregada oferecem uma vantagem operacional importante em termos de rapidez tanto na fase de treinamento quanto na inferência. Os tempos reportados foram medidos em um computador com processador Intel Core i5-1135G7 (11^a geração, 4 núcleos / 8 threads, 2.40 GHz), 16 GB de RAM e sistema operacional Windows 11 Pro 64-bits; essas medições são comparáveis entre si, mas refletem a configuração de execução e podem variar em função do hardware, número de threads, paralelização e eventual uso de aceleração por GPU.

Tabela 9 – Tempo computacional de treinamento e predição (segundos).

Modelo	Treino (s)	Predição (s)
SVM	761.72	0.54
Random Forest	211.40	0.06
LightGBM	208.42	0.06

Do ponto de vista de aplicação prática, as implicações são diretas. Se o objetivo for análise retrospectiva ou processamento centralizado (servidores com recursos adequados), onde o tempo de treinamento é tolerável e se busca a máxima separabilidade estatística, o *SVM* permanece uma opção válida dada sua *AUC* superior. Em contrapartida, para cenários de monitorização contínua (onde a latência por batimento e o consumo de energia são críticos), *LightGBM* e *Random Forest* podem ser mais adequados: tempos de predição baixos reduzem o consumo energético e permitem maior taxa de amostragem/*throughput*. Entre esses dois, o *LightGBM* frequentemente apresenta modelos menores e inferência mais otimizada, tornando-o particularmente atraente para soluções com restrição de memória e necessidade de baixa latência.

5.5 Desempenho dos modelos e compensações operacionais

Os resultados evidenciam um claro *trade-off* operacional entre poder discriminativo e eficiência computacional. O *SVM* obteve a maior capacidade de separação global ($AUC-ROC = 0,9886$, Acurácia = $0,9566$), atribuível à sua eficácia em modelar fronteiras de decisão em espaços de características de alta dimensão com amostras moderadas. Entretanto, essa precisão tem um custo computacional elevado: o tempo de treinamento do *SVM* (761,7s) foi quase quatro vezes maior que o dos métodos *ensemble*, e a latência de predição (0,54s) foi quase uma ordem de magnitude superior.

Em contrapartida, o *LightGBM* mostrou-se o candidato mais equilibrado para implantação em ambientes reais. Alcançou o maior *F1-score* (0,9862), indicando um equilíbrio superior entre sensibilidade e precisão, que é crucial em triagem clínica para minimizar alarmes falsos sem deixar de identificar eventos verdadeiros. Notavelmente, o *LightGBM* apresentou tempo de predição de 0,06s, aproximadamente 9 vezes mais rápido que o *SVM*. No contexto de dispositivos vestíveis ou monitorização contínua à beira do leito, onde duração de bateria e processamento em tempo real são restrições críticas, esse ganho de eficiência é determinante. O *Random Forest*, embora ligeiramente inferior em *AUC* (0,9263), igualou a velocidade de inferência do *LightGBM* e ofereceu interpretabilidade valiosa por meio da análise de importância de características.

Consequentemente, a escolha do modelo depende do cenário de aplicação clínica: o *SVM* é preferível para análises *offline* e retrospectivas em que a máxima acurácia é prioritária, enquanto o *LightGBM* é a opção mais adequada para aplicações em tempo real e computação de borda.

5.6 Comparação com o estado da arte

A Tabela 10 compara nossos resultados com estudos recentes focados na diferenciação de SVT. Embora a comparação direta seja dificultada por diferenças de bases de dados e populações (adultos vs. pediatria), chama a atenção que nossos modelos leves atingiram *AUCs* (0.92–0.98) e *F1-scores* (0.98) competitivos com, ou superiores a, outras abordagens, como as redes CNN empregadas por Higuchi et al. (HIGUCHI et al., 2023) e Sau et al. (SAU et al., 2023). Ademais, nosso método superou o recente modelo multivariável de De La Linde Valdes et al. (VALDES et al., 2024) (*F1-Score* = 0.898).

Tabela 10 – Comparação com estado da arte para diferenciação de SVT.

Modelo / Trabalho	Metodologia	Idade (Média)	Derivações	AUC	F1-Score
Nosso modelo (LightGBM)	Hjorth + LGBM	13.2	1	0.965	0.986
Nosso modelo (SVM)	Hjorth + SVM	13.2	1	0.989	0.983
De La Linde Valdes et al. (2024) (VALDES et al., 2024)	Clinical/ECG Features	53.6	12	0.916	0.898
Higuchi et al. (2023) (HIGUCHI et al., 2023)	Aprendizado Profundo (CNN)	45.0	12	0.909	0.760
Sau et al. (2023) (SAU et al., 2023)	Aprendizado Profundo (CNN)	54.0	12	0.820	0.630

Esse achado desafia a tendência predominante de que “mais profundo é sempre melhor”. Em cenários com dados limitados, como arritmias pediátricas raras, modelos profundos são suscetíveis a *overfitting* e demandam recursos computacionais extensos. Os resultados indicam que a extração explícita de características (por exemplo, parâmetros de Hjorth) combinada com classificadores *ensemble* robustos fornece uma alternativa mais eficiente e igualmente precisa. Crucialmente, enquanto trabalhos prévios basearam-se em ECGs de 12 derivações, este estudo alcançou alto desempenho utilizando características extraídas apenas da derivação V1, reduzindo significativamente tanto o custo computacional quanto a complexidade de hardware.

Ao obter discriminação elevada ($AUC > 0,96$) e confiabilidade ($F1\text{-score} > 0,98$) com informação significativamente reduzida, os achados validam a viabilidade de implementar ferramentas de triagem de alta precisão em patches vestíveis monocanais para crianças, superando limitações dos sistemas tradicionais de 12 derivações.

5.7 Limitações

Apesar dos resultados promissores, este estudo apresenta limitações inerentes, principalmente decorrentes da escassez de dados. A maior restrição é o pequeno número de pacientes pediátricos com AVNRT confirmada ($n = 13$). Como discutido na seção de Metodologia (Seção 4), isso reflete a atual falta de repositórios públicos de ECG pediátricos rotulados por arritmia, e não uma exclusão arbitrária. Essa limitação reduz a variabilidade amostral (idade, morfologia do QRS, ruído, posicionamento de eletrodos, condições clínicas) e pode inflar métricas obtidas em avaliações *offline*. Embora tenha sido adotada uma divisão por sujeito para mitigar *data leakage*, persiste o risco do modelo aprender traços específicos de pacientes em vez de padrões patológicos generalizáveis. Os dados oriundos de um único hospital podem refletir protocolos específicos, características demográficas regionais ou padrões técnicos particulares. Por isso, as métricas aqui reportadas devem ser interpretadas como prova de conceito do potencial metodológico, exigindo validação em coortes maiores e multicêntricas para confirmar a generalização a populações clínicas diversas.

Adicionalmente, os modelos foram treinados em batimentos pré-segmentados e anotados. A implantação em cenários reais exigirá a integração de um detector automático de picos R e de um módulo de rejeição de ruído para lidar com artefatos de movimento típicos de contextos ambulatoriais pediátricos. Trabalhos futuros devem enfrentar esses desafios de fluxo de trabalho ponta-a-ponta.

6 Conclusão

O objetivo central deste trabalho foi propor, desenvolver e validar um método reproduzível e operacionalmente viável para a detecção automática de batimentos com indicativos eletrocardiográficos de AVNRT em ECGs pediátricos. Para tanto, foi proposto um fluxo de trabalho baseado em segmentação batimento a batimento (pico R), extração de características tempo-morfológicas (incluindo parâmetros de Hjorth: Atividade, Mobilidade e Complexidade) e classificação por modelos com custo computacional inferior ao de arquiteturas profundas (*SVM*, *Random Forest* e *LightGBM*), adotando validação estratificada por paciente para mitigar contaminação de dados.

Os resultados observados indicam que a abordagem proposta cumpriu o objetivo de produzir um método viável para triagem automatizada. Na Tabela 6 todos os classificadores alcançaram *F1-scores* próximos de 0,98 (*SVM* = 0,9831; *LightGBM* = 0,9862; *Random Forest* = 0,9814), mostrando que o conjunto de 20 características extraídas contém informação discriminativa suficiente para separar batimentos Normais e AVNRT. Em termos de capacidade discriminativa global, o *SVM* apresentou a maior *AUC* (0,9886) e a maior acurácia geral (0,9566), sugerindo melhor separação entre classes quando considerados todos os limiares. O *LightGBM* obteve o maior *F1-score* (0,9862) e combinou desempenho preditivo competitivo com latência de predição muito baixa (0,06s), enquanto o *Random Forest* apresentou desempenho inferior em *AUC* (0,9263) e acurácia (0,8361), refletindo maior ocorrência de falsos negativos em AVNRT conforme indicado nas matrizes de confusão.

A partir dos resultados experimentais e das demandas clínicas típicas, é possível traçar recomendações de escolha do modelo:

- **SVM:** indicado quando a prioridade for máxima discriminação estatística por batimento (*AUC* mais alta) e quando o custo de treinamento/predição (tempo e recursos) não for o limitador, por exemplo, análises retrospectivas, processamento em servidor centralizado ou estudos diagnósticos secundários.
- **LightGBM:** é a opção preferível para implantação operacional em tempo real ou em dispositivos com restrições de latência/energia, pois combina *F1-score* elevado com tempo de inferência muito reduzido; ideal para aplicações de triagem contínua e embarcada, caso o pequeno sacrifício em *AUC* seja aceitável.
- **Random Forest:** oferece interpretabilidade via importâncias de atributos, mas, nas configurações testadas, mostrou sensibilidade menor para AVNRT e exigiria ajustes

(reponderação, seleção de características ou ajuste adicional) antes de ser adotado como sistema de triagem.

Portanto, concluímos que o procedimento proposto é bem sucedido como prova de conceito: alcançou o objetivo de detectar sinais associados a AVNRT com elevado poder discriminativo, sendo o *SVM* o vencedor em termos de separação estatística e o *LightGBM* o candidato operacional mais equilibrado.

6.1 Limitações

As conclusões acima devem ser consideradas à luz das limitações deste estudo:

- **Tamanho e origem da coorte:** a base utilizada contém 13 pacientes pediátricos rotulados; a amostra reduzida limita a variabilidade observada (idade, morfologias de QRS/T, condições clínicas) e aumenta a incerteza estatística das métricas.
- **Validação externa:** não houve, neste trabalho, validação em coortes multicêntricas independentes, que é uma etapa necessária para demonstrar generalização clínica.
- **Estudos eletrofisiológicos:** Por serem gravações de estudos eletrofisiológicos, os registros podem incluir estímulos e morfologias não típicas de ECGs ambulatoriais; portanto, a generalização dos resultados para cenários de monitorização contínua exige validação adicional em bases externas.
- **Fluxo de trabalho não totalmente ponta-a-ponta:** os modelos foram treinados sobre batimentos anotados; a integração de um detector automático de picos R robusto e de um módulo de rejeição de ruído (end-to-end) ainda é necessária para avaliação em fluxo real.
- **Incerteza estatística e testes de significância:** diferenças observadas (p.ex. *AUC SVM* vs *LightGBM*) requerem confirmação estatística (testes de *DeLong* ou *bootstrap* para IC) e avaliação por paciente (métricas agregadas) para evitar conclusões indevidas baseadas apenas em médias por batimento.
- **Sensibilidade a artefatos e vieses de aquisição:** variações em taxa de amostragem, posicionamento de eletrodos e pré-processamento podem afetar robustez dos classificadores.

6.2 Direções futuras e recomendações

Para avançar da prova de conceito à adoção clínica, propõe-se o seguinte roteiro prioritário:

1. **Expansão de dados e validação multicêntrica:** agregar coletas de diferentes instituições, com rótulos validados por estudo eletrofisiológico quando possível, para avaliar generalização e reduzir viés por paciente.
2. **Integração ponta-a-ponta:** incorporar detector automático de picos R robusto e módulo de rejeição de artefatos, e avaliar desempenho em dados brutos (fluxo de trabalho completo).
3. **Avaliações estatísticas robustas:** calcular intervalos de confiança (*bootstrap* por paciente), realizar testes de comparação de *AUC* (*DeLong*) e reportar métricas por paciente além das métricas por batimento.
4. **Otimização para produção:** explorar quantização/compactação de modelos, conversão para formatos embarcáveis (ONNX/TFLite), e avaliação de consumo energético em dispositivos reais.
5. **Estudos prospectivos e avaliação clínica:** conduzir ensaios prospectivos que mensurem impacto na triagem e no encaminhamento clínico, incluindo avaliação de aceitabilidade por profissionais de saúde.

6.3 Considerações finais

Em síntese, este trabalho demonstra que uma abordagem de engenharia de características de baixo custo, aliada a classificadores de complexidade moderada, é capaz de identificar batimentos com indícios de AVNRT em ECGs pediátricos com elevada acurácia e *F1-score*, oferecendo alternativas práticas ao uso exclusivo de modelos profundos em cenários com dados limitados. A escolha entre *SVM* e *LightGBM* dependerá do cenário de uso (*offline* vs. tempo real); contudo, a evidência obtida justifica a continuidade do desenvolvimento, com foco em expansão de coortes, validação externa e implementação ponta-a-ponta rumo a aplicações clínicas seguras e verificáveis.

Referências

- ANSARI, Y. et al. Deep learning for ecg arrhythmia detection and classification: an overview of progress for period 2017–2023. *Frontiers in Physiology*, v. 14, p. 1246746, 2023. Citado na página 22.
- Cables and Sensors, LLC. *12-Lead ECG Placement Guide – Ilustração do posicionamento de eletrodos*. 2026. <<https://www.cablesandsensors.com/pages/12-lead-ecg-placement-guide-with-illustrations>>. Imagem acessada em: 10 Jan. 2026. Citado 2 vezes nas páginas 7 e 17.
- CardVasc. *AV Atrioventricular Nodal Reentrant Tachyarrhythmia (AVNRT)*. 2023. Acesso em: 10 jan. 2026. Disponível em: <<https://cardvasc.org/av-atrioventricular-nodal-reentrant-tachyarrhythmia-reentry/>>. Citado 2 vezes nas páginas 7 e 20.
- CHOW, H.-S.; MOODY, G. B.; MARK, R. G. Detection of ventricular ectopic beats using neural networks. In: *Computers in Cardiology*. [S.l.: s.n.], 1992. p. 659–662. Citado na página 22.
- CUNHA, P. S. et al. The atrium in atrial fibrillation – a clinical review on how to manage atrial fibrotic substrates. *Frontiers in Cardiovascular Medicine*, v. 9, p. 879984, 2022. Citado na página 15.
- DHYANI, S.; KUMAR, A.; CHOUDHURY, S. Analysis of ECG-based arrhythmia detection system using machine learning. *MethodsX*, v. 10, p. 102195, 2023. Citado na página 32.
- DRAGO, F. et al. Transcatheter ablation of atrioventricular nodal reentry tachycardia in children and congenital heart disease in the era of 3d mapping. *Frontiers in Cardiovascular Medicine*, 2024. Recent review addressing pediatric ablation outcomes and technical considerations. Citado na página 21.
- ECGbook. *Electrodes and Leads*. 2024. <<https://www.ecgbook.com/electrodes-and-leads>>. Accessed: 15 Mar 2026. Citado 2 vezes nas páginas 7 e 17.
- EDENBRANDT, L.; DEVINE, B.; MACFARLANE, P. W. Neural networks for classification of ecg st–t segments. *Journal of Electrocardiology*, v. 25, p. 167–173, 1992. Citado na página 22.
- European Society of Cardiology (ESC). *Clinical practice resources — Supraventricular tachycardia*. 2019. <<https://www.escardio.org/Guidelines/Clinical-Practice-Guidelines/Supraventricular-Tachycardia>>. Accessed 2025-12-15. Citado 2 vezes nas páginas 19 e 21.
- FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. Citado 3 vezes nas páginas 36, 37 e 38.
- GERSCH, W.; EDDY, D. M.; DONG, E. J. Cardiac arrhythmia classification: a heart-beat interval–markov chain approach. *Computers in Biomedical Research*, v. 3, n. 4, p. 385–392, 1970. Citado na página 22.

- HARVEY, M. et al. Short versus long rp tachycardia — diagnostic approach. *Heart Rhythm Case Reports*, 2024. Explains RP-interval utility in differential diagnosis of SVT mechanisms. Citado na página 21.
- HEDÉN, B. et al. Acute myocardial infarction detected in the 12-lead ecg by artificial neural networks. *Circulation*, v. 96, n. 6, p. 1798–1802, 1997. Citado na página 22.
- HIGUCHI, S. et al. Identification of supraventricular tachycardia mechanisms with surface electrocardiograms using a convolutional neural network. *Heart Rhythm O2*, v. 4, n. 8, p. 491–499, 2023. Citado 2 vezes nas páginas 12 e 46.
- HJORTH, B. EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, v. 29, n. 3, p. 306–310, 1970. Citado 2 vezes nas páginas 12 e 25.
- JABBOUR, F. *Atrioventricular Re-entry Tachycardia (StatPearls)*. 2024. StatPearls [Internet]. Clinical summary including ECG features (short RP, P' buried in QRS). Citado na página 21.
- KALMADY, S. V. et al. Development and validation of machine learning algorithms based on electrocardiograms for cardiovascular diagnoses at the population level. *npj Digital Medicine*, v. 7, p. 133, 2024. Disponível em: <<https://doi.org/10.1038/s41746-024-01130-8>>. Citado 2 vezes nas páginas 22 e 26.
- KATRISSIS, D. G. et al. Atrioventricular nodal reentry tachycardia. *Circulation*, 2010. Review article (Circulation). Citado na página 19.
- KIM, J.; SHIN, H. Simple and Robust Realtime QRS Detection Algorithm Based on Spatiotemporal Characteristic of the QRS Complex. *PLoS One*, v. 11, n. 3, p. e0150144, 2016. Citado na página 29.
- KLABUNDE, R. E. *Electrocardiogram (EKG, ECG) – Ilustração do traçado eletrocardiográfico*. 2026. <<https://cvphysiology.com/arrhythmias/a009>>. Imagem acessada em: 10 Jan. 2026. Citado 2 vezes nas páginas 7 e 18.
- KLEHS, S. et al. *Leipzig Heart Center ECG-Database: Arrhythmias in Children and Patients with Congenital Heart Disease (version 1.0.0)*. [S.l.]: PhysioNet, 2025. RRID:SCR_007345. Citado 2 vezes nas páginas 14 e 27.
- KOTADIA, I. D.; WILLIAMS, S. E.; O'NEILL, M. Supraventricular tachycardia: An overview of diagnosis and management. *Clinical Medicine (London)*, v. 20, n. 1, p. 43–47, 2020. Citado na página 19.
- KUMAR, A.; SHARMA, R.; GUPTA, D. Automated electrocardiogram beat classification using wavelet-based feature extraction and support vector machines. *Biomedical Signal Processing and Control*, Elsevier, v. 85, p. 104857, 2023. Citado 2 vezes nas páginas 23 e 24.
- LEITE, J. P. R. R.; MORENO, R. L. Heartbeat Classification with Low Computational Cost Using Hjorth Parameters. *IET Signal Processing*, v. 12, n. 4, p. 431–438, 2018. Citado 2 vezes nas páginas 26 e 29.
- LI, T. et al. Cardiac conduction diseases: understanding the molecular mechanisms to uncover targets for future treatments. *Expert Opinion on Therapeutic Targets*, v. 28, n. 5, p. 385–400, may 2024. Citado na página 15.

- MICHAUD, G. F.; STEVENSON, W. G. Atrial fibrillation. *New England Journal of Medicine*, v. 384, n. 4, p. 353–361, 2021. Citado na página 19.
- MICHOWITZ, Y. et al. Familial occurrence of atrioventricular nodal reentrant tachycardia. *Heart Rhythm / Circulation: Arrhythmia and Electrophysiology (PubMed)*, 2017. Report describing prevalence 22.5 cases per 10,000. Citado 2 vezes nas páginas 20 e 21.
- NERI, L. et al. Electrocardiogram monitoring wearable devices and artificial-intelligence-enabled diagnostic capabilities: A review. *Sensors*, v. 23, n. 10, p. 4805, 2023. Citado na página 18.
- NETO, F. S. S. et al. Validation of a simple electrocardiographic algorithm for detection of ventricular tachycardia. *Arquivos Brasileiros de Cardiologia*, v. 116, n. 3, p. 454–463, 2021. Citado na página 19.
- OSE, B. et al. Artificial intelligence interpretation of the electrocardiogram: A state-of-the-art review. *Current Cardiology Reports*, v. 26, n. 6, p. 561–580, jun 2024. Citado 3 vezes nas páginas 12, 22 e 26.
- OZAKI, N. et al. Safety and Efficacy of Radiofrequency Catheter Ablation for Tachyarrhythmia in Children Weighing Less Than 10 kg. *Pediatric Cardiology*, v. 39, n. 2, p. 384–389, 2018. Citado na página 21.
- PONNUSAMY, S. S. et al. Catheter ablation of pediatric atrioventricular nodal reentrant tachycardia. *Innovations in Cardiac Rhythm Management / PMC*, 2020. Discusses pediatric prevalence and management; open-access review. Citado na página 21.
- PROBST, P.; WRIGHT, M. N.; BOULESTEIX, A.-L. Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 9, n. 3, p. e1301, 2019. Citado na página 33.
- Queensland Cardiovascular Group. *Heart Conduction System – Imagem ilustrativa do sistema de condução cardíaca*. 2026. <<https://qcg.com.au/healthy-heart/conduction-system/>>. Imagem acessada em: 10 Jan. 2026. Citado 2 vezes nas páginas 7 e 16.
- SACLOVA, L. et al. Reliable p wave detection in pathological ecg signals. *Scientific Reports*, v. 12, p. 6589, 2022. Citado na página 18.
- SATTAR, Y.; CHHABRA, L. *Electrocardiogram*. 2023. StatPearls [Internet]. Updated 2023 Jun 5. Treasure Island (FL): StatPearls Publishing. Available from: <https://www.ncbi.nlm.nih.gov/books/NBK549803/>. Citado 3 vezes nas páginas 15, 16 e 17.
- SAU, A. et al. Artificial intelligence-enabled electrocardiogram to distinguish atrioventricular re-entrant tachycardia from atrioventricular nodal re-entrant tachycardia. *Cardiovascular Digital Health Journal*, v. 4, n. 2, p. 60–67, jan 2023. Citado 3 vezes nas páginas 12, 23 e 46.
- SAUL, J. P. et al. Paces/hrs expert consensus statement on the use of catheter ablation in the pediatric population. *Heart Rhythm / Heart Rhythm Society*, 2016. Consensus statement reporting pediatric ablation success ranges and recommendations. Citado na página 21.

- scikit-learn developers. *sklearn.ensemble.RandomForestClassifier* — *scikit-learn documentation*. 2024. <<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>>. Acessado em 15 mar 2026. Citado na página 33.
- SILVA, L. A. et al. Automatic ecg beat classification using feature engineering and random forest. *Biomedical Signal Processing and Control*, v. 73, p. 103456, 2022. Citado 2 vezes nas páginas 23 e 24.
- SINGH, A. K.; KRISHNAN, S. Ecg signal feature extraction trends in methods and applications. *BioMedical Engineering OnLine*, v. 22, p. 22, 2023. Citado 2 vezes nas páginas 16 e 17.
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, v. 45, n. 4, p. 427–437, 2009. Citado 2 vezes nas páginas 36 e 37.
- STRACINA, T. et al. Golden standard or obsolete method? review of ecg applications in clinical and experimental context. *Frontiers in Physiology*, v. 13, 2022. Citado 3 vezes nas páginas 15, 16 e 18.
- STRANGIO, A. et al. Arrhythmias in pediatric age: A narrative review. *Children*, v. 12, n. 12, p. 1580, dec 2025. Citado na página 21.
- TAM, T. K. et al. Automatic algorithmic driven monitoring of atrioventricular nodal re-entrant tachycardia ablation to improve procedural safety. *Frontiers in Cardiovascular Medicine*, v. 10, p. 1212837, jul 2023. Disponível em: <<https://doi.org/10.3389/fcvm.2023.1212837>>. Citado na página 23.
- TAN, J. et al. A pediatric ecg database with disease diagnosis covering 11,643 children. *Scientific Data*, v. 12, p. 867, may 2025. Published 26 May 2025. Citado 2 vezes nas páginas 12 e 22.
- TAN, J. et al. Zzu pecg: A large-scale pediatric electrocardiogram dataset. *Scientific Data*, Nature Publishing Group, v. 12, n. 1, p. —, 2025. Disponível em: <<https://www.nature.com/articles/s41597-025-05225-z>>. Citado na página 26.
- TARANTINO, N. et al. Prevalence, outcomes, and management of ventricular arrhythmias. *Cardiac Electrophysiology Clinics*, 2022. Review article. Citado na página 19.
- VALDES, A. D. L. L. et al. Artificial intelligence in cardiology: a machine learning model for supraventricular tachycardia discrimination. *European Heart Journal*, v. 45, n. Supplement_1, p. ehae666.3472, 2024. Citado 2 vezes nas páginas 12 e 46.
- WANG, Y. et al. Electrocardiogram classification using feature engineering and lightgbm. *Biomedical Signal Processing and Control*, Elsevier, v. 85, p. 104930, 2023. Citado 2 vezes nas páginas 23 e 25.
- WU, Z.; GUO, C.; AL. et. Deep learning and electrocardiography: systematic review of current techniques in cardiovascular disease diagnosis and management. *BioMedical Engineering OnLine*, 2025. PMID: PMC11847366; systematic review cobrindo 198 artigos. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC11847366/>>. Citado na página 22.

XIE, C. et al. *Waveform Database Software Package (WFDB) for Python (version 4.1.0)*. [S.l.]: PhysioNet, 2023. RRID:SCR_007345. Citado na página [29](#).