



Universidade Federal de Pernambuco

Centro de Informática

Sistemas de Informação

**Alterações cardiovasculares na senescência: como a inteligência
artificial auxilia na identificação de padrões**

Trabalho de Conclusão de Curso de Graduação

Daniel Moraes Costa Andrade

Orientador: Profa. Maíra Araújo de Santana

Recife, Setembro de 2023

Daniel Moraes Costa Andrade

**Alterações cardiovasculares na senescência: como a inteligência artificial
auxilia na identificação de padrões**

Monografia apresentada ao Curso de
Sistemas de Informação, como requisito
parcial para a obtenção do Título de
Bacharel em Sistemas de Informação,
Universidade Federal de Pernambuco.

Orientador: Profa. Maíra Araújo de Santana

Recife

2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Andrade, Daniel Moraes Costa.

Alterações cardiovasculares na senescência: como a inteligência artificial auxilia na identificação de padrões / Daniel Moraes Costa Andrade. - Recife, 2023.

62 p. : il., tab.

Orientador(a): Maira Araujo de Santana

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Sistemas de Informação - Bacharelado, 2023.

1. Eletrocardiograma. 2. Aprendizado de máquina. 3. Alterações cardiovasculares. 4. Envelhecimento. I. Santana, Maira Araujo de . (Orientação). II. Título.

000 CDD (22.ed.)

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
CURSO DE BACHARELADO EM SISTEMAS DE INFORMAÇÃO

DANIEL MORAES COSTA ANDRADE

**ALTERAÇÕES CARDIOVASCULARES NA SENESCÊNCIA: COMO A
INTELIGÊNCIA ARTIFICIAL AUXILIA NA IDENTIFICAÇÃO DE
PADRÕES**

Monografia submetida ao corpo docente da Universidade Federal de Pernambuco,
defendida e aprovada em 19 de setembro de 2023.

Banca Examinadora:

Prof^a Dr. Giselle Machado Magalhães Moreno

Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco

Prof^o Nicolas Melo de Oliveira

Centro de Informática, Universidade Federal de Pernambuco

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão através destas palavras que têm o objetivo de refletir os sentimentos que carrego em relação a todos que contribuíram para a jornada da minha graduação e para a realização deste trabalho de conclusão de curso.

Primeiramente, quero elevar meu coração em agradecimento a Deus, a força maior que me inspirou e guiou em cada passo dessa trajetória acadêmica, sua presença constante em minha vida fortaleceu minha determinação e me deu esperança nos momentos mais desafiadores.

Minha família, pilar inabalável em minha jornada, merece uma gratidão que ultrapassa as palavras. Agradeço a eles por todo apoio, incentivo e compreensão ao longo dos anos. Minha mãe Fernanda e meu pai Junior, vocês são os alicerces do meu ser, os modelos de perseverança e caráter que sempre almejei seguir. Minha irmã Elisa, que desde a infância tem sido minha grande aliada e torcedora, sempre presente em todos os momentos importantes da minha vida. Minha namorada Camila com quem compartilho a minha vida sendo a pessoa que sempre está ao meu lado, me apoiando e me fazendo sentir especial em todas as ocasiões importantes. A minha avó Lourdes e Leni que sempre se mostram disponíveis a ajudar em qualquer situação que eu precise. Sua presença e suporte incondicionais têm sido uma grande bênção e um conforto para mim ao longo dos anos.

Na esfera acadêmica, minha gratidão se estende primeiramente à minha orientadora Maira Santana, cuja sabedoria, orientação e dedicação foram essenciais para moldar este trabalho.

Aos meus colegas de turma, Alexsandro Henrique, Gustavo Prazeres, Luis Gabriel, Vinicius Luiz e Yuri Alencar, cada um de vocês deixou uma marca em minha jornada universitária. Agradeço por cada troca de ideias, trabalho em equipe e por cada ajuda mútua em momentos desafiadores.

À equipe de professores que cruzou meu caminho, meu sincero agradecimento com suas aulas, conselhos, desafios propostos que com certeza contribuíram para minha formação acadêmica e pessoal.

Hoje, ao concluir esta etapa, reconheço que as palavras são insuficientes para traduzir toda a minha gratidão.

*Este trabalho é dedicado à minha
família, por me dar razões para
evoluir a cada dia. A dedicação e
o carinho que todos demonstram
constantemente me motivam a
alcançar meus objetivos e a nunca
desistir.*

RESUMO

A área da saúde está testemunhando um aumento significativo no uso de inteligência artificial para aprimorar diversas atividades, incluindo a interpretação de eletrocardiogramas (ECGs). Essa abordagem tecnológica tem se mostrado cada vez mais vital para agilizar a análise de ECGs, o que pode ser especialmente demorado sem a assistência da tecnologia. Com isso, surge a dificuldade de identificar com precisão alterações cardiovasculares em indivíduos saudáveis, especialmente considerando seu grupo etário, já que a maioria das pesquisas se concentra em dados cardíacos problemáticos, deixando uma lacuna na detecção de mudanças relacionadas ao envelhecimento em pessoas saudáveis. Nesse sentido, este estudo tem como objetivo central explorar o papel da inteligência artificial na detecção de alterações cardiovasculares no envelhecimento por meio da análise do ECG a fim de encontrar padrões cardíacos nas alterações cardiovasculares normais. Para isso, foi conduzido um experimento empregando algoritmos de aprendizado de máquina supervisionados, especificamente Máquinas de Vetores de Suporte e Floresta Aleatória, em uma base de dados composta por ECGs de 499 voluntários saudáveis. O experimento tinha como intuito compreender como o aprendizado de máquina pode ser útil para identificação de padrões em um ciclo de ECG associadas às alterações cardiovasculares durante o envelhecimento saudável. Os resultados do experimento indicaram dificuldade na previsão precisa do grupo etário dos idosos, com pontuações baixas de no máximo de 0.2 após a aplicação da técnica PSO para seleção de atributos. Em contraste, os resultados para o grupo de adultos consistentemente alcançaram pontuações próximas a 0.95, independentemente das configurações experimentais e das técnicas de pré-processamento empregadas. No entanto, com base nos resultados obtidos, pode-se discutir sobre a complexidade da tarefa de classificação proposta, bem como levantar potenciais abordagens futuras. Notou-se ainda a necessidade de investimento em outras técnicas e abordagens computacionais para estudo mais aprofundado das alterações cardiovasculares relacionadas ao envelhecimento natural. Pesquisas contínuas nesse sentido contribuem para o melhor entendimento do processo de envelhecimento humano como um todo.

Palavras-chave: ECG. Aprendizado de Máquina. Envelhecimento. Alterações Cardiovasculares.

ABSTRACT

The healthcare field is witnessing a significant increase in the use of artificial intelligence to enhance various activities, including the interpretation of electrocardiograms (ECGs). This technological approach has proven increasingly vital in speeding up the analysis of ECGs, which can be especially time-consuming without the assistance of technology. As a result, there is a challenge in accurately identifying cardiovascular changes in healthy individuals, taking into consideration their age group, as much of the research published today focuses on applying machine learning algorithms to datasets with problematic cardiac records, leaving a gap in the identification of age-related changes in healthy individuals. In this regard, this study aims to explore the role of artificial intelligence in detecting cardiovascular changes associated with aging through ECG analysis in order to find cardiac patterns in normal cardiovascular alterations. To achieve this, an experiment was conducted using supervised machine learning algorithms, specifically Support Vector Machines and Random Forests, on a database comprising ECGs from 499 healthy volunteers. The experiment sought to understand how machine learning can be useful in identifying patterns in an ECG cycle associated with cardiovascular changes during healthy aging. The results of the experiment indicated difficulty in accurately predicting the age group of the elderly, with scores as low as 0.2 at most after applying the PSO technique for feature selection. In contrast, results for the adult group consistently achieved scores close to 0.95, regardless of experimental settings and preprocessing techniques employed. However, based on the results obtained, it can be discussed that the proposed classification task is complex, and potential future approaches can be explored. There is also a need for investment in other computational techniques and approaches for a more in-depth study of natural age-related cardiovascular changes. Ongoing research in this direction contributes to a better understanding of the human aging process as a whole.

Keywords: ECG. Machine Learning. Aging. Cardiovascular Alteration.

LISTA DE FIGURAS

Figura 1	Fisiopatologia do envelhecimento vascular	23
Figura 2	Representação de modelo de aprendizado supervisionado	25
Figura 3	Modelo da Máquina de Vetores de Suporte (SVM)	27
Figura 4	Representação hipotética das árvore de decisão	28
Figura 5	Processo da Floresta Aleatória	28
Figura 6	Representação da matriz de confusão	30
Figura 7	Curva ROC	31
Figura 8	Diagrama da metodologia do experimento	32
Figura 9	Comparação dos eletrocardiogramas de três voluntários	43
Figura 10	Comparação da detecção de picos má sucedida e bem sucedida	44
Figura 11	Resultado da utilização da técnica correct_peaks no voluntário 326	45
Figura 12	Detecção de picos R utilizando a biblioteca heartpy	46
Figura 13	Diferença do tempo de execução	47
Figura 14	Comparativo de resultados com seleção de atributos	53
Figura 15	Comparativo de novos resultados com seleção de atributos	54

LISTA DE TABELAS

Tabela 1	Resumo dos trabalhos relacionados	20
Tabela 2	Termos usados para definir sensibilidade, especificidade e acurácia	29
Tabela 3	Intervalos da métrica AUC e suas respectivas classificações	30
Tabela 4	Resultado do modelo Floresta Aleatória sem a técnica de balanceamento .	46
Tabela 5	Comparação dos modelos com janelamento de 5s	48
Tabela 6	Comparação dos modelos com janelamento de 1s	49
Tabela 7	Comparação dos modelos sob aspecto de acurácia, roc-auc score e especificidade	49
Tabela 8	Comparação dos modelos após processo de binarização do alvo	51
Tabela 9	Modelos após binarização sob aspecto de acurácia, ROC-AUC score e especificidade	51

LISTA DE SIGLAS

UFPE	Universidade Federal de Pernambuco
IBGE	Instituto Brasileiro de Geografia e Estatística
SVM	Máquina de Vetores de Suporte
ECG	Eletrocardiograma
FDA	<i>Federal Drug Administration</i>
CNN	Rede Neural Convolucional
RNN	Rede Neural Recorrente
QRS	Ativação dos ventrículos
PTB-XL	<i>Physikalisch-Technische Bundesanstalt eXtended Lead</i>
CBAM	Módulo de Atenção a Blocos Convolucionais
IA	Inteligência Artificial
PCA	Análise de Componentes Principais
ICA	Análise de Componentes Independentes
ROC	Característica de Operação do Receptor
AUC	Área sob a curva ROC
SMOTE	Técnica de Sobre-amostragem Sintética da Classe Minoritária
PSO	Otimização por Enxame de Partículas

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Contexto	11
1.2	Motivação e justificativa	12
1.3	Objetivo da pesquisa	13
1.4	Trabalhos relacionados	14
1.5	Estrutura do trabalho	18
2	REFERENCIAL TEÓRICO	21
2.1	Etapas do processo de envelhecimento	21
2.2	Tipos de alterações cardíacas durante o envelhecimento natural/saudável	22
2.3	IA e reconhecimento de padrões	23
2.3.1	Tipos de aprendizagem	24
2.3.2	Classificadores	26
2.3.3	Métricas de avaliação	29
3	MATERIAL E MÉTODO	32
3.1	Base de dados	33
3.2	Estudo exploratório dos sinais	34
3.3	Pré-processamento de dados	34
3.3.1	Técnica de janelamento	34
3.3.2	Conversão de tipo de dados numéricos e limpeza da base de dados	35
3.3.3	Normalização de dados	35
3.4	Extração de atributos	36
3.5	Divisão dos conjuntos de treino e teste	37
3.6	Balanceamento de dados	37
3.7	Seleção de atributos	38
3.8	Modelos de classificação	39
3.9	Avaliação do modelo	40

4	RESULTADOS E DISCUSSÃO	42
4.1	Sinais de eletrocardiograma de três voluntários	42
4.2	Comparativo das técnicas de detecção do Complexo QRS e picos R	42
4.3	Tempo de execução das bases de dados após janelamento	44
4.4	Avaliação dos modelos com três rótulos de grupos de idades	45
4.4.1	Classificador Floresta Aleatória sem balanceamento	46
4.4.2	Resultados dos classificadores com balanceamento (Janelamento de 5s)	47
4.4.3	Resultados dos classificadores com balanceamento (Janelamento de 1s)	48
4.4.4	Comparação dos janelamentos com novas métricas	48
4.5	Avaliação dos modelos com dois rótulos de grupos de idades	50
4.5.1	Comparativo dos resultados de cada classificador	50
4.5.2	Diferença de resultados após aplicação da seleção de atributos	51
4.5.3	Melhor abordagem e configuração após experimentação	52
5	CONCLUSÃO E TRABALHOS FUTUROS	55
5.1	Desempenho do modelo	55
5.2	Complexidade do problema	56
5.3	Trabalhos futuros	57

1 INTRODUÇÃO

1.1 Contexto

As pessoas em nações industrializadas estão vivendo mais do que nunca, com uma significativa elevação na expectativa de vida desde o nascimento e, especialmente, após os 65 anos [1]. O Japão, os Estados Unidos e a Europa têm relatado um aumento não apenas na longevidade, mas também em uma vida mais saudável, o mesmo não acontece nos países em desenvolvimento, onde as desigualdades de riqueza, renda, educação e acesso aos cuidados de saúde têm um impacto direto na expectativa de vida. O envelhecimento da população também apresenta desafios, especialmente em relação aos cuidados de saúde e aos custos associados com mudanças na estrutura etária da população, o que resulta em efeitos profundos na sociedade, incluindo a economia, sistemas de pensões, serviços de saúde e decisões de alocação de recursos [1].

No contexto nacional, segundo o IBGE, a população brasileira continuou a envelhecer nos últimos anos, com um aumento de 4,8 milhões de idosos desde 2012, chegando a mais de 30,2 milhões em 2017 [2]. Esse crescimento de 18% no grupo de 60 anos ou mais reflete a melhoria na expectativa de vida. As mulheres representam a maioria dos idosos, com 16,9 milhões (56%), enquanto os homens são 13,3 milhões (44%). Esse envelhecimento é uma tendência global e ocorreu de maneira mais tardia no Brasil em comparação com outros lugares, e foi observado em todos os estados, sendo que o Rio de Janeiro e o Rio Grande do Sul têm as maiores proporções, com 18,6% de suas populações pertencendo a esse grupo, enquanto o Amapá tem o menor percentual, com 7,2% [2].

Nos últimos anos, o aumento significativo da aplicação da inteligência artificial na área da saúde tem se concentrado principalmente em questões relacionadas ao câncer, ao sistema nervoso, às doenças cardiovasculares e, cada vez mais, em doenças infecciosas e crônicas, devido ao elevado índice de mortalidade associado a essas condições, especialmente entre a população idosa. Esse avanço tem viabilizado diagnósticos precoces precisos, graças a algoritmos criteriosamente treinados. Exemplos que incluem programas para detectar fraturas de punho aprovado pela FDA e algoritmo que identificou tipos de câncer pulmonar com avaliação de patologistas, mostrando que o aprendizado de máquina busca algoritmos auto aperfeiçoados para responder a questões complexas da saúde humana [3].

A área da inteligência artificial aplicada à saúde experimentou um crescimento

significativo, desempenhando um papel fundamental ao auxiliar médicos em atividades como diagnóstico, escolhas terapêuticas e previsões de desfechos médicos. Esses sistemas incorporam uma variedade de abordagens, incluindo redes neurais artificiais, sistemas especialistas difusos e computação evolutiva, com o objetivo de fornecer suporte aos profissionais de saúde na gestão de dados e conhecimentos complexos. Apesar dos avanços, a adoção dessas tecnologias pela comunidade médica ainda é receosa, devido a preocupações relacionadas à confiança na tecnologia durante o processo de tomada de decisões. Contudo, fica claro que a integração da inteligência artificial pode ser de vital importância para aprimorar a qualidade da assistência médica, complementando a expertise clínica no panorama futuro da saúde [4].

1.2 Motivação e justificativa

Apesar dos notáveis avanços na saúde e nos protocolos de saúde, as doenças cardiovasculares (DCV) ainda persistem como uma das principais causas de óbito [5]. De acordo com um relatório recente da Organização Mundial da Saúde (OMS), as doenças cardíacas estão se tornando uma preocupação alarmante em indivíduos com 40 anos ou mais em todo o mundo [6].

O eletrocardiograma (ECG), ferramenta fundamental no diagnóstico de doenças cardíacas, está sendo cada vez mais combinado com tecnologias inteligentes por meio da integração, emergindo como uma solução crucial para enfrentar a escassez de recursos médicos [7]. Ao longo das últimas duas décadas, houve um significativo investimento em pesquisa no desenvolvimento de métodos capazes de classificar automaticamente os batimentos cardíacos [8]. Com isso, as técnicas de aprendizado de máquina têm desempenhado um papel vital nas ciências médicas, especialmente na análise de dados centralizados na nuvem, permitindo acesso global [6].

Ele funciona como um registro da atividade elétrica do coração na superfície do corpo, sendo comumente usado em pesquisas de detecção de estresse porque reflete diretamente a atividade cardíaca, que é influenciada por alterações no sistema nervoso autônomo. O ECG pode ser facilmente medido colocando eletrodos em locais específicos do corpo para medir diferenças de potencial [9].

Uma sessão de registro de ECG costuma durar alguns minutos, e os médicos analisam cuidadosamente as formas de onda do eletrocardiograma, batimento após batimento,

com o objetivo de diagnosticar a presença de arritmias cardíacas. Esse processo é conhecido por ser tedioso e demorado, o que torna a classificação automática dos batimentos cardíacos a partir dos sinais uma ferramenta importante na prática médica para auxiliar em diagnósticos relacionados ao sistema cardiovascular [8].

No entanto, ainda há um amplo espaço a ser explorado na análise do ECG para descobrir associações entre uma variedade de doenças relacionadas ao envelhecimento e hábitos crônicos e acredita-se que ele possa fornecer informações adicionais valiosas sobre essas condições. Atualmente, a análise automática é predominantemente focada em doenças cardíacas, como arritmia e infarto do miocárdio, com poucos estudos abordando outras áreas, como a relação entre a frequência cardíaca e o diabetes, por exemplo. No entanto, é importante continuar pesquisando e investigando o potencial do eletrocardiograma em fornecer informações abrangentes sobre várias doenças relacionadas ao envelhecimento e hábitos crônicos [10].

Nesse âmbito, a participação ativa de pessoas idosas em pesquisas sobre o envelhecimento é motivada por duas razões fundamentais. Primeiramente, trata-se de uma questão de direitos humanos, um princípio inegociável que reconhece o valor intrínseco de cada indivíduo, independentemente da idade, e em segundo lugar, a colaboração ativa desses idosos na pesquisa enriquece nossa compreensão das suas experiências e necessidades únicas, abrindo caminho para melhorias significativas na qualidade de vida dessa população. Embora haja desafios a serem enfrentados ao envolver pessoas idosas em pesquisas, os esforços empregados nesse sentido têm mostrado ser inestimáveis tanto para os próprios idosos quanto para o avanço da pesquisa sobre o envelhecimento [11].

1.3 Objetivo da pesquisa

Este trabalho pretende responder as seguintes perguntas de pesquisa:

- Q1 - Quais são as principais alterações cardiovasculares no processo de envelhecimento do ser humano?
- Q2 - Quais são os principais algoritmos de inteligência artificial utilizados na análise do ECG para identificar alterações cardiovasculares em idosos?
- Q3 - Quais as principais técnicas utilizadas para identificar um ciclo de ECG?

- Q4 - Com um eletrocardiograma é possível identificar alterações esperadas na pessoa devido ao fator da idade?

Para responder essas perguntas de pesquisa, o objetivo principal deste trabalho é compreender como o aprendizado de máquina pode ser útil para identificação de padrões em um ciclo de ECG associadas à alterações cardiovasculares durante o envelhecimento saudável. Para que seja possível atingir esse objetivo geral, os seguintes objetivos específicos foram estabelecidos:

- Identificar as prováveis alterações cardiovasculares que são desenvolvidas no processo de envelhecimento do ser humano.
- Entender os princípios básicos do exame de eletrocardiograma, incluindo sua representação gráfica.
- Explorar técnicas de processamento de sinais e análise de dados especificamente voltada para eletrocardiograma.
- Analisar a aplicação de modelos de aprendizagem de máquina envolvendo eletrocardiogramas.

1.4 Trabalhos relacionados

Xu, Mak e Cheung (2019) [8] apresentaram um método de aprendizado profundo com alinhamento de sinal para classificação de ECGs brutos em diferentes tipos de batimentos cardíacos. Os resultados mostram que o classificador proposto obtém uma sensibilidade pelo menos 10% maior na detecção de batimentos irregulares. A segmentação dos batimentos cardíacos através de um algoritmo baseado em limiar e o alinhamento dos batimentos é considerado vital para o desempenho da rede neural profunda. Essa abordagem *end-to-end* de classificação de ECG busca reduzir o tempo e esforço necessários, e com isso, conseguiu alcançar um desempenho superior em relação a outras abordagens existentes para a classificação de arritmias cardíacas.

O artigo de Xu et al. (2020) [12] propõe uma rede combinada de CNN e RNN para a classificação de sinais de ECG. A rede consiste em camadas convolucionais, blocos residuais com uma *Rede Squeeze-and-Excitation* (SENet), camadas bidirecionais de memória de longo prazo (biLSTM) e camadas totalmente conectadas. A combinação da CNN e

BiLSTM mostrou um desempenho superior na classificação de batimentos cardíacos em comparação com outros modelos existentes. Foram também utilizadas técnicas de processamento dos sinais de ECG como remoção de desvio da linha de base, *downsampling*, normalização, detecção de picos R e episódios T, extração de batimentos e preenchimento com zeros para padronização. A rede alcançou alta sensibilidade de reconhecimento e precisão na detecção de cinco classes de ECG. No entanto, o escopo do estudo se limitou à arritmia, sugerindo a necessidade de expandir a rede para incluir mais tipos de dados de ECG para lidar com a diversidade de doenças cardíacas.

Na pesquisa de Lee et al. (2023) [13] é proposto um sistema de medição de eletrocardiograma implementado no volante do veículo, juntamente com um modelo de aprendizado de máquina para classificar o estado de saúde cardíaca do motorista. Para isso, é proposta uma estrutura de aprendizado de máquina em dois estágios, treinada com um subconjunto ótimo de características extraídas de dados de ECG de uma única derivação. A estrutura de classificação em dois estágios alcançou a melhor pontuação F1 e um desempenho de classificação em tempo real. O estudo se concentra em extrair recursos com base nas ondas do ECG e localizar corretamente os pontos de pico P, Q, R, S e T. Além disso, são realizados processos de remoção de ruído e filtragem do sinal EMG e extração de características morfológicas e estatísticas usando os pontos de pico. O estudo destaca que a análise do pico R do ECG pode fornecer informações importantes, como alterações na frequência cardíaca.

Strodthoff et al. (2021) [14] realizaram testes com diferentes arquiteturas, como redes neurais convolucionais e recorrentes, e descobriram que as redes convolucionais baseadas nas arquiteturas ResNet e Inception apresentaram o melhor desempenho em todas as tarefas. Além disso, eles demonstraram a utilidade da aprendizagem por transferência, utilizando o PTB-XL como um recurso de pré-treinamento para classificadores genéricos de ECG. Os resultados mostraram que os algoritmos baseados em aprendizado profundo superaram outros métodos de classificação em termos de acurácia, sensibilidade e especificidade.

Zarei et al. (2019) [15] apresentam um novo método automático de detecção de apneia obstrutiva do sono (AOS) usando sinais de eletrocardiograma (ECG) de derivação única. O método proposto envolve a extração de características não lineares usando coeficientes de transformação wavelet obtidos por uma decomposição do sinal de ECG. Um

algoritmo de seleção de recursos é aplicado para escolher os melhores recursos. Diferentes classificadores, como Máquinas de Vetores de Suporte (SVM), Rede Neural Artificial (ANN) e Regressão Logística (LR), são investigados para a classificação dos eventos de apneia.

No artigo de Tseng et al. (2020) [10] é mostrada a análise das possíveis relações entre doenças comuns do envelhecimento e hábitos crônicos com registros médicos e ECG, como diabetes, obesidade, hipertensão e o hábito de fumar. Diversos métodos de pré-processamento e extração de recursos são utilizados, incluindo o padrão binário reduzido (RBP), transformação *wavelet*, análise de forma de onda, redução de ruído e detecção de pontos característicos. O algoritmo de agrupamento *K-Means* é aplicado para identificar associações entre ECGs e as doenças e hábitos mencionados. No final, a relação entre ECG e hipertensão, obesidade e tabagismo não é clara, abrindo caminho para pesquisas futuras nessa área.

O artigo de Butt et al. (2021) [16] apresenta um algoritmo de classificação de ECG baseado no uso de redes neurais convolucionais pré-treinadas (AlexNet e GoogLeNet) para distinguir entre quedas e atividades sem queda. São realizadas técnicas como: aplicação de um filtro elíptico para remover ruídos, como desvio da linha de base e interface de linha de energia, e, foram obtidos escalogramas dos sinais de ECG filtrados usando transformação *wavelet* contínua, que foram então utilizados como entrada para a rede neural. O primeiro modelo alcançou uma precisão de validação de 98,08% na classificação de quedas versus sem queda, enquanto o segundo modelo atingiu uma precisão de 98,44% na classificação de quedas, atividades diárias e nenhuma atividade.

A pesquisa de Wang et al. (2022) [7] aborda um método que utiliza dados de ECG de três derivações cardíacas (THML) e quatro modelos de classificação baseados em redes neurais convolucionais unidimensionais (1D-CNN), combinados com um método de votação integrado de modelo prioritário. O pré-processamento dos dados envolve a segmentação precisa dos sinais de ECG, seguida de reamostragem, filtragem de ruído *wavelet* e normalização de média zero. Por fim, os resultados mostram alta precisão na classificação de diferentes tipos de arritmias, evidenciando a eficácia do método proposto.

Jiao et al. (2022) [17] apresentam um modelo que combina as vantagens das redes neurais convolucionais 1D (CNN) e das redes de memória de longo prazo (LSTM) para extrair recursos espaciais e temporais dos sinais de ECG. O pré-processamento inclui

remoção de ruído usando *wavelets Daubechies* e segmentação adaptativa dos batimentos com base na forma de onda QRS. O trabalho destaca a capacidade de generalização do modelo, eliminando a necessidade de extração manual de recursos e permitindo a classificação direta do sinal de ECG.

Manik et al. (2019) [18] apresentam um algoritmo de classificação de taquiarritmias ventriculares. O processo de classificação envolveu pré-processamento usando o filtro mediano para remover o ruído e preservar as informações importantes do sinal de ECG. A extração de características foi realizada usando a técnica de Análise de Componentes Principais (PCA), que reduziu o número de amostras e detectou as características da onda QRS, essenciais para a detecção de doenças cardíacas. O algoritmo de classificação utilizado foi o *Backpropagation* modificado (MBP), uma rede neural com retropropagação de Levenberg Marquardt. O estudo obteve um alto grau de acerto de 91,67% na classificação das taquicardia ventricular, demonstrando a eficácia da abordagem proposta.

Rahman et al. (2022) [6] desenvolvem um algoritmo de classificação de ECG baseado em aprendizado de transferência usando três diferentes modelos de aprendizado profundo: *ResNet50*, *AlexNet* e *SqueezeNet*. O objetivo é detectar arritmias cardíacas com alta precisão. O estudo comparou os resultados dos três modelos e obteve uma precisão de 98.8%, 90.08% e 91% respectivamente. Aumentar o conjunto de dados e ajustar os parâmetros e posicionamento das imagens contribuiu para o progresso nessa área, que mostrou-se inovadora e eficaz na detecção e diagnóstico de arritmias multiclasse.

A pesquisa de Zheng et al. (2020) [19] mostra um algoritmo de classificação de ECG para detectar arritmias cardíacas que consiste em um estágio de redução de ruído em três etapas, um método de extração de recursos e um modelo de classificação otimizado. O estudo exaustivo comparou diversos algoritmos de classificação, sendo o *Extreme Gradient Boosting Tree* (EGBT) e *Gradient Boosting Tree* (GBT) os melhores desempenhos. Além de definir etapas de pré-processamento que envolveram a redução de ruído usando filtros *Butterworth Low-pass*, *Robust LOESS* e *Non Local Means*. A extração de recursos incluiu medições de ondas e segmentos, bem como medidas de relação entre picos e vales. A abordagem mostrou-se eficaz na detecção de arritmias com um *F1-Score* de 0.988 em pacientes sem condições cardíacas adicionais.

O artigo de Arquilla et al. (2022) [20] aborda um algoritmo de classificação de estresse usando sinais de eletrocardiograma (ECG). O estudo investigou a inclusão de

recursos derivados de picos menores (ondas P, Q, S e T) na forma de onda do ECG, além do pico R tradicionalmente utilizado. O objetivo era determinar se esses recursos adicionais melhoram a classificação do estresse e investigar os efeitos do ruído na detecção automática de pico. Os pesquisadores realizaram uma análise comparativa entre dois modelos, um com recursos de pico R e outro com recursos de picos menores. Ambos os modelos apresentaram resultados semelhantes em métricas como precisão, sensibilidade, F1, área sob a curva ROC (AUC) e precisão. Os resultados sugerem que os picos menores podem ser indicativos de processos independentes dentro do coração, refletindo uma resposta psicofisiológica ao estresse.

Chen et al. (2021) [21] mostram um sistema de diagnóstico automático baseado em aprendizado profundo para a detecção precoce de insuficiência cardíaca por meio de sinais de ECG. O modelo proposto, chamado CBAM-CNN, utiliza uma rede neural convolucional de atenção para extrair automaticamente características dos sinais de ECG e realizar a classificação. Os resultados mostram que o modelo CBAM-CNN é eficaz na classificação dos sinais de ECG, sendo sensível ao ruído e tendo sua precisão aprimorada após o refinamento do sinal. Esse sistema de diagnóstico auxiliado por computador pode ser útil para médicos e paramédicos no diagnóstico precoce da insuficiência cardíaca, e há potencial para expandir seu uso em outros problemas relacionados ao coração.

A pesquisa de Jurado et al. (2022) [5] apresenta uma metodologia para detectar o desvio do segmento ST em sinais de ECG e quantificar sua escala usando métodos automatizados de aprendizado de máquina que teve como pré-processamento dos sinais de ECG a remoção do desvio da linha de base. Características estatísticas e índices de qualidade de sinal foram extraídos dos batimentos separados. Os resultados mostraram uma precisão de 99,87% na detecção do desvio do segmento ST quando o problema foi binarizado e 98,30% quando consideradas três classes.

1.5 Estrutura do trabalho

Este documento está estruturado da seguinte forma:

- Capítulo 1 - Introdução;
- Capítulo 2 - Referencial Teórico;
- Capítulo 3 - Metodologia;

- Capítulo 4 - Resultados;
- Capítulo 5 - Conclusões;

Tabela 1: Resumo dos trabalhos relacionados

Autores	Base de dados	Técnicas de pré-processamento	Classificadores utilizados	Tema
Xu, Mak e Cheung (2019)	MIT-BIH	Segmentação, Alinhamento, Detecção do pico R	DNN	Classificação de ECG
Xu et al. (2020)	MIT-BIH	<i>Down-sampling</i> , Normalização, detecção do pico R e episódio T, <i>Beat Extraction</i> , <i>Zero padding</i>	CNN e RNN (BiLSTM)	Classificação de ECG
Lee et al. (2023)	PhysioNet Computing in Cardiology Challenge 2017	Detecção do pico R, Remoção de ruído, transformação de Fourier e extração de características morfológicas	Naives Bayes e SVM	Sistema de medição de ECG para implementação de veículos
Strothoff et al. (2021)	PTB-XL	Seleção de atributos and wavelet	N/A	ECG Benchmarking
Zarei et al. (2019)	Physionet Apnea-ECG, UCD Database	Segmentação, transformação wavelet, Extração de atributos, Seleção de atributos	SVM	Classificação de ECG (Obstructive sleep apnea)
Tseng et al. (2020)	PTB Diagnostic ECG Database	RBP, Transformação wavelet, análise de formas de onda, remoção de ruídos (Fourier, DCT), detecção do complexo QRS, <i>High and low pass filters</i>	K-Means	Análise de Agrupamento de Doenças do Envelhecimento e Hábitos Crônicos
Butt et al. (2021)	Base de dados autoral	Transformação wavelet, filtragem (filtro elíptico), conversão analógica para digital, criação de escalogramas, remoção de ruídos	AlexNet e GoogLeNet	Detecção de queda
Wang et al. (2022)	MIT-BIH	Corte de dados, rotulagem de dados, reamostragem, filtragem do sinal, normalização, remoção de ruídos (Wavelet)	1D-CNN	Classificação de Arritmia
Jiao et al. (2022)	MIT-BIH	Remoção de ruídos, Segmentação, <i>Standardized Label</i>	CNN e LSTM	Classificação de ECG
Manik el al. (2019)	CU Ventricular Tachyarrhythmia Database, MIT-BIH	Remoção de ruídos, PCA, detecção do complexo QRS	MBP	Classificação de ECG
Rahman et al. (2022)	MIT-BIH	N/A	ResNet50, AlexNet e SqueezeNet	Classificação de ECG
Zheng et al. (2020)	Base de dados autoral	Remoção de ruídos, Transformação Fast Fourier, Feature Extraction (magnitudes de pico, duração, distâncias entre picos e sua variabilidade em P, Q, T e complexo QRS)	DT, KNN, NC, GNB, MNB, CNB, BNB, LC, QDA, MLR, MPN, RRC, LCGSD, PAC, SVC, RF, ERT, GBT, EGBT	Classificação de Arritmia
Arquilla et al. (2022)	National Institutes of Health Database (Physionet)	Redução de ruído de sinal, Extração de atributos, detecção de pico	TFM, NFM	Estudo de ECG (Estresse)
Chen et al. (2021)	Physio-Bank e MIMIC-III	Segmentação	CBAM-CNN	Detecção de insuficiência cardíaca
Jurado et al. (2022)	ST-T Database	Extração de atributos, Seleção de atributos, detecção de pico, redução de ruído (<i>Butterworth</i> passa-alto)	AutoML	Interpretação de segmentos
Trabalho proposto	Autonomic Aging	Extração de atributos, Seleção de atributos, Detecção do Complexo QRS, Normalização, Balanceamento	Random Forest e SVM	Identificação de padrões em alterações cardiovasculares em idosos saudáveis

Fonte: Elaborado pelo próprio autor (2023)

2 REFERENCIAL TEÓRICO

Neste capítulo, serão abordados os principais conceitos sobre os principais temas presentes neste trabalho. A Seção 2.1 apresenta as etapas no processo de envelhecimento. Na Seção 2.2 são descritos quais tipos de alterações cardíacas acontecem durante o envelhecimento natural e saudável do ser humano. E, por fim, a Seção 2.3 apresenta conceitos sobre inteligência artificial e reconhecimento de padrões, trazendo elementos acerca dos tipos de aprendizagem de máquina, classificadores e métricas de avaliação, respetivamente.

2.1 Etapas do processo de envelhecimento

Segundo Erminda (1999) [22], o envelhecimento se configura como um processo de diminuição orgânica e funcional, não decorrente de doença, acontecendo inevitavelmente com o passar do tempo. Esse processo pode ser considerado um fenômeno biológico complexo envolvendo mudanças bioquímicas e morfológicas, com perda progressiva de diferentes funções fisiológicas na célula, tecido, órgão e no organismo como um todo.

A idade cronológica, que quantifica a passagem do tempo decorrido em dias, meses e anos desde o nascimento, é um dos meios mais usuais e simples de se obter informações sobre uma pessoa. A idade biológica é definida pelas alterações corporais e mentais que ocorrem ao longo do processo de desenvolvimento e caracterizam o processo de envelhecimento humano [23].

Com isso, o envelhecimento é um processo natural, a chamada senescência, que ocorre ao longo da vida. Desde o nascimento, passamos por mudanças fisiológicas e visuais que nos levam à maturidade. Mesmo aqueles que são saudáveis e esteticamente aptos experimentam o declínio gradual das funções físicas e a incapacidade funcional, o que pode resultar em maior dependência na velhice. Em muitos países desenvolvidos, a idade de 60 anos é considerada o início da velhice e a idade de aposentadoria, mas essas construções culturais variam de acordo com as diferentes sociedades e culturas ao redor do mundo [24].

Ademais, com o envelhecimento natural do corpo humano pode ocorrer um conjunto de processos patológicos associados à idade, chamada de senilidade. É comum que observações simultâneas de senescência ou senilidade sejam consideradas coincidência, mas a necessidade de diferenciá-las levou à criação de diretrizes para decisões clínicas, como

diagnóstico, tratamento e acompanhamentos específicos [25]. Além disso, na senilidade as manifestações patológicas são protagonistas e de forma gradual ocasionam um declínio no funcionamento dos sistemas corporais, o que pode resultar em óbito. Quando a senilidade se manifesta, é importante que os idosos recebam cuidados adequados e apoio emocional para lidar com suas limitações físicas e cognitivas [26].

2.2 Tipos de alterações cardíacas durante o envelhecimento natural/saudável

As mudanças na anatomia e fisiologia cardiovascular que ocorrem com o envelhecimento são responsáveis pelas alterações na função cardiovascular que são características [27]. De acordo com Cefalu (2011) [28], as mudanças comuns que ocorrem no sistema cardiovascular durante o envelhecimento podem ser observadas tanto em nível estrutural quanto funcional. Os miócitos sofrem uma hipertrofia progressiva e há uma perda gradual de 90% das células marca-passo no nódulo sinusal, o que resulta em um ritmo cardíaco mais lento em repouso e durante atividades físicas. A rigidez do ventrículo esquerdo atinge seu máximo quando há uma redução na complacência. Nesses casos, o coração responde à diminuição da frequência cardíaca máxima e ao aumento do volume sistólico com uma diminuição do débito cardíaco máximo e uma resposta vasodilatadora durante o exercício.


Nesta mesma ideia, Stratton et al. (2003) [29] mostra que com o envelhecimento ocorre uma redução no enchimento diastólico do ventrículo esquerdo e em seu relaxamento, que é compensada pela contração do átrio esquerdo. Esse quadro se deve, em parte, à calcificação das paredes dos vasos, aumento do diâmetro, perda de complacência causada pela deposição de colágeno e fragmentação da elastina no sistema vascular central e periférico, levando a um aumento da resistência vascular sistêmica.

Por outro lado, estudos realizados em modelos animais e em seres humanos têm demonstrado que o envelhecimento e seus efeitos estão associados a três alterações cardiovasculares: disfunção diastólica, aumento da rigidez arterial, conforme mostrado na Figura 1, e redução da resposta cronotrópica e inotrópica às catecolaminas. A disfunção diastólica ocorre devido ao prolongamento do relaxamento miocárdico e à dificuldade no enchimento diastólico ventricular. O aumento da rigidez arterial resulta em maior pós-carga. Já a redução da resposta cronotrópica e inotrópica às catecolaminas se deve à diminuição da responsividade β adrenérgica. Essas alterações podem ter implicações

na saúde cardiovascular de indivíduos idosos e, por isso, é importante considerá-las na avaliação e tratamento desses pacientes [30].

Ainda no contexto da rigidez arterial, ocorre a diminuição da elasticidade da aorta e das grandes artérias, medida como diminuição da complacência aórtica. À medida que a aorta se torna menos complacente, há aumento da resistência à ejeção de sangue do ventrículo esquerdo. Isso pode levar a uma série de consequências, como um aumento da pressão arterial, maior estresse no coração e no sistema circulatório, e um maior risco de doenças cardiovasculares, como doenças coronárias, acidente vascular cerebral e insuficiência cardíaca. Outra alteração é fibrose e calcificação do fibroesqueleto do coração, composto pelos anéis anulares e trígonos fibrosos, juntamente com calcificação das bases das cúspides aórticas, podendo levar a um aumento da rigidez das valvas cardíacas e a um mau funcionamento das mesmas, que podem dificultar o fluxo sanguíneo adequado [27].

Figura 1: Fisiopatologia do envelhecimento vascular



Fonte: Adaptado de Costantino, Paneni e Cosentino (2016)

2.3 IA e reconhecimento de padrões

A inteligência artificial (IA) pode ser vista tanto como parte da engenharia quanto como parte da ciência, dependendo dos objetivos. No contexto da engenharia da inte-

ligência artificial, busca-se resolver problemas do mundo real utilizando a IA como um conjunto de ideias para representar o conhecimento e construir sistemas. Por outro lado, no contexto científico da inteligência artificial, o objetivo é determinar quais ideias, sistemas e representações do conhecimento explicam diferentes formas de inteligência. A IA consegue ajudar especialistas a resolver problemas analíticos avançados e complexos [31]. A medicina moderna possui grandes quantidades de informações e conhecimentos precisos da inteligência artificial como solução do desafio de análise e aplicação, tendo sido relacionado à previsão de resultados [32].

O reconhecimento de padrões é o estudo de como os computadores e algoritmos podem observar o ambiente, aprender a distinguir padrões de interesse de seu contexto e tomar decisões sensatas e razoáveis sobre as categorias dos padrões [33]. Ainda nesta mesma ideia, Schrouff et al. (2013) [34] relata que reconhecimento de padrões estatísticos é um campo dentro da área de aprendizado de máquina, que se preocupa com a descoberta automática de regularidades em dados por meio do uso de algoritmos de computador e com o uso dessas regularidades para realizar ações como classificar os dados em diferentes categorias.


2.3.1 Tipos de aprendizagem

Com base no problema dado e nos dados disponíveis, podemos distinguir três tipos de aprendizado de máquina: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço [35].

No contexto do aprendizado supervisionado, um sistema computacional é fornecido com conjuntos de dados de treinamento contendo observações e os valores correspondentes de saída conhecidos. O objetivo é adquirir conhecimento sobre regras gerais, também chamadas de “modelo”, que estabelecem uma relação entre as entradas e as saídas. Esse conhecimento permite que o sistema faça previsões sobre as saídas de novos dados que não foram previamente observados, mas em que temos os valores de entrada disponíveis. Existem duas categorias principais de aprendizado supervisionado: a classificação, mostrado na figura 2, que lida com valores de saída categóricos, e a regressão, que lida com valores de saída numéricos [36]. A classificação é um método para atribuir um rótulo a uma amostra com base nos atributos, para isso é necessário que tenha rótulos para realizar a classificação. A regressão é semelhante à classificação, mas a diferença é que ela não

prevê um rótulo, mas sim tentar prever um valor contínuo, ou seja, caso o objetivo de um determinado trabalho seja prever um número é necessário usar algum algoritmo de regressão e não de classificação [37].

Figura 2: Representação de modelo de aprendizado supervisionado



Fonte: Adaptado de Gupta et al (2022)

O aprendizado não supervisionado é uma abordagem de aprendizado de máquina em que não há supervisão durante o processo. Os dados de entrada, que consistem em padrões ou imagens não rotulados, são processados pelo modelo para identificar padrões ocultos. Diferentes algoritmos, como PCA, ICA e *K-Means*, são utilizados para descobrir estruturas nos dados fornecidos. Ao contrário do aprendizado supervisionado, não há dados de saída predefinidos, tornando o formato da saída desconhecido. Essa abordagem é útil para explorar grandes conjuntos de dados e encontrar padrões significativos. O aprendizado não supervisionado desempenha um papel importante na descoberta de conhecimento em dados não rotulados [38]. Os tipos mais comuns de algoritmos usados no aprendizado não supervisionado são os modelos de *Clustering*, técnica com o objetivo principal de agrupar itens de forma que aqueles com mais semelhanças sejam agrupados e aqueles com pouca ou nenhuma semelhança sejam colocados juntos, e *Association*, que diferente do *clustering* é usada para encontrar correlações entre variáveis em um grande banco de dados [39].

O último tipo de aprendizado de máquina é o de *reinforcement learning*, e de acordo com Bonaccorso (2017) [40] o aprendizado por reforço é uma abordagem na qual um agente aprende a tomar decisões em um ambiente interativo. O agente recebe um retorno

qualitativo, chamado recompensa, do ambiente após tomar ações em estados específicos. O objetivo é aprender uma política, que é uma sequência de ações que maximizam a recompensa imediata e acumulativa. Mesmo que o agente cometa ações imperfeitas, a política global deve resultar na maior recompensa total. O aprendizado por reforço é eficaz em ambientes dinâmicos, estocásticos e nos quais não é possível ter uma medida precisa de erro.

2.3.2 Classificadores


A Máquina de Vetores de Suporte (do inglês, *Support Vector Machine - SVM*) é um modelo de aprendizado de máquina supervisionado, que envolve a construção de um hiperplano que separa os dados de diferentes classes de forma otimizada. O objetivo é encontrar o hiperplano que maximize a margem entre as classes, ou seja, a distância entre os pontos mais próximos de cada classe. Esses pontos mais próximos são chamados de vetores de suporte, daí o nome do modelo. A técnica combina três conceitos: a solução de *optimal hyperplanes* (que permite expandir a solução em vetores de suporte), *convolution of the dot-product* (que estende as superfícies de solução de linear para não linear) e *notion of soft margin* (que permite erros no conjunto de treinamento). A questão da construção do hiperplano foi resolvida em 1965, assim um hiperplano ótimo foi definido como a função de decisão linear com margem máxima entre os vetores das duas classes. Esse algoritmo foi testado e comparado com outros algoritmos clássicos na época, revelando um desempenho muito bom durante o estudo de comparação, apesar de sua aparente simplicidade na superfície de decisão [41].

A figura 3 mostra visualmente como é feita a separação de dados através de um hiperplano maximizado pela margem ótimo entre as classes.

Uma árvore de decisão tem diversos nós, cada nó interno da árvore contém um teste que é usado para decidir qual ramo seguir a partir desse nó. Os nós folha contém rótulos de classe e quando um caso de teste alcança um nó folha o algoritmo faz a devida classificação. As árvores que são desenvolvidas pelo C4.5, um algoritmo amplamente utilizado desenvolvido por J. Ross Quinlan, são rápidas e confiáveis, devido ao fato de possuir propriedades que tornaram a árvore de decisão uma ferramenta segura para classificação em aprendizado de máquina [42].

A Floresta Aleatória é um método de aprendizado de máquina que combina várias

Figura 3: Modelo da Máquina de Vetores de Suporte (SVM)

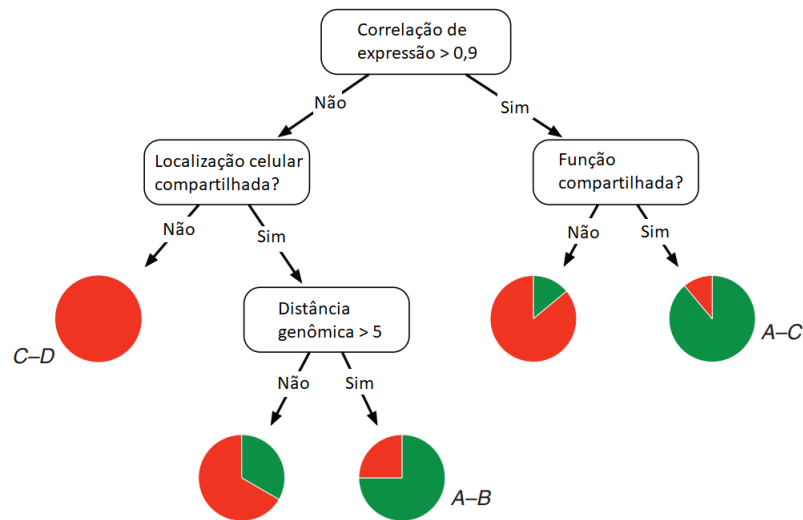


Fonte: Adaptado de Cortes, Paneni e Vapnik (1995)

árvores de decisão independentes para realizar classificação ou regressão. Cada árvore é treinada em uma amostra aleatória dos dados de treinamento e, em seguida, as árvores votam para determinar a classe mais popular ou a média das previsões das árvores é tomada como resultado final [43]. Ela usa a técnica de *bagging* para corrigir a tendência das árvores de decisão ao *overfitting*. Tem sido uma excelente alternativa para classificação e regressão mesmo tendo cedido espaço para *Gradient Boost*, que utiliza a técnica de *boosting*, onde cada árvore é criada com o intuito de corrigir os erros da anterior [37]. Esse algoritmo é apropriado para situações na qual a base dados possui uma alta dimensionalidade, devido a facilidade de trabalhar com valores nulos, categóricos, numéricos e binários, o que acaba sendo eficiente para vários tipos de conjuntos de dados [44]. Ele geralmente possui uma performance significativa em comparação a modelos de uma árvore só, como é o caso do C4.5 [45].

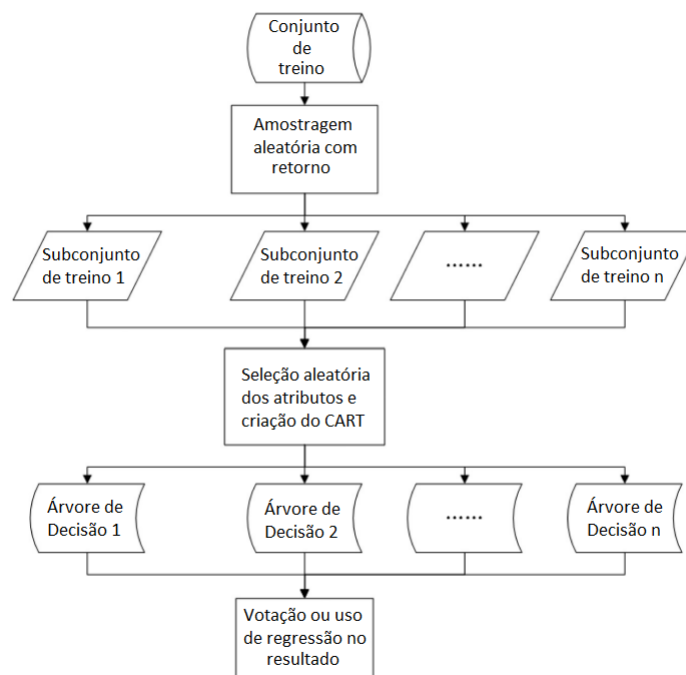
A figura 4 mostra a representação hipotética de uma árvore de decisão e a figura 5 as etapas do processo de decisão da Floresta Aleatória.

Figura 4: Representação hipotética das árvore de decisão



Fonte: Adaptado de Carl e Salzberg (2008)

Figura 5: Processo da Floresta Aleatória



Fonte: Adaptado de Sun et al (2020)

2.3.3 Métricas de avaliação

Acurácia, sensibilidade e especificidade são três medidas básicas para validar uma performance de um classificador [46]. A acurácia é calculada pela divisão dos verdadeiros positivos pela soma total dos resultados positivos, com isso ele mede o quão relevante são os resultados [37]. Ela mede a capacidade de identificar corretamente todas as amostras, não só positivas como também negativas. Sensibilidade, é conhecida por *recall* ou TPR (taxa de verdadeiros positivos), pois mede a frequência de amostras positivas verdadeiras em comparação com todas as amostras tidas como positivas. Já a especificidade, conhecida como *inverse recall* ou TNR (taxa de verdadeiros negativos), é o contrário da sensibilidade, mede a capacidade de identificar as amostras negativas [46].

Tabela 2: Termos usados para definir sensibilidade, especificidade e acurácia

Resultado do diagnóstico	Condição (doença) Conforme determinado pelo Padrão da Verdade		
	Positivo	Negativo	Total linhas
Positivo	TP	FP	TP+FP (Número total de pessoas com teste positivo)
Negativo	FN	TN	FN + TN (Número total de pessoas com teste negativo)
Total colunas	TP+FN (Total de pessoas com determinada condição)	FP+TN (Total de pessoas sem determinada condição)	N = TP+TN+FP+FN (Número total de pessoas no estudo)

Fonte: Adaptado de Zu, Zheng e Wang (2010)

Um dos principais objetivos de uma matriz de confusão é entender o desempenho atual de um classificador ao realizar alguma tarefa de previsão. No caso de um classificador binário pode ter quatro resultados, são eles: verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN) [37]. Ela apresenta informações sobre a frequência de detecção correta de um comportamento e com que frequência é classificado com outro tipo. Essa análise funciona como uma alternativa à validação de classificação discreta, tendo vantagens como: robustez no quesito de distribuição de dados, avaliação rigorosa da validade e mostra informações valiosas sobre os erros [47].

Mandrekar (2010) [48] define a curva ROC como simples “plotagem” de sensibilidade x especificidade. A curva ROC ilustra a variação da taxa de verdadeiros positivos

Figura 6: Representação da matriz de confusão

		Previsão		
		Positivos	Negativos	
Real	Positivos	TP	FN	$RP = TP + FN$
	Negativos	FP	TN	
		$PP = TP + FP$ $PN = TN + FN$		$RN = FP + TN$

Fonte: Adaptado de Jiao e Du (2016)

em relação à taxa de falsos positivos ao longo do tempo, fornecendo uma representação visual do desempenho do classificador. Uma regra prática estabelece que o gráfico deve se projetar no canto superior esquerdo para indicar um melhor desempenho. Quando um gráfico está localizado à esquerda e acima de outro, isso indica uma melhoria no desempenho. A diagonal no gráfico representa o comportamento de um classificador que faz adivinhações aleatórias. O cálculo da AUC (área sob a curva) fornece uma métrica para avaliar o desempenho do classificador [37]. Segundo [49] este cálculo funciona como um teste para discriminar se uma certa condição está presente ou não. Uma AUC próximo a 1.0 representa uma discriminação perfeita, sendo uma métrica diretamente proporcional, fazendo com que um resultado de 0.5 já representa um teste sem capacidade discriminação, não sendo recomendada.

Tabela 3: Intervalos da métrica AUC e suas respectivas classificações

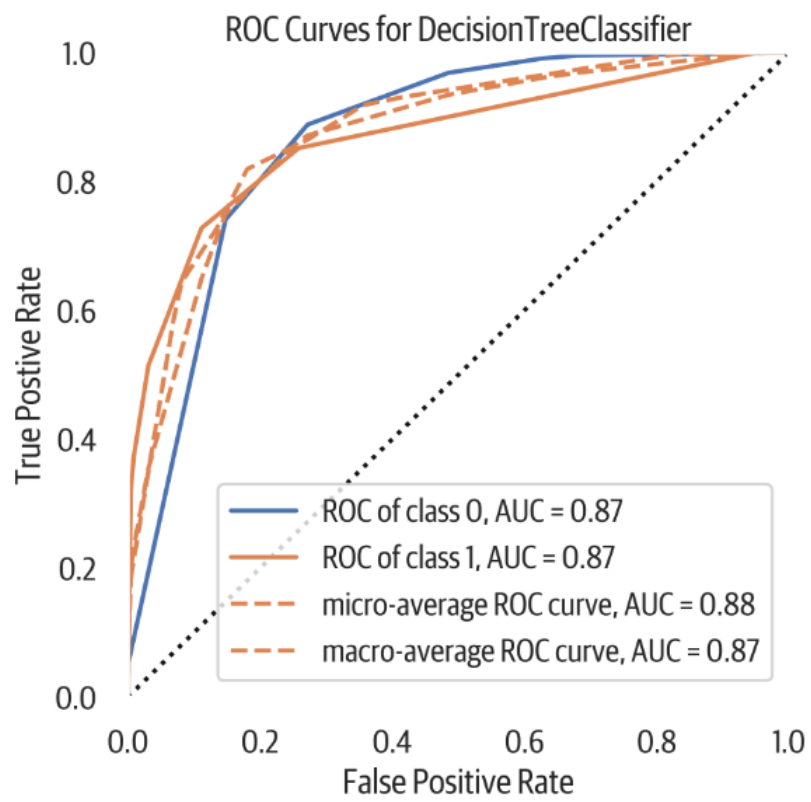
Intervalo AUC	Classificação
$0.9 < AUC < 1.0$	Excelente
$0.8 < AUC < 0.9$	Bom
$0.7 < AUC < 0.8$	Impróprio
$0.6 < AUC < 0.7$	Ruim

Fonte: Adaptado de Zu, Zheng e Wang (2010)

A figura abaixo ilustra um exemplo da curva ROC em um classificador de Árvore de

Decisão, contendo duas classes (0 e 1) e o resultado da métrica AUC de forma individual.

Figura 7: Curva ROC

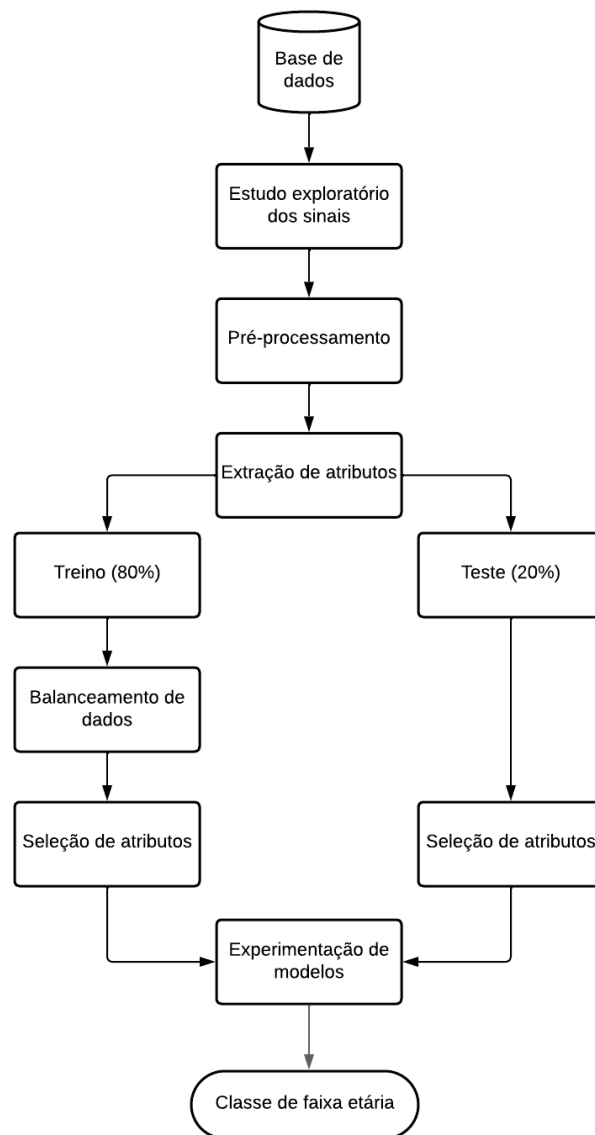


Fonte: Harrison (2019)

3 MATERIAL E MÉTODO

Nesta seção, encontra-se o delineamento dos passos realizados na busca por respostas em direção aos objetivos estabelecidos neste trabalho, como mostrado na figura 8. A metodologia, através da experimentação envolveu entendimento da base de dados, estudo exploratório dos sinais, pré-processamento dos dados para garantir a qualidade e consistência das informações, o desenvolvimento do classificador e por fim validação dos modelos através de métricas, por exemplo acurácia, precisão e sensibilidade.

Figura 8: Diagrama da metodologia do experimento



Fonte: Elaborado pelo próprio autor (2023)

3.1 Base de dados

A base de dados, Autonomic Aging PhysioNet, utilizada no experimento, teve seus dados coletados no Departamento de Medicina Psicossomática e Psicoterapia do Hospital Universitário de Jena. O estudo recebeu aprovação ética da Faculdade de Medicina da Friedrich Schiller University Jena, e todos os participantes forneceram consentimento por escrito pela participação na base de dados disponibilizando os próprios batimentos cardíacos.

O conjunto de dados compreende registros de eletrocardiogramas na derivação II, amostrados a 1000 Hz, usando um sistema MP150 da BIOPAC e um sistema Task Force Monitor da CNSystems. Dos dois aparelhos citados que foram utilizados para captação de registros de eletrocardiograma, apenas os dados do MP150 da BIOPAC Systems foram contabilizados, já que tinha apenas um canal de ECG, o que contribui para reduzir a complexidade do processamento e economizar recursos computacionais.

Os arquivos de dados do conjunto de dados seguem um formato padrão WFDB aberto, comumente utilizado para armazenar informações médicas de sinais biológicos, que foi utilizado para realização do estudo exploratório dos sinais. Os registros dos 500 voluntários são organizados com números consecutivos após ordenação aleatória, as faixas etárias originais da base de dados foram categorizadas em 15 grupos, abrangendo idades de 18 a 92 anos, mas para o estudo houve a redução do número de grupo para somente três: jovens (abaixo dos 20 anos), adultos (20 à 59 anos) e idosos (60 anos ou mais). Um ponto importante que foi observado foi a ausência dos dados de idade de um dos voluntários, que, para os propósitos do estudo, acabou sendo considerada relevante. Devido a importância da idade para o experimento, esse voluntário foi excluído da base de dados, resultando em um total de 499 participantes.

A distribuição da idade dos voluntários foi feita de forma desigual, cerca de 90% dos participantes foram alocados no grupo 2, enquanto apenas 7% pertenciam ao grupo 3 e 3% ao grupo 1. Essa discrepância na quantidade de dados em cada grupo resultou em um conjunto desbalanceado, ou seja, a amostra não apresenta uma distribuição uniforme de indivíduos por faixa etária, o que implicou na necessidade do balanceamento dos dados na experimentação.

3.2 Estudo exploratório dos sinais

O estudo exploratório dos sinais do eletrocardiograma é uma etapa fundamental para a compreensão e análise da atividade elétrica do coração, já que fornece informações valiosas sobre a saúde cardiovascular dos indivíduos presentes na base de dados. Neste estudo, foram analisados três ECGs de voluntários de forma aleatória, utilizando a biblioteca *wfdb* que possui métodos para processar e interpretar esses sinais.

Cada ECG continha um extenso registro de dados, com uma média de 976.665 amostras por voluntário. Devido a essa grande quantidade de informações, optou-se por realizar um recorte curto na qual não retornasse as ondulações iniciais do sinal, selecionando amostras compreendidas entre 2500 e 15000 (aproximadamente 12s do exame), visando reduzir a complexidade computacional da análise e garantir resultados mais concisos e visíveis. Uma das primeiras observações importantes foi a inexistência de valores nulos nos registros de ECG que proporcionaram uma maior confiabilidade e segurança na interpretação dos resultados obtidos ao longo do estudo.

Na sequência, a biblioteca *heartpy* foi escolhida para a detecção do complexo QRS, essa detecção é crucial para o diagnóstico de arritmias e outras anomalias do ritmo cardíaco. Medidas de frequência cardíaca também foram analisadas devido a importância na avaliação da regularidade dos batimentos cardíacos e para detectar possíveis irregularidades ou divergências da normalidade. Um aspecto notável durante o estudo foi a constatação de que não foi necessária a redução de ruído, pois o sinal capturado apresentava uma qualidade satisfatória, livre de interferências significativas que pudessem comprometer as análises subsequentes.

3.3 Pré-processamento de dados

3.3.1 Técnica de janelamento

Neste estudo, foi proposto a utilização da técnica de janelamento de sinais para extrair informações relevantes do ECG, que divide o sinal contínuo em segmentos menores para análise detalhada.

Inicialmente, o processo de janelamento visou capturar segmentos de 1 segundo (1000 amostras) de cada ECG, de acordo com a frequência de amostragem de 1000Hz. No entanto, ao tentar aplicar a técnica de extração de atributos verificou-se que as colunas

contendo os dados de batimentos cardíacos utilizando o método da biblioteca *heartpy* ficavam nulas devido ao intervalo de tempo reduzido, o que se deve à limitação temporal para a extração confiável de atributos cardíacos em segmentos tão curtos.

Para contornar essa limitação, uma estratégia foi adotada, envolvendo um segundo estágio de janelamento. Nesse estágio, segmentos de 5 segundos (5000 amostras) foram considerados, permitindo a aquisição completa de informações sobre os atributos cardíacos, o que demonstrou ser mais eficaz para a extração precisa dos parâmetros desejados, superando as restrições temporais impostas pelo janelamento de 1 segundo.

A implementação dos janelamentos de 1 segundo e 5 segundos foi facilitada pela utilização da função *peakdetection.make_windows* também da biblioteca *heartpy*, função que permitiu a criação eficiente de janelas de diferentes tamanhos.

3.3.2 Conversão de tipo de dados numéricos e limpeza da base de dados

Para otimizar o processamento e a análise desses sinais, muitas vezes é necessário lidar com a conversão de tipos de dados e a limpeza de registros com campos ausentes. Neste contexto, este estudo aborda a técnica de conversão de tipos de dados, enfocando a transformação de tipos de `int64` e `float64` para `int32` e `float32`, para otimizar a eficiência de processamento, reduzir os requisitos de memória e acelerar as análises subsequentes. Posteriormente, foi aplicado a técnica *dropna()* para lidar com registros incompletos. Isso foi feito para evitar distorções ou imprecisões nos resultados das análises posteriores e na previsão do modelo, garantindo que apenas os registros completos e consistentes fossem considerados.

3.3.3 Normalização de dados

A normalização desempenha um papel fundamental na preparação de dados para análise e modelagem, especialmente em contextos onde diferentes atributos têm escalas variadas. Assim, no âmbito da análise de sinais de eletrocardiograma a normalização é essencial para garantir que as variações de escala nos atributos não afetem negativamente a precisão das técnicas de previsão. Este estudo aborda a metodologia de normalização utilizando quatro técnicas distintas a serem comparadas: *StandardScaler*, técnica que padroniza os atributos para ter média zero e desvio padrão unitário, *MinMaxScaler*, técnica que dimensiona os atributos para um intervalo especificado entre 0 e 1, *MaxAbs*, técnica

que dimensiona os atributos para o intervalo $[-1, 1]$ tomando o valor absoluto máximo como referência e *RobustScaler*, técnica que utiliza estatísticas robustas para dimensionar os atributos, reduzindo o impacto de *outliers*.

A normalização tem como objetivo principal ajustar as escalas dos atributos para que fiquem em uma faixa similar, evitando assim que atributos com escalas maiores tenham um impacto desproporcional sobre os resultados da análise. Neste estudo, a normalização foi realizada seguindo um formato ideal, onde as etapas de *fit_transform* foram aplicadas inicialmente à base de treino, ajustando os parâmetros da normalização de acordo com essa base e em seguida o método transform foi aplicada à base de testes, utilizando os parâmetros previamente ajustados, garantindo a coerência entre os dados de treino e teste.

Os resultados indicaram que as técnicas de normalização *StandardScaler* e *RobustScaler* apresentaram os melhores resultados, tal qual será mostrado adiante na seção de resultados.

3.4 Extração de atributos

A análise de sinais de eletrocardiograma é uma tarefa complexa que envolve a extração de informações relevantes a partir dos dados brutos, permitindo entender mais sobre a saúde cardíaca e a atividade elétrica do coração. Nesse contexto, a extração de atributos é uma etapa crucial, onde medidas significativas são derivadas dos sinais de ECG para avaliar padrões, variações e características específicas. Essa experimentação envolve a exploração do processo de extração de atributos dos sinais, empregando informações de localização, frequência e batimentos cardíacos, utilizando métodos da biblioteca *tftb* e *heartpy*.

Foi utilizada a biblioteca *tftb* com o módulo *processing*, fazendo uso dos métodos *loctime*, *locfreq* e *inst_freq*. A primeira desempenhou um papel fundamental ao identificar os pontos de máxima relevância espacial nos sinais. Tal identificação facilitou a caracterização de elementos vitais, como as ondas R, P e Q.

A função *locfreq* contribuiu com a estimativa das frequências predominantes presentes no próprio sinal, componente da pesquisa que revelou-se crucial para a análise das oscilações cardíacas.

No prosseguimento da investigação, o método *inst_freq* desempenhou um papel

central na extração de informações de frequência, revelando informações para a compreensão das flutuações da atividade cardíaca ao longo do tempo, o que por sua vez, auxiliou na detecção de padrões de ritmo e variações de frequência cardíaca.

A biblioteca *heartpy* ajudou na obtenção de informações detalhadas sobre os batimentos cardíacos através do método *process*, na qual diversos parâmetros foram extraídos, cada um proporcionando uma visão única sobre a atividade cardíaca. Isso incluiu medidas como batimentos por minuto, intervalo entre batimentos, desvio padrão dos intervalos NN, desvio padrão das diferenças dos intervalos NN, raiz quadrada do somatório dos quadrados das diferenças dos Intervalos NN, PNN20 e PNN50, além de medidas como *HR_MAD*, *SD1* e *SD2*, estas últimas ligadas à análise da variabilidade da frequência cardíaca. A partir dessa abordagem, métricas baseados no pico R foram extraídos, como por exemplo a média dos intervalos R-R e desvio padrão dos intervalos R-R, fornecendo uma compreensão mais abrangente da atividade cardíaca.

3.5 Divisão dos conjuntos de treino e teste

A divisão adequada da base de dados é uma etapa essencial na construção de modelos de aprendizado de máquina, permitindo avaliar a capacidade do modelo de generalizar para novos dados não vistos durante o treinamento. Nesse contexto, o método *train_test_split* da biblioteca *sklearn* é frequentemente utilizado para separar os dados em conjuntos de treinamento e teste. O estudo explora o processo de separação da base de dados em duas partes distintas na proporção 80-20, onde 80% dos dados foram alocados para a base de treino, que é utilizada para treinar o modelo, e 20% para a base de teste. Além disso, o atributo *random_state* foi definido como 42 para garantir a reprodutibilidade dos resultados assegurando que a divisão dos dados seja consistente e replicável, isso significa que ao executar o mesmo código várias vezes com o mesmo valor, a divisão dos dados será sempre a mesma, permitindo que outros pesquisadores ou desenvolvedores obtenham os mesmos resultados ao executar o código.

3.6 Balanceamento de dados

O balanceamento de conjuntos de dados é uma consideração crítica ao lidar com tarefas de classificação, especialmente quando há desequilíbrio significativo entre as classes

alvo. Neste estudo, a técnica de balanceamento foi aplicada visando melhorar o desempenho do modelo em classes minoritárias pelo fato que 90% dos registros de sinais de eletrocardiograma dos voluntários correspondem ao grupo de adultos. Duas abordagens de balanceamento foram exploradas, uma envolvendo o aumento das classes minoritárias e a outra diminuição das amostras da classe majoritária, utilizando a biblioteca *imbalanced-learn*, que fornece ferramentas para lidar com classificação com classes desequilibradas.

Na primeira combinação, foram empregados os métodos *RandomUnderSampler* e *RandomOverSampler*. O *RandomUnderSampler* reduz a amostragem da classe majoritária para igualar o tamanho das classes minoritárias, enquanto o *RandomOverSampler* aumenta a amostragem da classe minoritária para igualar o tamanho da classe majoritária. Na segunda combinação, foram utilizadas as técnicas *NearMiss* e *SMOTE*, o primeiro é uma técnica de subamostragem que seleciona amostras da classe majoritária com base na proximidade com as amostras da classe minoritária e o segundo gera novas amostras sintéticas para a classe minoritária, ampliando o conjunto de dados e atenuando o desequilíbrio.

Quando a análise foi estendida para lidar com três rótulos na classe alvo (jovens, adultos e idosos), a classe de adultos sofreu redução de amostras, enquanto as classes de jovens e idosos tiveram aumento na amostragem. Quando a binarização da coluna alvo foi realizada, observou-se que a classe de adultos sofreu diminuição e a classe de idosos sofreu aumento, sendo importante lembrar que nesse cenário o rótulo jovens não estava presente, o que influenciou a dinâmica do balanceamento.

Cada combinação de estratégia de balanceamento apresenta suas próprias vantagens e desvantagens. Ao comparar diferentes abordagens, incentiva-se a exploração dos efeitos de diferentes tipos de desbalanceamento no desempenho do modelo, permitindo que a escolha de qual combinação funciona melhor para a base de dados do estudo. No fim, os resultados que serão mostrados na seção posterior revelaram que a segunda combinação de balanceamento apresentou melhores resultados em termos de desempenho do modelo.

3.7 Seleção de atributos

A seleção de atributos também é uma etapa fundamental no processo de construção de um modelo preditivo. Esta técnica permite que o modelo se concentre em

características relevantes e ignore atributos irrelevantes ou redundantes. Neste estudo, a seleção de atributos foi realizada apenas nos testes voltados para classificação binária de faixa etária entre adultos e idosos, devido aos melhores resultados obtidos em comparação à previsão de três classes. Foram aplicadas quatro técnicas de seleção de atributos, cada uma delas testada em combinação com as abordagens de balanceamento e normalização utilizadas anteriormente. As técnicas de seleção de atributos incluíram: *SelectKBest*, *SelectFromModel*, *PSO* e *VarianceThreShold*.

SelectKBest, técnica que apresenta uma maneira de avaliar e escolher os k melhores atributos com base em testes estatísticos, no caso do experimento deste trabalho foi testado com valor igual à 2000.

Outra estratégia usada foi o *SelectFromModel*. Nessa abordagem um estimador de modelo, como uma Máquina de Vetores de Suporte, foi utilizado para avaliar a importância dos atributos, selecionando os que têm uma contribuição significativa para o desempenho do modelo.

A penúltima abordagem testada foi o *PSO*, que trabalha simulando o comportamento de um enxame de partículas para encontrar a combinação ideal de atributos que otimizam um objetivo específico, como maximizar a acurácia de um modelo, sendo particularmente útil para explorar de maneira eficiente o espaço de atributos, buscando um equilíbrio entre a busca exaustiva e a eficiência computacional.

Por fim, a *VarianceThreshold* foi escolhida, já que oferece uma abordagem diferente, focando na remoção de atributos com baixa variância através da premissa de que atributos com pouca variação possuem pouca informação discriminativa.

Cada uma dessas técnicas traz uma perspectiva única para a seleção de atributos, permitindo que pelos resultados de cada combinação fosse no fim escolhida a abordagem mais adequada às necessidades específicas da previsão desse experimento.

3.8 Modelos de classificação

Neste trabalho, foram explorados dois tipos de classificadores: Floresta Aleatória e SVM.

Esses modelos foram escolhidos para este trabalho devido ao conhecimento prévio em aprendizado de máquina, bem como à leitura de estudos relacionados que citaram ambos em alguns trabalhos. Eles se mostraram promissores para o objetivo de previsão

com base em dados de ECG, o que respaldou a decisão de utilizá-los.

O classificador da Floresta Aleatória foi configurado com uma série de parâmetros para otimizar o desempenho: o parâmetro *n_estimators* foi variado de 100 a 500 para avaliar o impacto do número de árvores na floresta na precisão do modelo e o parâmetro *class_weight* foi ajustado para *balanced* a fim de tratar o desequilíbrio de classes de maneira apropriada.

O SVM foi utilizado com um kernel linear, uma escolha comum para tarefas de classificação, com o parâmetro C definido como 1, afetando a regularização do modelo, e o parâmetro *gamma* foi definido como auto, o que indica que o valor será calculado automaticamente.

Cada modelo foi treinado e testado utilizando diferentes combinações das técnicas de balanceamento, normalização e seleção de atributos previamente mencionadas. Essas combinações permitiram avaliar como cada modelo reagia a diferentes configurações e preparações dos dados.

3.9 Avaliação do modelo

A avaliação adequada dos modelos de classificação foi a última etapa do processo de classificação, a fim de entender a eficácia de cada abordagem e selecionar a configuração que melhor se adequa aos objetivos do estudo. Nesta etapa da metodologia, cada modelo foi avaliado de forma abrangente, empregando uma variedade de métricas para compreender melhor os resultados.

Para cada modelo, foi utilizado com principal método avaliativo o *classification_report* da biblioteca *scikit-learn*, que fornece uma visão detalhada das métricas de avaliação, incluindo precisão, que mede a proporção de instâncias classificadas como positivas pelo modelo que realmente são positivas em relação ao total de instâncias classificadas como positivas, sensibilidade que mede a proporção de instâncias positivas corretamente identificadas pelo modelo em relação ao total de instâncias verdadeiramente positivas e f1-score que combina a precisão e a sensibilidade em um único valor.

Além disso, para avaliar a capacidade discriminativa dos modelos, duas métricas adicionais foram empregadas: a área sob a curva ROC e especificidade. A primeira mede a habilidade do modelo em distinguir entre classes positivas e negativas voltado para a proporção de verdadeiros negativos em relação ao total de negativos, já a segunda

complementa a sensibilidade ao fornecer informações sobre a capacidade do modelo de identificar corretamente os casos negativos

A combinação dessas métricas oferece uma visão necessária do desempenho dos modelos em diferentes cenários, levando em consideração configurações de balanceamento, normalização e seleção de atributos. Isso permitiu comparar as abordagens e identificar qual modelo e configuração obtiveram os melhores resultados em termos de capacidade preditiva e inferir possíveis conclusões finais a respeito do processo de classificação abordado neste material.

4 RESULTADOS E DISCUSSÃO

Neste capítulo, apresentaremos e discutiremos os resultados decorrentes do desenvolvimento e aplicação do algoritmo de aprendizado de máquina por meio da experimentação. Os resultados obtidos por meio deste estudo foram organizados em cinco seções distintas, cada uma contribuindo para a compreensão do processo de criação do algoritmo e suas implicações no diagnóstico de padrões relacionados a essas alterações.

A primeira seção tem como objetivo apresentar os sinais de eletrocardiograma dos três voluntários escolhidos na etapa de estudo exploratório dos sinais, visando mostrar visualmente o registro de ECG de cada indivíduo. A segunda seção é voltada exclusivamente para resultados comparativos e visuais do processo de detecção do complexo QRS e picos R dos três registros. A terceira seção foca na comparação do tempo de execução da criação de cada base de dados com seu respectivo tempo de janelamento. A quarta seção é voltada exclusivamente para modelos com três tipos de alvo: jovens, adultos e idosos. Por fim, a última seção concentra-se na análise dos resultados após a binarização dos rótulos de alvo, a fim de avaliar possível mudança significativa com a exclusão do menor alvo e o impacto da aplicação de seleção de atributos nos resultados do modelo.

4.1 Sinais de eletrocardiograma de três voluntários

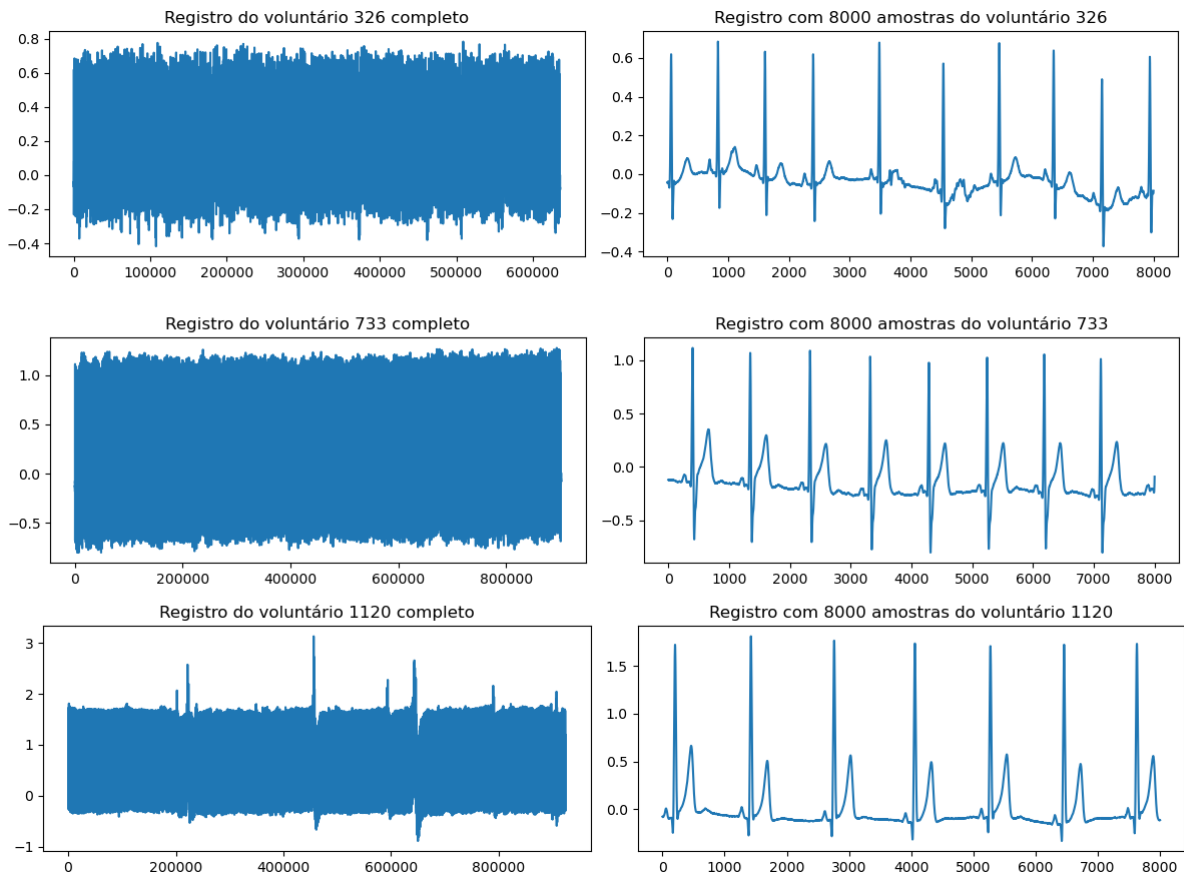
Para que fosse possível realizar todo o processo de construção de um modelo de aprendizado de máquina foi necessário antes estudar e entender como estavam distribuídos e apresentados alguns eletrocardiogramas dos voluntários, para extrair informações valiosas sobre as variações e características dos sinais cardiovasculares presentes em cada registro.

Todo o processo de estudo exploratório dos sinais foi realizado em três voluntários aleatórios de identificação: 326, 733 e 1120. Além de utilizar apenas o canal 0 do exame, que representa o sinal de ECG, como mostrado na figura 9.

4.2 Comparativo das técnicas de detecção do Complexo QRS e picos R

Foi realizado a identificação dos complexos QRS e dos picos R de três registros aleatórios, a fim de analisar uma possível interferência de fatores externos. Essa análise

Figura 9: Comparação dos eletrocardiogramas de três voluntários



Fonte: Elaborado pelo próprio autor (2023)


visava verificar se tais fatores poderiam causar falsos picos, distorções nas amplitudes e formas das ondas, ou até mesmo ocultar completamente os picos reais.

Devido ao registro do sinal do ECG ser bem extenso para níveis visuais e de análise, a quantidade de dados da gravação de sinal foi limitada em 8000 amostras. As imagens a seguir mostram a detecção realizada com sucesso dos picos R em três tipos de estratégias utilizadas: *xqrs.detect*, *correctpeaks* e *heartpy* respectivamente.

Na primeira tentativa utilizando o *xqrs.detect* o voluntário 326 não teve seus picos detectados corretamente, diferentemente dos outros dois. A figura 10 apresenta a comparação da detecção de picos: na esquerda uma detecção má sucedida e na direita uma bem sucedida.

A incorporação do método *correct_peaks* da biblioteca *wfdb* como a segunda abordagem de detecção revelou-se altamente eficaz na realização da identificação precisa dos picos R, mostrado na figura 11. Esse sucesso foi ainda mais evidente quando aplicado ao caso específico do voluntário no qual o método de detecção anterior não conseguiu

Figura 10: Comparação da detecção de picos má sucedida e bem sucedida



Fonte: Elaborado pelo próprio autor (2023)

obter resultados satisfatórios, como pode ser observado claramente na imagem ilustrativa acima.

Por último, o método de detecção, utilizando a biblioteca *hearty*, se destacou ao conquistar sucesso na detecção de picos R em todos os três voluntários analisados, como é demonstrado na figura 12. Essa consistente eficácia não foi afetada pelas variações nos tamanhos das amostras cardíacas individuais, reforçando o resultado positivo em meio à detecção de picos R.

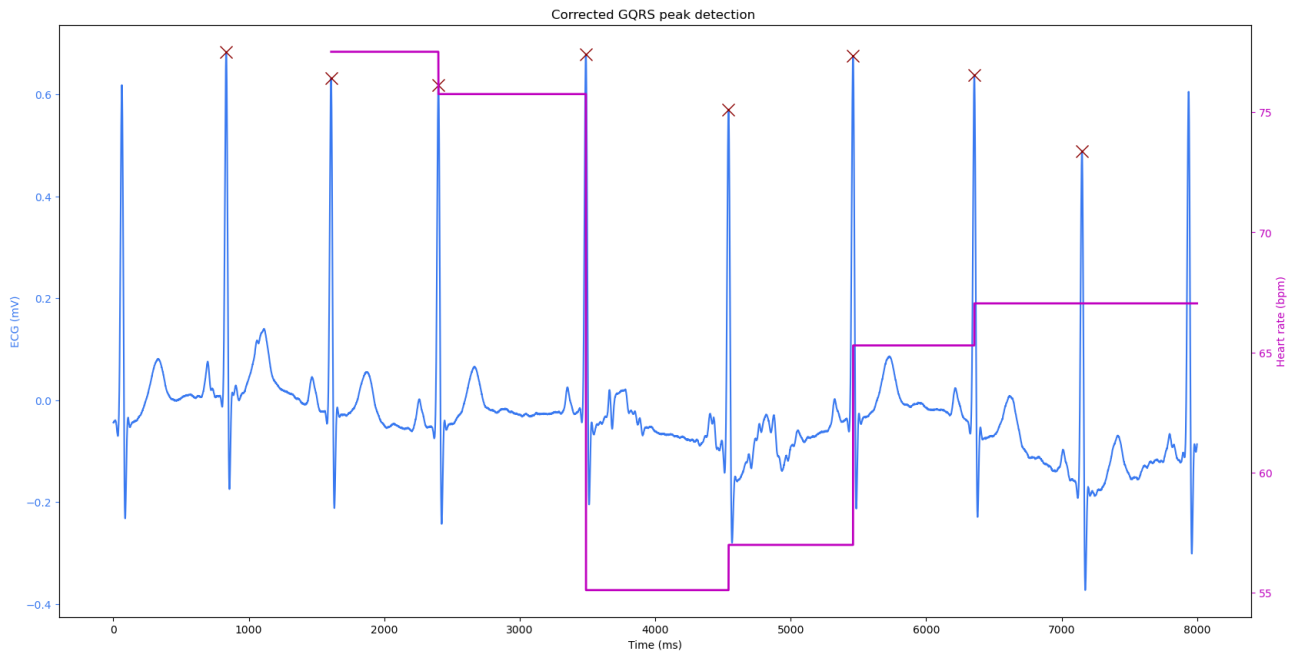
4.3 Tempo de execução das bases de dados após janelamento

Para comparar os efeitos de diferentes estratégias de janelamento, duas abordagens foram adotadas, e o tempo de processamento necessário para criar a base de dados após a aplicação de cada técnica foi avaliado.

Ao utilizar um janelamento de 1 segundo, o processo de construção do *DataFrame* levou um total de 246 segundos, mostrando uma eficiência relativa em comparação com a alternativa de janelamento de 5 segundos. Neste último caso, houve um aumento notável no tempo de processamento, demandando um período de 1124 segundos, equivalente a aproximadamente 4,57 vezes mais tempo para ser concluído, como evidenciado na figura 13.

É possível que a diferença significativa no número de colunas resultante dos diferentes tamanhos de janelamento tenha contribuído para o aumento no tempo de processa-

Figura 11: Resultado da utilização da técnica `correct_peaks` no voluntário 326



Fonte: Elaborado pelo próprio autor (2023)


mento. O janelamento de 5000 amostras resultou em 5028 atributos, enquanto o de 1000 amostras por segundo teve 1013 atributos, representando quase 5 vezes mais colunas.

4.4 Avaliação dos modelos com três rótulos de grupos de idades

A análise inicial dos resultados obtidos pelo modelo desenvolvido, empregando os algoritmos classificadores Floresta Aleatória e SVM, será fundamentada na categorização em três classes distintas. Esse enfoque permitirá avaliar a capacidade do modelo em diferenciar grupos etários através dos registros de eletrocardiograma provenientes de indivíduos saudáveis, além de ter um objetivo crucial de verificar a viabilidade de identificar idosos com base nas características de frequência e localização presentes nos eletrocardiogramas. Ao conduzir essa comparação entre os classificadores, será possível obter resultados importantes sobre a eficácia do modelo em relação às tarefas de categorização etária e detecção de idosos.

Todas as análises foram conduzidas com base em critérios cruciais, incluindo a normalização dos dados comparativa com *StandardScaler* e *RobustScaler* (métodos que tiveram melhores resultados), o dimensionamento após o balanceamento das amostras utilizando as técnicas de *NearMiss* e *SMOTE* e a aplicação de janelas temporais de

Figura 12: Detecção de picos R utilizando a biblioteca heartpy



Fonte: Elaborado pelo próprio autor (2023)

Tabela 4: Resultado do modelo Floresta Aleatória sem a técnica de balanceamento

Normalização	Modelo	Rótulo	Precisão	Sensibilidade	F1-Score
StandardScaler	Floresta Aleatória	0	0	0	0
		1	0.91	1	0.95
		2	0	0	0


Fonte: Elaborado pelo próprio autor (2023)

durações distintas: 5 segundos e 1 segundo. Essa abordagem sistemática permite avaliar minuciosamente o desempenho do nosso modelo em diferentes contextos.

4.4.1 Classificador Floresta Aleatória sem balanceamento

Primeiramente, realizou-se uma avaliação do modelo sem executar a etapa de balanceamento. Observou-se que o rótulo 0 possuía 2949 registros, o rótulo 1 possuía 83849 registros e o rótulo 2 possuía 5946 registros. É relevante ressaltar que a etapa de balanceamento é importante em conjuntos de dados altamente desbalanceados, e, devido a esta importância, a ausência desse processo teve um impacto significativo nos resultados com previsões para as classes minoritárias (rótulos 0 e 2) imprecisas, tendo a precisão, sensibilidade e *f1-score* igual a zero utilizando o modelo Floresta Aleatória e normalização *StandardScaler*, já o rótulo 1 de classe majoritária teve resultados bem expressivos, conforme disponibilizado na tabela 4.

Figura 13: Diferença do tempo de execução



Fonte: Elaborado pelo próprio autor (2023)

4.4.2 Resultados dos classificadores com balanceamento (Janelamento de 5s)

Em seguida, já com a base de dados balanceada, foi feita uma comparação dos resultados de precisão, sensibilidade e $f1$ -score dos dois modelos, como mostrado na tabela 5. Em geral, a normalização *RobustScaler* parece oferecer ligeiramente melhores resultados do que a *StandardScaler*, particularmente no que diz respeito à sensibilidade e ao $f1$ -score. Já o modelo Floresta Aleatória também tendeu a ter um desempenho ligeiramente melhor do que o SVM, conforme indicado pelo $f1$ -score mais alto em muitos dos cenários.

No quesito de rótulos contendo os grupos de idades a serem previstos, os resultados para o rótulo voltado aos jovens não são bons, aproximando sempre de 0.05 de precisão e $f1$ -score, independentemente do modelo ou da normalização utilizada. Diferentemente para o rótulo de voluntários adultos, os resultados sempre estiveram como o melhor em comparação aos outros. Vale lembrar que esse foi o grupo majoritário da base dados antes de ser balanceado.

Por fim, para o rótulo “idosos”, os resultados variam entre baixos e razoáveis a depender da métrica, ficando com a segunda posição nos melhores resultados de previsão do modelo treinado, com a combinação Floresta Aleatória e *RobustScaler* mostrando um desempenho um pouco melhor.

Tabela 5: Comparação dos modelos com janelamento de 5s

Normalização	Modelo	Rótulo	Precisão	Sensibilidade	F1-Score
StandardScaler	SVM	0	0.04	0.19	0.06
		1	0.92	0.65	0.76
		2	0.13	0.42	0.2
	Floresta Aleatória	0	0.07	0.23	0.11
		1	0.94	0.74	0.83
		2	0.24	0.68	0.35
RobustScaler	SVM	0	0.05	0.31	0.08
		1	0.93	0.6	0.73
		2	0.17	0.6	0.27
	Floresta Aleatória	0	0.06	0.21	0.1
		1	0.94	0.75	0.83
		2	0.24	0.68	0.35

Fonte: Elaborado pelo próprio autor (2023)

4.4.3 Resultados dos classificadores com balanceamento (Janelamento de 1s)

Comparando os resultados anteriores, observamos uma redução na precisão do grupo de idosos ao utilizar um janelamento de 1 segundo, evidenciado na tabela 6. Enquanto a média de precisão e o $f1-score$ eram de 0.16 e 0.25, respectivamente, com o janelamento de 5 segundos, o uso do janelamento de 1 segundo resultou em precisões próximas a 0.1.

No entanto, essa diferença não se refletiu nos valores de sensibilidade e $f1-score$, os quais mantiveram um padrão semelhante. O desempenho do modelo Floresta Aleatória geralmente superou o do SVM levemente para este conjunto de dados e rótulos. Além disso, a estratégia de normalização utilizando o *RobustScaler* tendeu a oferecer resultados mais favoráveis em comparação com o uso do *StandardScaler*, sobretudo para os rótulos 0 e 1.

Embora os resultados de cada rótulo tenham se aproximado independentemente do tipo de avaliação empregada, é importante ressaltar que o janelamento de 5 segundos resultou em um desempenho superior em relação aos outros parâmetros avaliados.

4.4.4 Comparação dos janelamentos com novas métricas

Na tabela 7 é apresentado os resultados comparativos para dois intervalos de janelamento, considerando sua acurácia, pontuação $ROC-AUC$ e especificidade. Observa-se

Tabela 6: Comparação dos modelos com janelamento de 1s

Normalização	Modelo	Rótulo	Precisão	Sensibilidade	F1-Score
StandardScaler	SVM	0	0.03	0.26	0.05
		1	0.91	0.42	0.58
		2	0.09	0.4	0.14
	Floresta Aleatória	0	0.04	0.15	0.06
		1	0.93	0.42	0.58
		2	0.1	0.77	0.17
RobustScaler	SVM	0	0.03	0.29	0.06
		1	0.92	0.4	0.56
		2	0.09	0.41	0.14
	Floresta Aleatória	0	0.05	0.16	0.07
		1	0.93	0.42	0.58
		2	0.1	0.77	0.17

Fonte: Elaborado pelo próprio autor (2023)

Tabela 7: Comparação dos modelos sob aspecto de acurácia, roc-auc score e especificidade

Normalização	Modelo	Janelamento	Acurácia	ROC-AUC Score	Especificidade
StandardScaler	SVM	1s	0.42	0.53	0.63
		5s	0.67	0.59	0.44
	Floresta Aleatória	1s	0.44	0.62	0.69
		5s	0.72	0.75	0.59
RobustScaler	SVM	1s	0.4	0.53	0.66
		5s	0.59	0.64	0.59
	Floresta Aleatória	1s	0.43	0.62	0.7
		5s	0.73	0.81	0.44

Fonte: Elaborado pelo próprio autor (2023)

uma considerável variação nos resultados de acurácia para diferentes combinações. No entanto, ao analisar o intervalo de janelamento de 5 segundos nota-se uma tendência de resultados mais altos em comparação com o de 1 segundo, especialmente no modelo Floresta Aleatória, onde a diferença é aproximadamente 0.2 em relação ao SVM.

Quanto à pontuação *ROC-AUC*, os resultados também favorecem o intervalo de 5 segundos, independentemente da normalização e do modelo utilizado. Notavelmente, a combinação do *RobustScaler* com o modelo Floresta Aleatória apresentou o melhor desempenho nesse aspecto apesar dos resultados semelhantes.

Por fim, em contraste com as outras métricas avaliadas, a especificidade apresentou um desempenho superior no intervalo de janelamento de 1 segundo. Novamente, os resultados exibem variações, porém, não evidenciam uma tendência clara em relação à normalização e ao intervalo de janelamento.

4.5 Avaliação dos modelos com dois rótulos de grupos de idades

Nesta seção, apresentaremos todos os resultados subsequentes após a aplicação da binarização ao alvo. Diferentemente da abordagem anterior, onde os rótulos eram divididos em três grupos distintos, nesta etapa do estudo o foco se volta para a previsão de apenas dois grupos etários: adultos e idosos. Uma vez que os resultados prévios demonstraram vantagens no uso da janela de 5 segundos, todas as avaliações subsequentes foram conduzidas com base nesse período de janela. Importante destacar que as técnicas de normalização e os classificadores utilizados anteriormente foram mantidos com as mesmas combinações empregadas.

4.5.1 Comparativo dos resultados de cada classificador

Apresentado na tabela 8, observa-se uma notável consistência na obtenção de altos índices de precisão para o grupo de adultos, semelhantemente quando tinha três rótulos, independentemente das diversas combinações empregadas de técnicas de normalização e modelos, oscilando entre 0.95 e 0.96. A sensibilidade, igualmente, mantém-se em patamares relativamente elevados, variando entre 0.69 e 0.77, enquanto o *f1-score* oscila entre 0.8 e 0.86.

Por outro lado, para o grupo de idosos, as métricas exibem consistentemente valores inferiores. A precisão desloca-se entre 0.1 e 0.13, a sensibilidade varia de 0.41 a 0.54 e o *f1-score* oscila entre 0.16 e 0.2, o que indica ainda que o modelo encontra desafios na correta previsão dos casos positivos relacionados a idosos.

Destaca-se que, em ambas as categorias, a configuração que geralmente se destaca com os melhores resultados é a combinação “*RobustScaler* - Floresta Aleatória”, evidenciado pela observação dos valores mais elevados de precisão, sensibilidade e *f1-score* para o rótulo 0.

Na tabela 9 é mostrado que os modelos Floresta Aleatória exibem acurácia e especificidade superiores a 0.75 e 0.76, respectivamente, independentemente da normalização, indicando um médio desempenho na previsão, sem focar unicamente em um grupo específico. Contudo, o SVM, quando normalizado com *RobustScaler*, registra queda leve tanto na acurácia (de 0.74 para 0.68) quanto na especificidade (de 0.76 para 0.69).

Em relação à métrica *ROC-AUC score*, o modelo Floresta Aleatória apresentou

Tabela 8: Comparação dos modelos após processo de binarização do alvo

Normalização	Modelo	Rótulo	Precisão	Sensibilidade	F1-Score
StandardScaler	SVM	0	0.95	0.76	0.85
		1	0.1	0.41	0.16
	Floresta Aleatória	0	0.96	0.76	0.85
		1	0.12	0.52	0.2
RobustScaler	SVM	0	0.96	0.69	0.8
		1	0.1	0.54	0.17
	Floresta Aleatória	0	0.96	0.77	0.86
		1	0.13	0.52	0.2

Fonte: Elaborado pelo próprio autor (2023)

Tabela 9: Modelos após binarização sob aspecto de acurácia, ROC-AUC score e especificidade

Normalização	Modelo	Acurácia	ROC-AUC Score	Especificidade
StandardScaler	SVM	0.74	0.62	0.76
	Floresta Aleatória	0.75	0.72	0.76
RobustScaler	SVM	0.68	0.65	0.69
	Floresta Aleatória	0.76	0.72	0.76

Fonte: Elaborado pelo próprio autor (2023)

um desempenho consistente, alcançando um valor de 0.72, independentemente da técnica de normalização adotada, valor que foi superior ao obtido pelo modelo SVM, que teve uma média de 0.63.

Comparando ambos os métodos, o Floresta Aleatória mostra melhor desempenho geral em termos de acurácia, enquanto o SVM conseguiu equiparar ao outro modelo na métrica de especificidade utilizando a normalização *StandardScaler*. A melhor escolha, baseada nas métricas acima para o problema, também foi o modelo Floresta Aleatória com normalização *RobustScaler*, atingindo a maior acurácia global e mantendo bons valores de especificidade em ambos os rótulos.

4.5.2 Diferença de resultados após aplicação da seleção de atributos

Ambos os classificadores passaram por avaliação após a aplicação da técnica de seleção de atributos, utilizando quatro diferentes métodos: *PSO*, *SelectKBest*, *SelectK-Model* e *VarianceThreshold*. O método *PSO* diminui o número de atributos para 2014, enquanto o *SelectKBest* foi realizado testes com diferentes k , porém o que alcançou melhor resultado foi $k=2000$. O método *VarianceThreshold* baixou para 3512 e *SelectKModel*

com *threshold* = ‘mean’ resultou em 3211 atributos.

A figura 14 ilustra os resultados de cada técnica de seleção de atributos. Inicialmente, foram avaliadas métricas de precisão, sensibilidade e *f1-score*, que manteve o padrão alto de previsão para adultos, apresentando valores mais elevados em comparação aos idosos. Independentemente da técnica de seleção de atributos empregada, todas as métricas demonstraram valores consistentemente altos, atingindo patamares acima de 0.8 para a previsão de adultos, enquanto os resultados para idosos permaneceram em torno de 0.2.

Vale destacar um ponto relevante: a redução do número de atributos antes do treinamento do modelo demonstrou ser suficiente para aumentar as métricas, principalmente os valores de precisão. Esse ganho culminou no melhor resultado obtido dentre todos os testes realizados especificamente quando observamos o modelo Floresta Aleatória combinado com a técnica *PSO*.

Ainda na mesma figura, analisando as comparações entre os classificadores, percebe-se que o Floresta Aleatória apresentou ligeira superioridade em relação ao SVM em grande parte dos resultados. A exceção ocorreu somente no método *VarianceThreshold*, no qual o SVM mostrou vantagem para o grupo de idosos.


Em seguida foi conduzida uma avaliação das métricas de acurácia, *ROC-AUC score* e *f1-score*, que diferentemente da avaliação da figura 14 na qual as métricas eram representadas por rótulo, essa focava no desempenho geral do modelo. Este comparativo está apresentado na figura 15.

O modelo Floresta Aleatória demonstrou consistentemente um desempenho superior em comparação com o SVM em todas as métricas avaliadas independentemente da técnica utilizada, o que pode ser mais visível nos resultados do *ROC-AUC score* com uma diferença de 0.15 a 0.3. Nos resultados de acurácia e especificidade os valores se mantiveram próximos, mas com uma vantagem média de cerca de 0.015 para o Floresta Aleatória.

4.5.3 Melhor abordagem e configuração após experimentação

Após diversas experimentações com diferentes combinações, chegamos à conclusão da configuração de modelo mais eficaz para a análise de sinais de ECG. Entre as diferentes abordagens avaliadas, o modelo classificador da Floresta Aleatória se destacou

Figura 14: Comparativo de resultados com seleção de atributos

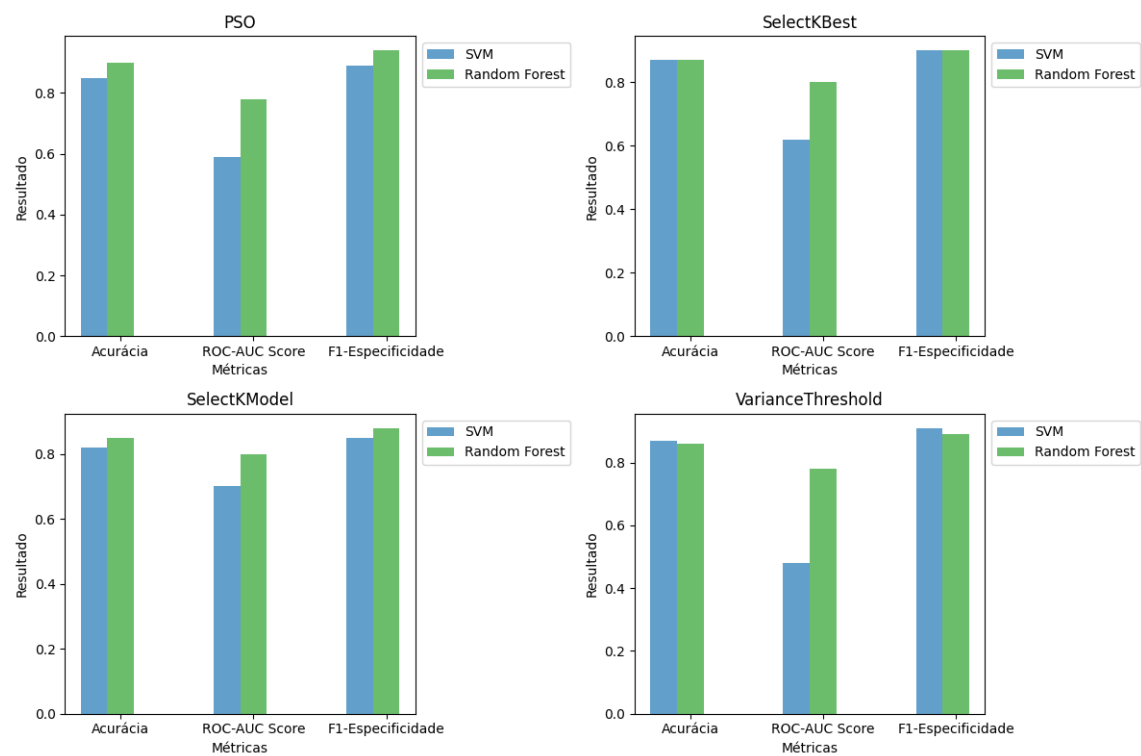


Fonte: Elaborado pelo próprio autor (2023)

como a escolha mais adequada, fornecendo resultados mais consistentes em comparação ao SVM. No pré-processamento, os melhores resultados das métricas avaliadas vieram da combinação da técnica *RobustScaler* de normalização e das técnicas *NearMISS* e *SMOTE* para tratar do desbalanceamento do alvo, que juntos geraram melhores resultados com 5000 amostras para cada rótulo comparado com *RandomUnderSampler* e *RandomOverSampler*. O algoritmo *PSO* teve o melhor resultado na seleção de atributos, que otimizou parâmetros diminuindo a quantidade de colunas de 5028 para 2014. Por último, a extração de atributos da base de dados teve desempenho superior sendo feita com o janelamento de 5 segundos em comparação ao de 1 segundo.

No entanto, mesmo com todas essas otimizações e aplicações de técnicas pré-processamento, o desafio persiste no que diz respeito ao grupo de idosos. Apesar das melhorias significativas em termos de precisão com essa configuração específica, o resultado ainda atingiu um patamar nada agradável em termos de previsão do alvo deste grupo. Isso sinaliza que existem fatores intrínsecos aos padrões cardíacos dos idosos saudáveis no contexto de frequência e localização de sinal que demandam uma análise mais aprofundada e talvez abordagens mais específicas para aumentar a assertividade.

Figura 15: Comparativo de novos resultados com seleção de atributos



Fonte: Elaborado pelo próprio autor (2023)

5 CONCLUSÃO E TRABALHOS FUTUROS

O avanço tecnológico da inteligência artificial tem desempenhado um papel fundamental ao tornar a medicina mais eficiente e precisa. No entanto, quando se trata de aplicar modelos de aprendizado de máquina para prever grupos de idade com base em ECG, surge um desafio distinto e complexo. Este trabalho buscou explorar essa complexidade, com o objetivo específico de compreender a viabilidade de diferenciar com precisão grupos de adultos e idosos saudáveis por meio de características extraídas desses sinais. A fim de validar a nítida detecção de alterações cardiovasculares normais através unicamente da frequência e localização dos sinais. Diversas conclusões puderam ser obtidas e serão apresentadas a seguir.

5.1 Desempenho do modelo

Foi observado que empregando técnicas do campo de aprendizado supervisionado, especificamente os modelos de Máquina de Vetores de Suporte e Floresta Aleatória, foi obtido percepções importantes sobre a relação entre características cardiovasculares e a idade das pessoas. A análise comparativa dos resultados revelou que, enquanto ambos os modelos apresentaram desempenho semelhante, a Floresta Aleatória demonstrou superioridade, indicando sua capacidade de capturar padrões mais complexos nos dados.

No entanto, é notável que, apesar dos esforços empreendidos no pré-processamento dos dados, incluindo normalização, balanceamento de classes e seleção de atributos, não foi possível atingir resultados satisfatórios na previsão do grupo de idosos. A precisão máxima alcançada para esse grupo foi de apenas 0.2, sugerindo que as alterações cardiovasculares inerentes ao processo de envelhecimento não foram tão discerníveis por meio das características extraídas escolhidas quanto às variações associadas aos adultos. Indicando que os padrões de frequência e localização não foram suficientes para diferenciar grupos de idades.

O processo de seleção de atributos se mostrou crucial para melhorar o desempenho na previsão do grupo de idosos, sugerindo que determinadas características extraídas dos sinais desempenham um papel mais significativo na diferenciação etária em certos grupos. Portanto, explorar mais a fundo quais são essas características e como elas se correlacionam com as alterações cardiovasculares associadas ao envelhecimento pode ser

útil para futuros estudos.

Uma observação relevante é que o desequilíbrio entre as classes de adultos e idosos pode ter influenciado os resultados, já que o grupo de adultos que representou a grande maioria dos voluntários teve um alto nível de acurácia na previsão. Por outro lado, o grupo de idosos, embora tenha passado pelo processo de balanceamento, continuou a apresentar resultados desafiadores, inferindo que esse desequilíbrio intrínseco às classes pode ter dificultado a capacidade dos modelos de generalizar as características distintivas do grupo de idosos.

5.2 Complexidade do problema

Embora os métodos não tenham alcançado desempenho satisfatório na previsão dos grupos de idosos via sinais de ECG, esses resultados são importantes para indicar que a complexidade das variações cardiovasculares associadas ao envelhecimento exige abordagens mais elaboradas. Ao continuar a explorar as relações entre ECG, envelhecimento e saúde cardiovascular, podemos aprimorar as técnicas de análise e considerar fatores adicionais para alcançar uma previsão mais precisa das idades de indivíduos saudáveis. Pode-se investir ainda em abordagens de aprendizagem profunda, visto que podem lidar melhor com problemas de maior complexidade. Dessa forma, avançamos rumo a uma compreensão mais abrangente dos processos cardíacos em diferentes fases da vida.

O fato que nenhum dos trabalhos relacionados citados neste trabalho não tem temática voltado para envelhecimento ou indivíduos saudáveis também enfatiza a singularidade e a relevância do trabalho realizado, uma vez que abordou uma lacuna significativa na literatura científica. Ao direcionar a atenção para a complexidade das mudanças no ECG em relação à idade em indivíduos saudáveis, este estudo oferece uma base sólida para futuras pesquisas.

Essa pesquisa contribui para um avanço significativo na compreensão dos processos cardíacos em diferentes fases da vida, que podem beneficiar não apenas a previsão da idade em indivíduos saudáveis, mas também o desenvolvimento de estratégias mais eficazes para a promoção da saúde cardiovascular ao longo do envelhecimento.

5.3 Trabalhos futuros

Com o objetivo de expandir e aprofundar o tema em questão, como trabalhos futuros, sugere-se:

- Realizar investigações mais aprofundadas para identificar e desenvolver características específicas dos sinais de ECG que melhor capturem as nuances das alterações cardiovasculares relacionadas ao envelhecimento.
- Enriquecer o conjunto de recursos e potencialmente melhorar a capacidade de previsão de grupos etários ao incorporar dados de diferentes modalidades, como informações clínicas ou dados de imagem cardíaca.
- Explorar outros modelos de aprendizado de máquina e até mesmo abordagens baseadas em redes neurais, além de SVM e Floresta Aleatória, para avaliar se são mais adequados para a tarefa em questão. Sugere-se ainda avaliações de desempenhos de redes convolutivas, visto que têm se destacado na resolução de problemas complexos.
- Reduzir os efeitos do desequilíbrio de classes e possibilitar uma análise mais precisa das características associadas ao envelhecimento ao expandir a amostra, com um foco particular na inclusão de dados de idosos em maior quantidade.
- Conduzir testes em um conjunto independente de dados clínicos para validar a aplicabilidade clínica do modelo desenvolvido, avaliando como ele se comporta em situações do mundo real.
- Contribuir para aprimorar a previsão de grupos etários ao incorporar informações temporais dos sinais de ECG, como análise de padrões de variabilidade da frequência cardíaca ao longo do tempo.
- Expandir o escopo da pesquisa para incluir a análise de sinais voltados à indivíduos que possuem condições cardíacas específicas ou patologias, como arritmias investigando como pode ser aplicada para identificar e caracterizar essas condições.

REFERÊNCIAS

- [1] KHAW, K.-T. Healthy aging. *Bmj*, British Medical Journal Publishing Group, v. 315, n. 7115, p. 1090–1096, 1997.
- [2] PARADELLA, R. *Número de idosos cresce 18% em 5 anos e ultrapassa 30 milhões em 2017*. 2018. Acesso em 27 de nov. 2023. Available at: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/20980-numero-de-idosos-cresce-18-em-5-anos-e-ultrapassa-30-milhoes-em-2017>.
- [3] NOORBAKHS-SABET, N. et al. Artificial intelligence transforms the future of health care. *The American journal of medicine*, Elsevier, v. 132, n. 7, p. 795–801, 2019.
- [4] RAMESH, A. et al. Artificial intelligence in medicine. *Annals of the Royal College of Surgeons of England*, Royal College of Surgeons of England, v. 86, n. 5, p. 334, 2004.
- [5] JURADO, I. C. et al. Interpretable assessment of st-segment deviation in ecg time series. *Sensors*, v. 22, n. 13, 2022. ISSN 1424-8220. Available at: <https://www.mdpi.com/1424-8220/22/13/4919>.
- [6] RAHMAN, A. et al. Ecg classification for detecting ecg arrhythmia empowered with deep learning approaches. *Computational Intelligence and Neuroscience*, v. 2022, p. 1–12, 07 2022.
- [7] WANG, L.-H. et al. Three-heartbeat multilead ecg recognition method for arrhythmia classification. *IEEE Access*, v. 10, p. 44046–44061, 2022.
- [8] XU, S. S.; MAK, M.-W.; CHEUNG, C.-C. Towards end-to-end ecg classification with raw signal extraction and deep neural networks. *IEEE Journal of Biomedical and Health Informatics*, v. 23, n. 4, p. 1574–1584, 2019.
- [9] ALBERDI, A.; AZTIRIA, A.; BASARAB, A. Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review. *Journal of biomedical informatics*, Elsevier, v. 59, p. 49–75, 2016.

- [10] TSENG, K.-K. et al. Clustering analysis of aging diseases and chronic habits with multivariate time series electrocardiogram and medical records. *Frontiers in Aging Neuroscience*, v. 12, 2020. ISSN 1663-4365. Available at: <<https://www.frontiersin.org/articles/10.3389/fnagi.2020.00095>>.
- [11] WALKER, A. *Why involve older people in research?* [S.l.]: Oxford University Press, 2007. 481–483 p.
- [12] XU, X.; JEONG, S.; LI, J. Interpretation of electrocardiogram (ecg) rhythm by combined cnn and bilstm. *IEEE Access*, v. 8, p. 125380–125388, 2020.
- [13] LEE, C. H.; KIM, S. H. Ecg measurement system for vehicle implementation and heart disease classification using machine learning. *IEEE Access*, v. 11, p. 17968–17982, 2023.
- [14] STRODTHOFF, N. et al. Deep learning for ecg analysis: Benchmarks and insights from ptb-xl. *IEEE Journal of Biomedical and Health Informatics*, v. 25, n. 5, p. 1519–1528, 2021.
- [15] ZAREI, A.; ASL, B. M. Automatic detection of obstructive sleep apnea using wavelet transform and entropy-based features from single-lead ecg signal. *IEEE Journal of Biomedical and Health Informatics*, v. 23, n. 3, p. 1011–1021, 2019.
- [16] BUTT, F. S. et al. Fall detection from electrocardiogram (ecg) signals and classification by deep transfer learning. *Information*, v. 12, n. 2, 2021. ISSN 2078-2489. Available at: <<https://www.mdpi.com/2078-2489/12/2/63>>.
- [17] JIAO, Y.; QI, H.; WU, J. Capsule network assisted electrocardiogram classification model for smart healthcare. *Biocybernetics and Biomedical Engineering*, v. 42, n. 2, p. 543–555, 2022. ISSN 0208-5216. Available at: <<https://www.sciencedirect.com/science/article/pii/S0208521622000328>>.
- [18] MANIK, A.; ADIWIJAYA, K.; UTAMA, D. Classification of electrocardiogram signals using principal component analysis and levenberg marquardt backpropagation for detection ventricular tachyarrhythmia. *Journal of Data Science and Its Applications*, v. 2, p. 78–87, 04 2019.

- [19] ZHENG, J. et al. Optimal multi-stage arrhythmia classification approach. *Scientific Reports*, v. 10, 02 2020.
- [20] ARQUILLA, K.; WEBB, A.; ANDERSON, A. Utility of the full ecg waveform for stress classification. *Sensors*, v. 22, p. 7034, 09 2022.
- [21] CHEN, L. et al. Ecg signal-enabled automatic diagnosis technology of heart failure. *Journal of Healthcare Engineering*, v. 2021, 2021.
- [22] ERMINDA, J. Processo de envelhecimento. In: _____. *O idoso: problemas e realidade*. [S.l.]: Formasau, 1999. p. 45–59.
- [23] HOYER, W.; ROODIN, P. *Adult Development and Aging*. [S.l.]: McGraw-Hill, 2003. ISBN 9780697362025.
- [24] AMARYA, S.; SINGH, K.; SABHARWAL, M. Ageing process and physiological changes. In: D'ONOFRIO, G.; GRECO, A.; SANCARLO, D. (Ed.). *Gerontology*. Rijeka: IntechOpen, 2018. cap. 1. Available at: <<https://doi.org/10.5772/intechopen.76249>>.
- [25] MONACO, T. O.; SILVEIRA, P. S. P. Aging is not senescence: a short computer demonstration and implications for medical practice. *Clinics*, Faculdade de Medicina / USP, v. 64, n. 5, p. 451–457, May 2009. ISSN 1807-5932. Available at: <<https://doi.org/10.1590/S1807-59322009000500013>>.
- [26] CIOSAK, S. I. et al. Senescência e senilidade: novo paradigma na atenção básica de saúde. *Revista da Escola de Enfermagem da USP*, Universidade de São Paulo, Escola de Enfermagem, v. 45, n. spe2, p. 1763–1768, Dec 2011. ISSN 0080-6234. Available at: <<https://doi.org/10.1590/S0080-62342011000800022>>.
- [27] CHEITLIN, M. D. Cardiovascular physiology—changes with aging. *The American Journal of Geriatric Cardiology*, v. 12, n. 1, p. 9–13, 2003. Available at: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1076-7460.2003.01751.x>>.
- [28] CEFALU, C. A. Theories and mechanisms of aging. *Clinics in Geriatric Medicine*, v. 27, n. 4, p. 491–506, 2011. ISSN 0749-0690. Successful Aging. Available at: <<https://www.sciencedirect.com/science/article/pii/S0749069011000395>>.

- [29] STRATTON, J. R. et al. Effects of aging on cardiovascular responses to parasympathetic withdrawal. *Journal of the American College of Cardiology*, v. 41, n. 11, p. 2077–2083, 2003. ISSN 0735-1097. Available at: <<https://www.sciencedirect.com/science/article/pii/S0735109703004182>>.
- [30] JÚNIOR, L. M. O envelhecimento e o coração: as valvas. *Revista da Faculdade de Ciências Médicas de Sorocaba*, v. 18, n. 1, p. 58–59, 2016.
- [31] WINSTON, P. H. *Artificial intelligence*. [S.l.]: Addison-Wesley Longman Publishing Co., Inc., 1992.
- [32] HAMET, P.; TREMBLAY, J. Artificial intelligence in medicine. *Metabolism*, Elsevier, v. 69, p. S36–S40, 2017.
- [33] BASU, J. K.; BHATTACHARYYA, D.; KIM, T.-h. Use of artificial neural network in pattern recognition. *International journal of software engineering and its applications*, v. 4, n. 2, 2010.
- [34] SCHROUFF, J. et al. Pronto: Patter recognition for neuroimaging toolbox. *Neuroinformatics*, v. 11, 02 2013.
- [35] JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. *Machine learning and deep learning*. 04 2021.
- [36] BADILLO, S. et al. An introduction to machine learning. *Clinical pharmacology & therapeutics*, Wiley Online Library, v. 107, n. 4, p. 871–885, 2020.
- [37] HARRISON, M. *Machine Learning Pocket Reference: Working with Structured Data in Python*. O'Reilly Media, 2019. ISBN 9781492047513. Available at: <<https://books.google.com.br/books?id=RoirDwAAQBAJ>>.
- [38] GUPTA, V. et al. An overview of supervised machine learning algorithm. In: *2022 11th International Conference on System Modeling Advancement in Research Trends (SMART)*. [S.l.: s.n.], 2022. p. 87–92.
- [39] JHA, K. K. et al. A brief comparison on machine learning algorithms based on various applications: A comprehensive survey. In: *2021 IEEE International Conference on*

- Computation System and Information Technology for Sustainable Solutions (CSITSS)*. [S.l.: s.n.], 2021. p. 1–5.
- [40] BONACCORSO, G. *Machine learning algorithms*. [S.l.]: Packt Publishing Ltd, 2017.
- [41] CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, p. 273–297, 1995.
- [42] SALZBERG, S. L. *C4. 5: Programs for machine learning by j. ross quinlan. morgan kaufmann publishers, inc., 1993*. [S.l.]: Kluwer Academic Publishers, 1994.
- [43] BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, p. 5–32, 2001.
- [44] QI, Y. Random forest for bioinformatics. In: *Ensemble machine learning: Methods and applications*. [S.l.]: Springer, 2012. p. 307–323.
- [45] ALI, J. et al. Random forests and decision trees. *International Journal of Computer Science Issues (IJCSI)*, International Journal of Computer Science Issues (IJCSI), v. 9, n. 5, p. 272, 2012.
- [46] JIAO, Y.; DU, P. Performance measures in evaluating machine learning based bioinformatics predictors for classifications. *Quantitative Biology*, Springer, v. 4, p. 320–330, 2016.
- [47] RUUSKA, S. et al. Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural processes*, Elsevier, v. 148, p. 56–62, 2018.
- [48] MANDREKAR, J. N. Receiver operating characteristic curve in diagnostic test assessment. *Journal of Thoracic Oncology*, Elsevier, v. 5, n. 9, p. 1315–1316, 2010.
- [49] HOO, Z. H.; CANDLISH, J.; TEARE, D. *What is an ROC curve?* [S.l.]: BMJ Publishing Group Ltd and the British Association for Accident . . . , 2017. 357–359 p.