



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE SOBRAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO (PPGEEC)

RENAN HENRIQUE CARDOSO

DETECÇÃO DE FIBRILAÇÃO ATRIAL EM ECG COM O USO DA DECOMPOSIÇÃO
TENSORIAL BTD

SOBRAL

2024

RENAN HENRIQUE CARDOSO

DETECÇÃO DE FIBRILAÇÃO ATRIAL EM ECG COM O USO DA DECOMPOSIÇÃO
TENSORIAL BTD

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) do Campus de Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Aprendizado de Máquina em Saúde Digital.

Orientador: Prof. Dr. Carlos Alexandre Rolim Fernandes.

Coorientador: Dr. Pedro Marinho Ramos de Oliveira.

SOBRAL

2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

C266d Cardoso, Renan Henrique.
DETECÇÃO DE FIBRILAÇÃO ATRIAL EM ECG COM O USO DA DECOMPOSIÇÃO TENSORIAL
BTD / Renan Henrique Cardoso. – 2024.
101 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação
em Engenharia Elétrica e de Computação, Sobral, 2024.

Orientação: Prof. Dr. Carlos Alexandre Rolim Fernandes.

Coorientação: Prof. Dr. Pedro Marinho Ramos de Oliveira.

1. Fibrilação Atrial. 2. Decomposição Tensorial. 3. Eletrocardiograma. 4. Detecção Automática. 5.
Aprendizado de Máquina. I. Título.

CDD 621.3

RENAN HENRIQUE CARDOSO

DETECÇÃO DE FIBRILAÇÃO ATRIAL EM ECG COM O USO DA DECOMPOSIÇÃO
TENSORIAL BTD

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) do Campus de Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Aprendizado de Máquina em Saúde Digital.

Aprovada em: 27/05/2024.

BANCA EXAMINADORA

Prof. Dr. Carlos Alexandre Rolim
Fernandes (Orientador)
Universidade Federal do Ceará (UFC)

Dr. Pedro Marinho Ramos de
Oliveira (Coorientador)

Profª. Dra. Jermana Lopes de Moraes
Universidade Federal do Ceará (UFC)

Prof. Dr. Douglas Almonfrey
Instituto Federal de Educação, Ciência e Tecnologia
do Espírito Santo (IFES)

Este trabalho é dedicado ao meu filho, José Henrique, ao meu pai, Antônio José, e à minha mãe, Débora Angélica.

AGRADECIMENTOS

Ao meu filho, José Henrique, que é a luz da minha vida. Seus abraços apertados são os motores que aquecem o meu coração.

Aos meus pais, Antônio e Débora, pelo apoio incondicional em todos os momentos da minha trajetória acadêmica e formação como ser humano. Sem eles, nada seria possível.

Ao meu Professor e orientador, Carlos Alexandre, sou grato por todo o suporte e paciência neste trabalho. Minha admiração é tão grande quanto a sua valiosa orientação.

Ao meu coorientador, Pedro Marinho, pelas discussões e valiosas colaborações, e por estar sempre disponível.

Por fim, agradeço a todos que acreditam em uma universidade pública, gratuita e de qualidade.

RESUMO

A Fibrilação Atrial (FA) é uma arritmia cardíaca comum associada a diversas doenças cardiovasculares e tem impacto significativo na mortalidade em todo o mundo. Este trabalho tem como foco a detecção de FA utilizando dados coletados do monitoramento cardíaco por meio do Eletrocardiograma (ECG), propondo novos atributos para predição de FA. Em particular, o presente trabalho propõe a utilização de indicadores de convergência e otimização da decomposição em termos de bloco, ou *Block-Term Decomposition* (BTD). Essas informações serão combinadas com os *R-R Intervals* (RRIs) do ECG, recurso amplamente explorado em trabalhos relacionados para detecção de FA e outras arritmias. Este conjunto de recursos permitiu a detecção e diagnóstico precoce de FA usando algoritmos de aprendizado de máquina que realizaram a tarefa de classificação binária entre um sinal saudável, rotulado como *Normal Sinus Rhythm* (NSR), ou com FA. O estudo também discute a aquisição de dados de três bancos de dados de ECG distintos: *Atrial Fibrillation Database* (AFDB), *Long-term Atrial Fibrillation Database* (LTAfDB) e *Normal Sinus Rhythm Database* (NSRDB). Este conjunto de bases de dados possibilitou a investigação cujo objetivo foi validar o método proposto e indicar direções futuras para o aprimoramento da técnica. Os resultados obtidos demonstram o desempenho da abordagem apresentada para a detecção de FA na base de teste, atingindo uma acurácia de 97,04%, sensibilidade de 97,44% e especificidade de 96,59%. Esses resultados destacam o potencial do método para integração em dispositivos de monitoramento destinados ao diagnóstico de condições cardíacas.

Palavras-chave: Fibrilação Atrial; Decomposição Tensorial; Eletrocardiograma; Detecção Automática; Aprendizado de Máquina .

ABSTRACT

The Atrial Fibrillation (AF) is a common cardiac arrhythmia associated with various cardiovascular diseases and has a significant impact on mortality worldwide. This work focuses on AF detection using data collected from cardiac monitoring through Eletrocardiogram (ECG), proposing new attributes for AF prediction. In particular, the present work proposes the use of convergence and optimization indicators of the Block-term Decomposition (BTD). This information will be combined with the R-R Intervals (RRIs) from ECG, a feature widely explored in related works for AF and other arrhythmias detection. This set of features enabled the early detection and diagnosis of AF using machine learning algorithms that performed the binary classification task between a healthy signal, labeled as Normal Sinus Rhythm (NSR), or with AF. The study also discusses the data acquisition from three different ECG databases: Atrial Fibrillation Database (AFDB), Long-term Atrial Fibrillation Database (LTAfDB) e Normal Sinus Rhythm Database (NSRDB). This set of databases provided the investigation that aimed to validate the proposed method and indicate future directions for technique improvement. The results obtained demonstrate the effectiveness of the presented approach for detecting FA in the test base, reaching an accuracy of 97.04%, sensitivity of 97.44% and specificity of 96.59%. These results highlight the potential of the method for integration into monitoring devices intended for diagnosing cardiac conditions.

Palavras-chave: Atrial Fibrillation; Tensor Decomposition; Eletrocardiogram; Automatic Detection; Machine Learning .

LISTA DE FIGURAS

Figura 1 – O sistema circulatório humano.	22
Figura 2 – A anatomia do coração humano.	24
Figura 3 – O sistema de condução do coração.	25
Figura 4 – O dipolo através do coração.	26
Figura 5 – Um sinal de ECG típico de um batimento cardíaco.	27
Figura 6 – O ECG 12 derivações.	27
Figura 7 – As derivações bipolares DI, DII e DIII.	28
Figura 8 – As derivações unipolares aVR, aVL e aVF.	28
Figura 9 – As derivações precordiais.	29
Figura 10 – Os picos de ondas R destacadas em um segmento de ECG diagnosticado com FA.	30
Figura 11 – ECG: Fibrilação atrial com ritmo irregular comparada a flutuação atrial com ondas regulares.	31
Figura 12 – Visualização vetorial ilustrativa da condição de FA no coração.	32
Figura 13 – Fatias de um tensor \mathcal{X} de ordem 3.	35
Figura 14 – O processo de matricização de um tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times I_3}$	36
Figura 15 – Representação visual do processo de decomposição PARAFAC.	38
Figura 16 – Representação visual do processo de decomposição <i>Tucker</i>	38
Figura 17 – Representação visual da decomposição BTD em termos de <i>rank</i> $(L_r, L_r, 1)$	39
Figura 18 – Aplicação de tensorização no contexto de sinais de ECG.	41
Figura 19 – Curva ROC.	46
Figura 20 – Sinal de ECG com ruído Eletromiográfico (EMG).	50
Figura 21 – Sinal de ECG com ruído interferência da linha de energia.	50
Figura 22 – Sinal de ECG com deslocamento da linha da base.	50
Figura 23 – Análise final do mapa dividido em painéis de grade (com resolução fixa de 20 ms no eixo y e comprimento de passo de 15 a 60 s no eixo x).	53
Figura 24 – A média dos histogramas de RRIs.	54
Figura 25 – Sinais observados e estimados a partir da derivação V1.	57
Figura 26 – Contribuição obtida e estimada das fontes atriais para a derivação V1.	58

Figura 27 – Panorama da metodologia proposta.	60
Figura 28 – Procedimentos voltados para a coleta e preparação dos vetores de entrada. . .	62
Figura 29 – Um trecho de sinal diagnosticado com FA composto por 5 batimentos. . . .	63
Figura 30 – Distribuição (em termos de porcentagem) da quantidade total de segmentos coletados.	64
Figura 31 – Procedimentos voltados para a preparação dos vetores de características. . .	65
Figura 32 – Evolução dos valores de cada parâmetro BTM.	70
Figura 33 – Pontuações médias de relevância das características em <i>XGBoost</i> para detecção de FA.	70
Figura 34 – Histogramas obtidos a partir do parâmetro <i>relerr</i> para as classes FA e NSR. . .	71
Figura 35 – Abordagem elaborada para ajuste de hiperparâmetros.	72
Figura 36 – Abordagem para obtenção dos resultados com validação cruzada.	74
Figura 37 – Comparação dos classificadores com os resultados da validação cruzada. . .	76
Figura 38 – <i>Boxplots</i> comparativos das simulações com e sem ajuste dos hiperparâmetros (<i>Boosting</i> de Gradiente).	78
Figura 39 – <i>Boxplots</i> comparativos das simulações com e sem ajuste dos hiperparâmetros (Floresta Aleatória).	79
Figura 40 – <i>Boxplots</i> comparativos das simulações com e sem ajuste dos hiperparâmetros (Árvores Extremamente Aleatórias)	79
Figura 41 – <i>Boxplots</i> comparativos das simulações com e sem ajuste dos hiperparâmetros (<i>Boosting</i> de Gradiente Extremo).	79
Figura 42 – <i>Boxplots</i> comparativos das simulações com e sem ajuste dos hiperparâmetros (Máquina de <i>Boosting</i> de Gradiente Leve).	80
Figura 43 – Abordagem para obtenção dos resultados finais.	81
Figura 44 – Comparação dos classificadores com os resultados finais.	82
Figura 45 – Curvas ROC obtidas de todos os algoritmos.	83
Figura 46 – Comparativo entre as configurações de características (classificadores). . . .	86
Figura 47 – Comparativo entre as configurações de características (variação na porção de treinamento).	87

LISTA DE TABELAS

Tabela 1 – Matriz de confusão.	44
Tabela 2 – Tipos comuns de ruídos em ECG e soluções potenciais de filtragem.	51
Tabela 3 – Resultados dos trabalhos relacionados (em ordem cronológica crescente).	55
Tabela 4 – Total dos vetores de entrada extraídos (por diagnóstico) das bases de dados selecionadas.	64
Tabela 5 – Distribuição dos vetores de características prontos para validação (separados por gravação).	66
Tabela 6 – Especificações da função <i>lll_rnd</i> (Tensorlab).	68
Tabela 7 – Especificações da função <i>lll_nls</i> (Tensorlab).	69
Tabela 8 – Parametrização dos classificadores.	73
Tabela 9 – Resultados obtidos com hiperparâmetros ajustados.	75
Tabela 10 – Matriz de confusão com os resultados da validação cruzada.	76
Tabela 11 – Resultados obtidos com hiperparâmetros padrão.	77
Tabela 12 – Resultados finais.	81
Tabela 13 – Resultado conclusivo alcançado nesta pesquisa.	84
Tabela 14 – Matriz de confusão.	84
Tabela 15 – Resultados dos trabalhos relacionados (em ordem cronológica crescente).	85
Tabela 16 – Métricas de avaliação obtidas a partir do intervalo de confiança 95%.	85

LISTA DE ABREVIATURAS E SIGLAS

AA	Atividade Atrial
ACC	Acurácia
ADB	<i>Arrhythmia Database</i>
AFDB	<i>Atrial Fibrillation Database</i>
AGL	<i>Alternating Group Lasso</i>
ALS	<i>Alternating Least Squares</i>
ALS-ELS	<i>Alternating Least Squares - Enhanced Line Search</i>
AUC	<i>Area Under the ROC Curve</i>
AV	Atividade Ventricular
BSS	<i>Blind Source Separation</i>
BTD	<i>Block-Term Decomposition</i>
CAGL	<i>Constrained Alternating Group Lasso</i>
CNN	<i>Convolutional Neural Network</i>
CPD	<i>Canonical Polyadic Decomposition</i>
ECG	Eletrocardiograma
EMG	Eletromiográfico
FA	Fibrilação Atrial
FN	Falso Negativo
FP	Falso Positivo
HMM	<i>Hidden Markov Models</i>
HRV	<i>Heart Rate Variability</i>
ICA	<i>Independent Component Analysis</i>
LCAGL	<i>Löwner Constrained Alternating Group Lasso</i>
LightGBM	<i>Light Gradient Boosting Machine</i>
LSVM	<i>Linear Support Vector Machine</i>
LTAFDB	<i>Long-term Atrial Fibrillation Database</i>
MIT-BIH	<i>Massachusetts Institute of Technology - Beth Israel Hospital</i>
NLS	<i>Nonlinear Least Squares</i>
NSR	<i>Normal Sinus Rhythm</i>
NSRDB	<i>Normal Sinus Rhythm Database</i>

PCA	<i>Principal Component Analysis</i>
RNN	<i>Recurrent Neural Network</i>
ROC	<i>Receiver Operating Characteristic</i>
RRI	<i>R-R Interval</i>
SEN	Sensibilidade
SPE	Especificidade
SVM	<i>Support Vector Machine</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
XGB	<i>Extreme Gradient Boosting</i>

LISTA DE SÍMBOLOS

\mathbf{v}	Vetor
\mathbf{M}	Matrix
\mathcal{T}	Tensor
\mathcal{G}	Tensor Núcleo
R	Rank de um Tensor
L_r	Rank da matriz fator

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Organização do trabalho	18
2	OBJETIVOS	20
2.1	Objetivos Gerais	20
2.2	Objetivos Específicos	20
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	Sistema Cardiovascular	21
3.1.1	<i>Sangue</i>	22
3.1.2	<i>Vasos sanguíneos</i>	22
3.1.3	<i>Coração</i>	23
3.2	Sistema de Condução e Eletrocardiograma (ECG)	24
3.2.1	<i>Eletrocardiograma (ECG)</i>	25
3.3	Intervalos R-R	29
3.4	Arritmias Cardíacas	30
3.5	A Fibrilação Atrial	31
3.5.1	<i>Impacto Clínico</i>	32
3.5.2	<i>Sintomas</i>	33
3.5.3	<i>Categorização</i>	33
3.5.4	<i>Tratamento</i>	34
3.6	Decomposições Tensoriais	34
3.6.1	<i>Introdução à Álgebra Tensorial</i>	34
3.6.2	<i>Decomposições Tensoriais</i>	37
3.6.3	<i>Decomposição em Termos de Blocos (BTD)</i>	38
3.7	Separação cega de fontes em ECG	40
3.8	Tensorização	41
3.8.1	<i>Hankelização</i>	41
3.8.2	<i>Hankel-BTD</i>	42
3.9	Métricas de Avaliação	43
3.9.1	<i>Matriz de Confusão</i>	43
3.9.2	<i>Métricas Tradicionais</i>	44

3.9.3	<i>Curva ROC</i>	45
3.10	Classificadores	46
4	TRABALHOS RELACIONADOS	48
4.1	Desafios enfrentados na detecção de FA	48
4.2	Estudos relevantes em detecção FA	51
4.2.1	<i>Extração da AA em sinais ECG</i>	55
4.2.2	<i>Aprendizagem Profunda</i>	59
5	TÉCNICA PROPOSTA	60
5.1	Bases de Dados	60
5.2	Pré-processamento	61
5.3	Extração de Características	64
5.3.1	<i>Extração de Características de Convergência da BTD</i>	65
6	RESULTADOS	72
6.1	Configuração dos classificadores	72
6.2	Resultados com Validação Cruzada	74
6.2.1	<i>Comparativo sem etapa de ajuste dos hiperparâmetros</i>	77
6.3	Resultados com dados de teste (<i>hold-out</i>)	80
6.4	Resultado Conclusivo	83
6.4.1	<i>Intervalo de Confiança</i>	85
6.5	Contribuição dos parâmetros BTD	86
7	CONCLUSÃO	88
7.1	Objetivos	88
7.2	Resultados	89
7.3	Trabalhos Futuros	89
	REFERÊNCIAS	90

1 INTRODUÇÃO

As doenças cardiovasculares estão entre as principais causas de mortalidade em todo o mundo, onde cerca de 20,5 milhões de pessoas vieram a óbito em 2021 devido a essas condições cardíacas (Cesare *et al.*, 2024). Algumas dessas doenças são decorrentes de falhas na condução dos estímulos elétricos do coração, conhecidas também como arritmias cardíacas. Estas podem ter implicações clínicas significativas como o aumento do risco de acidente vascular cerebral e insuficiência cardíaca (Lip *et al.*, 2016). Dentre as arritmias, a Fibrilação Atrial (FA) é reconhecida como a arritmia cardíaca mais comum na prática clínica (Morillo *et al.*, 2017), caracterizada pelo comprometimento da contração dos átrios devido à geração e condução anormais dos impulsos elétricos.

Em 2010, nos Estados Unidos, a incidência de FA era de 1,2 milhão de casos, com uma prevalência de 5,2 milhões. Projeta-se que, até 2030, a incidência alcance 2,6 milhões, e a prevalência aumente para 12,1 milhões de pacientes (Colilla *et al.*, 2013). As razões fundamentais ao aumento observado em FA foram atribuídas a combinação de uma maior carga de fatores de risco: um aumento em ocorrências de insuficiência cardíaca, tempos de sobrevivência com doenças cardiovasculares mais longos e envelhecimento da população (Delaney *et al.*, 2018).

Os mecanismos eletrofisiológicos responsáveis por essa condição cardíaca ainda não são completamente compreendidos e muitas pesquisas sobre FA têm sido produzidas nos últimos anos. O diagnóstico inicial da FA é realizado a partir de sintomas específicos, como a dificuldade respiratória, dor no peito e pulso anormal (Mant *et al.*, 2007). Além disso, os sinais de Eletrocardiograma (ECG) são analisados visualmente por cardiologistas, que buscam identificar características que indicam a presença de FA.

A utilização de técnicas computacionais, especificamente métodos derivados do aprendizado de máquina (Rizwan *et al.*, 2021), para a detecção de FA em sinais de ECG, tem demonstrado resultados promissores. Essas técnicas têm trazido um aumento significativo na precisão e na rapidez dos resultados, auxiliando assim o diagnóstico dos profissionais em casos de FA, o que é determinante para a detecção precoce e o tratamento mais adequado para essa condição cardíaca.

Por outro lado, abordagens que exploram decomposições tensoriais usando dados de ECG vêm sendo consideradas nos últimos anos (Oliveira; Zarzoso, 2018a; Oliveira; Zarzoso, 2018b; Oliveira *et al.*, 2021). Resumidamente, um tensor pode ser descrito como um arranjo de dados com ordem maior do que 2, enquanto uma decomposição tensorial é o processo no

qual um tensor é fragmentado em componentes mais simples (matrizes ou vetores) ou em outros tensores. Este método assemelha-se à decomposição de uma matriz em vetores, ou matrizes, mas é adaptado para lidar com as estruturas mais complexas dos tensores.

A aplicação de decomposições tensoriais na análise do sinal de ECG para FA tem sido comparada às técnicas matriciais, em especial a decomposição em termo de bloco, ou do inglês, *Block-Term Decomposition* (BTD), devido às suas características e vantagens notáveis (Oliveira; Zarzoso, 2018a). Esta abordagem tem o potencial de superar as restrições impostas pelas decomposições matriciais, garantindo a sua unicidade em condições mais relaxadas (Oliveira *et al.*, 2021). Além disso, a estabilidade temporal da BTD na análise de FA tem sido enfatizada, ressaltando ainda mais os benefícios potenciais dos métodos de decomposição tensorial neste domínio (Oliveira; Zarzoso, 2018b). No geral, o uso da BTD na análise do sinal de ECG para FA apresenta uma abordagem promissora para a extração e análise da Atividade Atrial (AA), sobretudo para a realização da tarefa de separação cega de fontes, ou do inglês, *Blind Source Separation* (BSS), oferecendo estabilidade temporal, unicidade essencial e aplicações potenciais no diagnóstico e pesquisa em FA de forma não invasiva.

Até o momento, as técnicas tensoriais envolvendo a BTD têm sido utilizadas restritamente em problemas relacionados à separação de fontes em sinais de ECG, onde as fontes identificadas como FA são posteriormente analisadas de forma clínica. O presente trabalho propõe uma nova aplicação dessa abordagem, pois, em vez de realizar separação das fontes do sinal de ECG, serão analisados os parâmetros de convergência gerados pela BTD para aprimorar a detecção de FA. Em outras palavras, os parâmetros de convergência da decomposição Hankel-BTD serão usados como atributos de entrada de métodos do aprendizado de máquina que irão detectar a FA.

A motivação por trás desta hipótese é que a decomposição tensorial Hankel-BTD com sinais ECG só possui garantia de unicidade quando aplicada em sinais com presença de FA. Isso se deve ao fato de que, quando o sinal ECG possui FA, as fontes atriais presentes podem ser modeladas por modelos do tipo só-polos (*all-pole filters*), também conhecidos como modelo exponencial (Zarzoso, 2017). Esta modelagem das fontes atriais, por sua vez, garante que as condições de unicidade da decomposição Hankel-BTD sejam satisfeitas.

De fato, pode-se demonstrar que, quando quando as fontes atriais são aproximadas por modelos tipo só-polos, as matrizes de Hankel, usadas no método Hankel-BTD, podem ser expressas através da decomposição de Vandermonde, garantindo que as matrizes de Hankel

tenham posto completo, tal como descrito em (Zarzoso, 2017). Isto permite que se encontre condições que garantem a unicidade da decomposição Hankel-BTD.

Por outro lado, quando o sinal ECG não possui FA, não há garantia unicidade da decomposição tensorial Hankel-BTD. Desta forma, a abordagem proposta no presente trabalho fundamenta-se na hipótese de que a decomposição Hankel-BTD de um segmento de ECG diagnosticado com FA é executado de forma mais eficiente do que quando não há FA. Um segmento de ritmo cardíaco saudável tenderia a convergir com desempenho insatisfatório. Essa variação na convergência entre um segmento com FA e outro em ritmo saudável se manifestaria nos indicadores obtidos após a execução do algoritmo. Ao todo, sete parâmetros de convergência foram coletados e explorados neste trabalho, que são descritos em mais detalhes na Seção 5.3.1. Essa abordagem representa uma nova contribuição para a detecção de FA em sinais de ECG, pois revelam características intrínsecas ao sinal com FA, permitindo uma posterior discriminação entre segmentos de sinais saudáveis e com a condição.

Por sua vez, os intervalos R-R, ou *R-R Intervals* (RRIs), que representam os intervalos entre sucessivas ondas R no sinal de ECG, têm se mostrado uma abordagem promissora na identificação de irregularidade no ritmo cardíaco associada à FA. Sendo amplamente utilizados na literatura para abordar o problema de detecção mencionado (Tateno; Glass, 2001).

Dessa forma, esta pesquisa propõe a elaboração de um vetor de atributos composto pela combinação dos indicadores que foram obtidos através da aplicação da BTD em um segmento pré-processado de ECG, juntamente com os RRIs deste mesmo segmento. Mais especificamente, para a BTD, será utilizada a técnica Hankel-BTD, que envolve a construção de um tensor a partir da matriz de Hankel e, em seguida, a aplicação da decomposição, para posterior obtenção das variáveis de interesse geradas durante o cálculo. Estes dois tipos de atributos (parâmetros de convergência da BTD e os RRIs), quando aplicados em conjunto, podem fornecer uma robusta informação discriminatória para a detecção de FA. Além disso, algoritmos baseados em árvore foram empregados para realizar uma classificação binária nos segmentos como indicativos, ou não indicativos, de FA. Este estudo fez uso das técnicas: Floresta Aleatória, Árvores Extremamente Aleatórias, *Boosting* de Gradiente, *Boosting* de Gradiente Extremo e a Máquina de *Boosting* de Gradiente Leve (Ke *et al.*, 2017).

Para validar a detecção proposta de FA desta pesquisa, foi destacada as bases de dados elaboradas pelo Instituto de Tecnologia de *Massachusetts*, conhecidas na literatura em inglês como *Massachusetts Institute of Technology - Beth Israel Hospital* (MIT-BIH), as quais

constituem um conjunto de dados voltado para pesquisadores e profissionais nos campos da cardiologia e do processamento de sinais. Diante disso, foram selecionados três conjuntos de dados para garantir a robustez da metodologia que será desenvolvida. As bases selecionadas foram: a *Atrial Fibrillation Database (AFDB)*, *Long-term Atrial Fibrillation Database (LTAfDB)* e *Normal Sinus Rhythm Database (NSRDB)*, provenientes de (Goldberger *et al.*, 2000). Em diferentes estudos relacionados ao tema, enfatiza-se a importância da utilização de bases de dados distintas (Uittenbogaart *et al.*, 2020; Giebel; Gissel, 2019; Tison *et al.*, 2018). Um conjunto diversificado de registros ECG é essencial para validar técnicas de detecção de FA, pois considera diferentes casos e populações, contribuindo assim para melhorar a generalização dos modelos gerados.

A metodologia adotada resultou em 97,04% de acurácia, 97,44% de sensibilidade e 96,59% de especificidade na detecção de FA. Esses resultados evidenciam uma melhoria em relação às abordagens encontradas na literatura e estabelecem um novo padrão na análise de sinais de ECG ao fazer uso dos artefatos da BTd como características para detecção de FA. Dessa forma, a pesquisa sugere um potencial significativo para a implementação de monitoramento de ECG.

1.1 Organização do trabalho

O restante desse trabalho é organizado da seguinte forma:

No **Capítulo 2** é realizada a apresentação dos objetivos deste trabalho, fornecendo um panorama das expectativas estabelecidas para a pesquisa.

Serão expostos no **Capítulo 3** os conceitos fundamentais e necessários para a compreensão do problema que esta pesquisa propõe resolver.

O **Capítulo 4** contextualiza a pesquisa atual, destacando as abordagens recentes na análise de ECG com foco na detecção de FA. Além disso, será realizada uma revisão dos estudos relevantes sobre técnicas tensoriais envolvendo BSS e uma discussão sobre as recentes aplicações da aprendizagem profunda para a detecção de FA.

No **Capítulo 5** são apresentados os detalhes da técnica proposta, onde será exposta uma compreensão da abordagem metodológica adotada neste estudo, destacando suas inovações e relevância para a análise dos sinais cardíacos.

O **Capítulo 6** expõe e discute os resultados desta pesquisa.

E por fim, no **Capítulo 7**, são indicadas as considerações finais e as perspectivas

para futuros desenvolvimentos.

2 OBJETIVOS

Após a elucidação do problemas evidenciados na seção anterior a respeito da FA, e a motivação de utilização de técnicas computacionais para detecção desta condição cardíaca, os objetivos deste trabalho são definidos a seguir.

2.1 Objetivos Gerais

O presente trabalho tem como objetivo principal introduzir um novo método de detecção de FA em monitoramento cardíaco utilizando registros de ECG de 12 derivações. A técnica proposta envolve a extração de características de segmentos coletados destas gravações para uma posterior combinação. Para a análise, são empregados dois tipos distintos de características: as métricas que correspondem aos indicadores de convergência resultantes da execução da BTM, juntamente com os RRIs advindos de um segmento ECG. Essas características extraídas foram obtidas das três bases de dados mencionadas anteriormente, pré-processadas e organizadas em segmentos rotulados e então estruturadas como dados de entrada para um algoritmo discriminador visando uma classificação binária, entre um segmento com FA e outro sem a condição.

2.2 Objetivos Específicos

- Aprimorar a detecção de FA em bases de dados distintas por meio da aplicação de etapas de pré-processamento, tais como filtragem de ruídos, normalização e particionamento temporal do sinal;
- Preparar um repositório de dados a partir dos sinais de ECG provenientes das bases de dados pré-processadas. Este processo também inclui a organização dos segmentos particionados do sinal por paciente, visando análises posteriores.
- Propor como característica discriminante os parâmetros gerados durante a execução do BTM em segmentos de ECG;
- Reproduzir o método de utilização dos RRIs e combiná-lo com as características coletadas do objetivo anterior;
- Realizar uma análise de algoritmos de classificação supervisionada visando diferenciar adequadamente os segmentos de sinal rotulados entre e FA ou em ritmo sinusal normal, do inglês *Normal Sinus Rhythm* (NSR).

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como objetivo fornecer uma base teórica que fundamentará as análises realizadas nesta dissertação. As áreas de estudo abordadas incluem:

- **Sistema Cardiovascular:** Uma exploração do sistema cardiovascular com ênfase na fisiologia do coração, visando proporcionar uma melhor compreensão dos mecanismos e funções cardíacas.
- **Sistema de Condução e o Eletrocardiograma (ECG):** Uma análise do sistema de condução cardíaca e sua avaliação elétrica através do ECG, destacando sua relevância no diagnóstico de arritmias cardíacas.
- **Intervalos R-R:** Uma discussão sobre o que são os RRs, a elaboração e interpretação dos RRs e sua importância clínica na análise do ritmo cardíaco.
- **Arritmias e Fibrilação Atrial (FA):** Um resumo sobre as arritmias cardíacas e, em específico, será enfatizada a FA e uma interpretação de suas características diagnósticas e implicações clínicas.
- **Abordagem Tensorial:** As definições relevantes da álgebra tensorial e as decomposições tensoriais, especialmente a BTD, serão apresentadas. Também serão definidos os conceitos acerca dos problemas que envolvem BSS. Finalmente, a técnica Hankel-BTD será apresentada, demonstrando sua aplicação e integração na análise de sinais ECG.
- **Métricas de Avaliação:** Serão definidas as métricas utilizadas para avaliar o desempenho dos modelos de detecção de FA, incluindo a acurácia, sensibilidade, especificidade e outras métricas relevantes para a análise dos resultados.
- **Classificadores:** Nesta subseção, serão apresentados os algoritmos selecionados para realizar a classificação das características extraídas.

3.1 Sistema Cardiovascular

O sistema cardiovascular, também referido como sistema circulatório, tem como função principal facilitar a transferência de nutrientes, oxigênio, hormônios e resíduos do corpo humano. Este sistema engloba os componentes: sangue, os vasos sanguíneos e o coração (Chaudhry *et al.*, 2022).

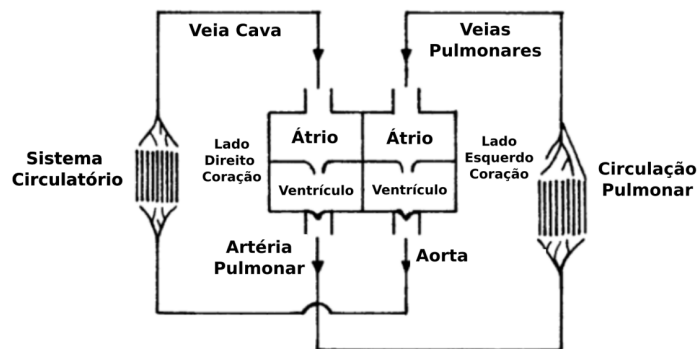
3.1.1 Sangue

O sangue é um tecido vivo que circula por todo o corpo, seu objetivo é manter a homeostase, ou seja, o equilíbrio dos processos fisiológicos, e também tem a função de garantir que todos os órgãos e outros tecidos recebam os nutrientes e oxigênio necessários para funcionarem corretamente. É composto por glóbulos vermelhos, responsáveis pelo transporte de oxigênio; glóbulos brancos, essenciais para a resposta imunitária; plaquetas, cruciais na coagulação do sangue; e plasma, que transporta células sanguíneas e outras substâncias.

3.1.2 Vasos sanguíneos

O sistema de vasos sanguíneos, representado na Figura 1, constitui uma rede complexa para o transporte de sangue e nutrientes por todo o corpo humano, sendo composto por três componentes principais: artérias, veias e capilares, que desempenham um papel essencial na manutenção da homeostase e no funcionamento adequado de todos os sistemas do corpo humano. O equilíbrio dinâmico entre esses componentes promove uma circulação sanguínea saudável e contribui para o bem-estar geral do organismo.

Figura 1 – O sistema circulatório humano.



Fonte: Adaptado de (Noordergraaf, 1978).

A função principal das artérias é transportar sangue rico em oxigênio do coração para os tecidos do corpo. Por exemplo, a aorta, a maior artéria, se ramifica em redes menores para distribuir esse sangue oxigenado, enquanto as veias retornam o sangue pobre em oxigênio de volta ao coração. As artérias também podem transportar sangue venoso, como é o caso da artéria pulmonar, que leva o sangue do ventrículo direito para os pulmões. A veia cava é considerada a maior veia e retorna o sangue ao coração, onde ele é oxigenado nos pulmões, reiniciando o ciclo circulatório. Por último, os capilares, os vasos sanguíneos menores, atuam como pontos de

troca entre o sangue e os tecidos, permitindo a transferência de oxigênio, nutrientes e resíduos (Mitchell; Schoen, 2010). Todo o sistema de vasos sanguíneos também desempenha um papel importante na regulação da temperatura corporal, equilíbrio do pH e resposta imunológica (Thosar *et al.*, 2018).

3.1.3 Coração

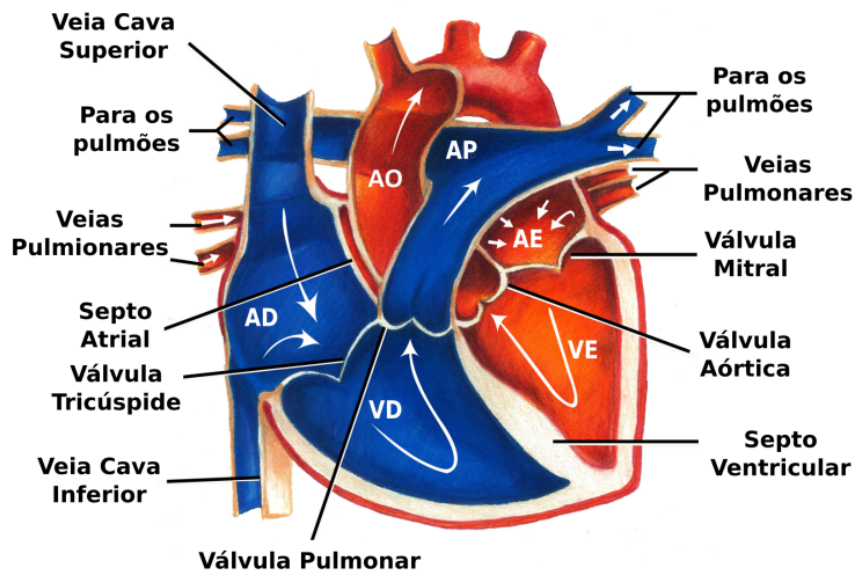
O coração humano, um órgão vital na circulação sanguínea, possui uma anatomia complexa que facilita a separação e movimentação do sangue oxigenado e desoxigenado. A camada da parede cardíaca que desempenha a função de bombeamento do sangue é o miocárdio, um tecido muscular espesso que realiza a contração e o relaxamento do coração, através das diferentes câmaras e válvulas cardíacas (Farrell; Jones, 2023).

O ciclo cardíaco pode ser categorizado em duas fases distintas: sístole e diástole. Durante a sístole, ocorre a contração do miocárdio que resulta no aumento da pressão arterial, que é aferida como a máxima pressão arterial sistólica nas artérias. Por outro lado, a diástole caracteriza-se pelo relaxamento do músculo cardíaco onde a pressão arterial diminui e registra-se a pressão diastólica, que é a leitura mais baixa da pressão arterial nas artérias (Pollock; Makaryus, 2022).

Conforme ilustrado na Figura 2, as regiões coloridas em azul representam as áreas por onde flui o sangue pobre em oxigênio, enquanto as áreas em vermelho indicam a passagem do sangue rico em oxigênio. O fluxo inicia-se com o sangue desoxigenado retornando ao coração pelas veias cavas superior e inferior, entrando no Átrio Direito (AD), identificado na Figura 2 como AD. Este átrio recebe o sangue e o direciona ao Ventrículo Direito (VD) por meio da válvula tricúspide. A válvula pulmonar permite a passagem do sangue para a Artéria Pulmonar (AP), uma vez bombeado pelo VD. Por conseguinte, a AP é o caminho pelo qual o sangue desoxigenado é transportado para os pulmões, onde ocorre a oxigenação sanguínea.

Após a oxigenação nos pulmões, o sangue oxigenado retorna ao coração pelas veias pulmonares, alcançando o Átrio Esquerdo (AE). O AE coleta e encaminha o sangue através da válvula mitral para o Ventrículo Esquerdo (VE), que se caracteriza como uma câmara muscular responsável por impulsionar o sangue oxigenado para a Aorta (AO), através da válvula aórtica. A AO, então, distribui o sangue oxigenado para todo o corpo, fornecendo oxigênio e nutrientes essenciais para os tecidos. Além dessas estruturas primárias, a Figura 2 destaca o septo atrial e o septo ventricular, barreiras que separam os lados direito e esquerdo do coração. Esses septos

Figura 2 – A anatomia do coração humano.



Fonte: Adaptado de (Weinhaus; Roberts, 2009).

são fundamentais para manter a eficiência do sistema circulatório, assegurando que o sangue oxigenado e desoxigenado não se misturem.


3.2 Sistema de Condução e Eletrocardiograma (ECG)

Os impulsos elétricos que coordenam as contrações cardíacas são originados no sistema de condução (Kennedy *et al.*, 2016), o qual garante o sincronismo adequado para a realização das contrações cardíacas. Este sistema é uma rede especializada de células no coração que iniciam e propagam sinais elétricos, como ilustrado na Figura 3.

O sistema de condução cardíaca, compreende vários componentes que trabalham em conjunto para regular o ritmo cardíaco (Anderson *et al.*, 2008), são eles:

- **Nó Sinusatrial (SA):** O nó SA, localizado no átrio direito, é considerado o principal marca-passo do coração, determinando seu ritmo;
- **Feixe de Bachmann:** Atua como um caminho principal para os sinais elétricos se propagarem do nó SA para o átrio esquerdo;
- **Nó Atrioventricular (AV) e Feixe de His:** O nó AV é responsável por conduzir o impulso sinusal até a massa ventricular do coração. O Nó AV e o Feixe de His são os únicos componentes do coração que atravessam uma barreira isolante entre os átrios e os ventrículos, sendo essenciais para conduzir sinais elétricos do topo ao fundo do coração,

Figura 3 – O sistema de condução do coração.



Fonte: Adaptado de (St John Ambulance, 2020).

garantindo o ritmo cardíaco adequado;

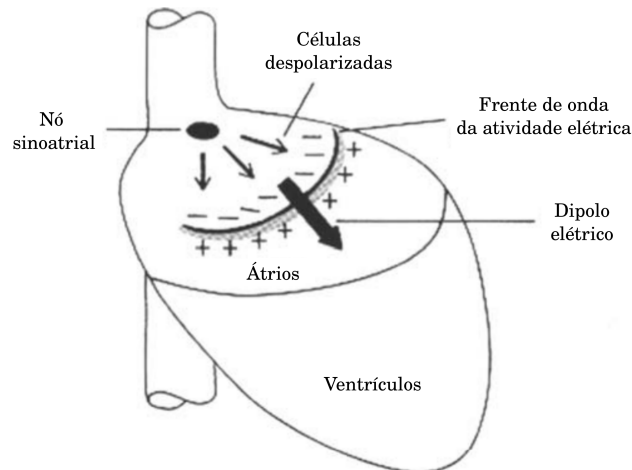
- **Ramos do feixe e fibras de Purkinje:** Após atravessar o corpo fibroso central cardíaco, o feixe de *His* se separa do miocárdio atrial e se divide em ramos direito e esquerdo nos ventrículos. Estes ramos estendem-se até os ventrículos, formando as vias de condução ventricular denominadas de fibras de *Purkinje*.

Durante a fase de contração e relaxamento do coração, as quatro câmaras devem bombear de forma sincronizada, assumindo o comportamento de um coração em ritmo sinusal normal, ou do inglês, *Normal Sinus Rhythm* (NSR). Durante o processo de contração, uma parte do miocárdio é despolarizada e outra parte se mantém polarizada, resultando em um dipolo elétrico, como ilustrado na Figura 4. O dipolo elétrico, por sua vez, gera um campo elétrico por todo o corpo, cuja intensidade pode ser detectada por meio de eletrodos na superfície corporal, viabilizando o ECG (Dupre *et al.*, 2005).

3.2.1 Eletrocardiograma (ECG)

O ECG é o exame médico usado para registrar a atividade elétrica do coração, como discutido anteriormente, através dos eletrodos e apresenta os dados em um gráfico, medido em milivolts (mV). Geralmente, um batimento cardíaco, quando registrado no ECG, é descrito por ondas, segmentos e intervalos característicos, tal como observado na Figura 5. A Figura ilustra as diversas fases da função cardíaca, incluindo a despolarização e repolarização dos átrios e ventrículos. Os principais elementos são: onda P, segmento PR, intervalo PR, onda Q, onda R, onda S, complexo QRS, segmento ST, intervalo QT, onda T e onda U (quando houver). Esses

Figura 4 – O dipolo através do coração.




Fonte: Adaptado de (Dupre *et al.*, 2005).

elementos são detalhados a seguir:

1. **Onda P** - Representa a despolarização atrial, indicando a contração dos átrios cardíacos;
2. **Segmento PR** - Refere-se ao trecho entre o final da onda P e o início do QRS, representando o atraso na condução elétrica no nó atrioventricular (AV);
3. **Intervalo PR** - Mede o tempo entre o início da onda P e o início do QRS, refletindo a função do nó AV.
4. **Onda Q** - Indica a despolarização dos septos interventriculares;
5. **Onda R** - Representa a despolarização ventricular;
6. **Onda S** - É a onda negativa que segue a onda R, também refletindo a despolarização ventricular;
7. **Complexo QRS** - Compreende as ondas Q, R e S e reflete a despolarização ventricular, sendo fundamental para a análise do ritmo cardíaco e detecção de anormalidades;
8. **Segmento ST** - É o trecho após o complexo QRS, indicando a fase inicial de repolarização ventricular e sendo relevante na detecção de isquemia ou lesão cardíaca;
9. **Intervalo QT** - Mede o tempo entre o início do complexo QRS e o fim da onda T;
10. **Onda T** - Reflete a repolarização ventricular;
11. **Onda U** - Uma pequena onda que segue a onda T, cuja origem não é completamente compreendida, mas está relacionada à repolarização das fibras de Purkinje.

Geralmente, o ECG emprega dez eletrodos que, em conjunto, estabelecem doze canais, ou derivações, e cada derivação representa a percepção do impulso elétrico do coração sob um ângulo distinto, proporcionando assim uma perspectiva específica para o profissional que


Figura 5 – Um sinal de ECG típico de um batimento cardíaco.



Fonte: Adaptado de (Dupre *et al.*, 2005).

realiza a análise de acordo com o que é exposto na Figura 6. Dessa forma, o ECG possibilita uma representação tridimensional da atividade elétrica e oferece uma análise mais abrangente dos elementos que contribuem para uma determinada condição cardíaca (Garcia, 2015).

Figura 6 – O ECG 12 derivações.




Fonte: (Mirvis, 1993).

Essas derivações são categorizadas em grupos horizontais e verticais e registram medidas positivas ou negativas com base na orientação do eletrodo em relação às origens e extremidades do vetor do coração. A análise da soma desses resultados isoeletricos fornece uma melhor compreensão sobre como certas doenças ou alterações afetam a atividade elétrica do coração (Arfelli, 2010). O corpo humano possui um número infinito de derivações em sua

superfície e, para estudo e comparação, em 1913, *Einthoven* estabeleceu três derivações bipolares DI, DII e DIII, formando o que hoje é conhecido como o "triângulo de *Einthoven*", mostrado na Figura 7. Essas derivações representam os lados de um triângulo.


Figura 7 – As derivações bipolares DI, DII e DIII.



Fonte: (Npatchett, 2015).

Mais tarde, em 1933, descobriu-se que ao conectar as derivações clássicas de *Einthoven* em um ponto central, o potencial resultante era próximo de zero (Cadogan, 2022). Esse ponto foi denominado terminal central de *Wilson* que fica localizado no centro do coração, criando três derivações unipolares adicionais: aVR, aVL e aVF (Figura 8). Essas derivações geram um vetor apontando do centro do coração para a área de maior positividade.


Figura 8 – As derivações unipolares aVR, aVL e aVF.



Fonte: (Npatchett, 2015).

O ECG também inclui seis derivações conhecidas como derivações precordiais, de V1 a V6, constituídas por eletrodos posicionados na região torácica, conforme ilustrado na Figura 9. Na imagem, VD refere-se ao ventrículo direito e VE ao ventrículo esquerdo. Cada derivação precordial oferece uma perspectiva única do coração, sendo fundamental na identificação de uma variedade de anormalidades cardíacas. Dentre elas, os infartos do miocárdio se destacam.

Figura 9 – As derivações precordiais.



Fonte: (Afya,).

Essencial na identificação de anormalidades na frequência e regularidade cardíaca, o ECG se configura como uma robusta ferramenta para o diagnóstico de condições cardíacas diversas. A interpretação desses dados por médicos cardiologistas é fundamental para um diagnóstico preciso e um subsequente tratamento especializado (Wagner; Strauss, 2014).


3.3 Intervalos R-R

Conforme discutido em seções anteriores, cardiologistas frequentemente buscam identificar características anormais no ECG para realizar diagnósticos clínicos. As principais características a serem observadas na detecção da FA incluem o ritmo ventricular irregular e a substituição das ondas P pelas ondas f (Perez *et al.*, 2009).

Um ritmo ventricular completamente irregular se manifesta através da variação dos RRI. Um RRI refere-se ao período de tempo entre duas sucessivas ondas R do complexo QRS, representando a duração de um ciclo cardíaco completo, o qual inclui tanto a despolarização quanto a repolarização dos ventrículos. A Figura 10 ilustra um segmento de um sinal de ECG da base de dados AFDB diagnosticado com FA, onde os picos das ondas R estão destacadas em linhas azuis. O RRI compreende o período entre duas marcações sucessivas de ondas R.

Geralmente, durante um episódio de FA, observa-se a ausência de ondas P, que representam a ativação atrial. No entanto, o reconhecimento de ondas P em um ECG pode ser uma tarefa complexa devido a vários fatores. Isso inclui o tamanho e a amplitude reduzidos das ondas P em comparação com outras deflexões do ECG, bem como variações em sua forma e tamanho entre indivíduos e em diferentes condições de saúde. Além disso, a presença de ruídos e interferências no traçado do ECG, juntamente com alterações na condução elétrica do

Figura 10 – Os picos de ondas R destacadas em um segmento de ECG diagnosticado com FA.



Fonte: Elaborado pelo autor.

coração, pode modificar a aparência das ondas P. Esses fatores acabam por dificultar a detecção automática de FA por meio deste biomarcador.

Outra característica observada são as ondas fibrilatórias, caracterizadas por oscilações irregulares, muito rápidas e de baixa amplitude. Essas ondas fibrilatórias podem ser visualizadas na Figura 10. Sendo assim, os RRIs, que refletem o batimento interventricular, surgem como um biomarcador relevante para a detecção de FA através dos sinais ECG (Duan *et al.*, 2022).

Os RRIs são clinicamente significativos devido à sua associação com a variabilidade da frequência cardíaca, ou mais conhecido do inglês como, *Heart Rate Variability* (HRV). A HRV reflete a interação dinâmica entre as partes simpático e parassimpático do sistema nervoso autônomo, útil no monitoramento de ataques cardíacos e pacientes diabéticos. Emerge como uma informação valiosa que é obtida de forma não invasiva para avaliar a função autonômica e a saúde cardiovascular (Drawz *et al.*, 2013). Com isso, durante um episódio de FA, os RRIs apresentam maior variabilidade por indicar um desvio padrão mais elevado, em contraste com os RRIs mais consistentes e regulares encontrados em trechos de ECG sem a condição clínica.


3.4 Arritmias Cardíacas

O coração, em condições normais, mantém um ritmo regular impulsionado pelo nó sinoatrial (SA). Qualquer perturbação nessas funções pode levar a alterações no NSR, se configurando como uma arritmia cardíaca, conforme descrito em (Guimarães, 2002). Além disso, o sistema cardiovascular também pode sofrer alterações relacionadas à idade e ser influenciado por fatores ambientais, tais como poluição do ar, atividade física e ritmos circadianos. Estes fatores têm sido objeto de estudos em (Shiogai *et al.*, 2010; Miller; Newby, 2019; Miller *et al.*, 2009). Geralmente, as arritmias que perturbam o ritmo NSR são classificadas em: taquicardia

(muito rápida), bradicardia (muito lenta) ou batimentos cardíacos irregulares (Heart; Institute, 2022).

Os casos mais representativos de arritmias cardíacas incluem a flutuação atrial (também conhecida pelo termo em inglês, atrial *flutter*), caracterizado por contrações atriais rápidas e regulares que resultam em um ritmo cardíaco igualmente rápido, porém organizado. Outra condição comumente encontrada em cenários clínicos é a Fibrilação Atrial (FA), que é o foco deste trabalho e será detalhadamente discutida na próxima subseção. A FA difere da flutuação atrial por apresentar um ritmo atrial completamente desorganizado e irregular, conforme evidenciado suas diferenças na Figura 11, levando a uma contração ventricular igualmente irregular e, muitas vezes, rápida. A flutuação atrial e a FA são classificadas como arritmias supraventriculares, ou seja, corresponde a uma alteração no NSR que tem relação com os átrios ou com o nó atrioventricular.

Figura 11 – ECG: Fibrilação atrial com ritmo irregular comparada a flutuação atrial com ondas regulares.




Fonte: (Disciplina de Emergências Clínicas da FMUSP, 2017).

3.5 A Fibrilação Atrial

Como mencionado no Capítulo 1, a FA é a arritmia cardíaca mais comum encontrada na prática clínica, se caracterizando pela perda da função de contração dos átrios do coração, uma condição conhecida como ausência de sístole atrial (January *et al.*, 2014; Magalhaes *et al.*, 2016). Essencialmente, isso significa que os átrios não se contraem de maneira sincronizada durante cada ciclo cardíaco, de acordo com o que pode ser observado na Figura 12.

Na FA, conforme ilustrado na Figura 12, múltiplos focos de atividade elétrica anômala disparam impulsos elétricos descoordenados. Esses impulsos causam uma ativação rápida e desordenada dos átrios, impedindo uma contração atrial em NSR, resultando na perda

Figura 12 – Visualização vetorial ilustrativa da condição de FA no coração.



Fonte: (Pulse Cardiology, 2020).

de sincronização com os ventrículos. Um ECG saudável mostra ondas P regulares antes de cada complexo QRS, indicando uma condução normal do nó SA. Em contraste, um ECG de FA exibe a ausência de ondas P detectáveis, que são substituídas por ondas fibrilatórias e resposta ventricular irregulares, resultando em uma diminuição significativa no desempenho cardíaco (Perez *et al.*, 2009).

3.5.1 Impacto Clínico

Conforme observado por (Miyasaka *et al.*, 2006), a quantidade de pacientes que apresentam essa condição cardíaca aumenta com a idade, afetando cerca de 3% da população adulta. Além disso, espera-se um número crescente de casos em pessoas com mais de 55 anos até 2060 (Krijthe *et al.*, 2013). Esse aumento pode ser atribuído a vários fatores. Primeiro, o envelhecimento da população global está contribuindo para um aumento no número de indivíduos suscetíveis a arritmias como a FA. Além disso, os avanços no tratamento de doenças cardíacas crônicas têm permitido que as pessoas vivam mais, aumentando assim a probabilidade de desenvolver FA. Também há uma diferença entre homens e mulheres na frequência do aparecimento de FA, indicando uma maior predisposição masculina. No entanto, apesar de os homens terem

uma maior predisposição, as mulheres representam uma parcela maior do total de pacientes com FA (Renoux *et al.*, 2014).

3.5.2 Sintomas

A FA é uma condição que apresenta diversos sintomas clínicos, os quais podem variar em intensidade e apresentação entre pacientes. Geralmente, o sintoma mais frequente é a palpitação, que é a percepção desconfortável de batimentos cardíacos rápidos e irregulares. Outro sintoma comum é a dispneia ou falta de ar, principalmente durante o esforço físico, atribuída à redução da eficiência da função cardíaca devido aos batimentos cardíacos rápidos e irregulares. A fadiga, fraqueza e diminuição da tolerância ao exercício também são sintomas comuns da FA, devido ao comprometimento da capacidade cardíaca de fornecer oxigênio suficiente para atender às demandas do corpo. É importante notar que a FA muitas vezes pode ser assintomática e descoberta incidentalmente durante exames de rotina ou investigações de outras condições. Além disso, a FA é um fator de risco significativo para eventos tromboembólicos, como acidente vascular cerebral (Heidt *et al.*, 2016).

3.5.3 Categorização

A FA é categorizada em vários tipos, dependendo de sua duração e padrão. Compreender esses tipos é essencial para seu tratamento (Magalhaes *et al.*, 2016). As classificações são:

- **Fibrilação Atrial Paroxística:** Esta categoria inclui casos de FA que cessam sozinhos ou com tratamento médico em no máximo 7 dias. Esses episódios são temporários e podem acabar sem tratamento a longo prazo, o que os diferencia de outras formas de FA.
- **Fibrilação Atrial Persistente:** Quando a FA dura mais de 7 dias, ela é classificada como persistente. Esta classificação sugere a necessidade de uma abordagem diferente em termos de tratamento e controle, comparada à FA paroxística.
- **Fibrilação Atrial Persistente de Longa Duração:** Esta é a descrição para casos de FA que duram mais de um ano. Estes geralmente exigem uma estratégia de tratamento mais complexa e intensiva, dada a sua longa duração.
- **Fibrilação Atrial Permanente:** Usada para casos onde não se tenta mais reverter a FA para um ritmo cardíaco normal. Aqui, o objetivo do tratamento muda para o controle da frequência cardíaca e prevenção de problemas adicionais, ao invés de tentar restaurar o

ritmo normal.

3.5.4 Tratamento

Os objetivos principais do tratamento de FA é o controle do NSR. As estratégias geralmente envolvem o uso de medicamentos antiarrítmicos baseado no perfil clínico do paciente e na sua condição cardíaca. Se os medicamentos forem ineficazes ou contraindicados, a ablação por cateter pode ser considerada, que caracteriza-se pela destruição direcionada do tecido cardíaco responsável pelos sinais elétricos anormais causadores da FA (Prystowsky *et al.*, 2015). Outra opção é uma descarga elétrica para restaurar o ritmo cardíaco, técnica conhecida como cardioversão elétrica.

3.6 Decomposições Tensoriais

3.6.1 Introdução à Álgebra Tensorial

A notação utilizada neste trabalho é apresentada a seguir. As variáveis matemáticas escalares são denotadas por letras minúsculas (a, b, \dots, z), os vetores como letras minúsculas e em negrito ($\mathbf{a}, \mathbf{b}, \dots, \mathbf{z}$), as matrizes como letras maiúsculas em negrito ($\mathbf{A}, \mathbf{B}, \dots, \mathbf{Z}$) e os tensores através de letras caligráficas ($\mathcal{A}, \mathcal{B}, \dots, \mathcal{Z}$). O i -ésimo elemento de um vetor \mathbf{a} é denotado por a_i , o (i, j) -ésimo elemento de uma matriz \mathbf{A} é denotado por $a_{i,j}$, e o (i_1, \dots, i_N) -ésimo elemento do tensor \mathcal{T} de ordem N é denotado por t_{i_1, \dots, i_N} .

De acordo com (Hitchcock, 1927), tensores são definidos como objetos matemáticos que generalizam as representações de escalares, vetores e matrizes para ordens maiores do que 2. Para um tensor de ordem $N > 3$, a representação se torna uma estrutura multidimensional, com N dimensões. Mais formalmente, um tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_N}$ de ordem N é um arranjo de dados com N dimensões.

O produto diádico, também conhecido como produto externo, é uma operação fundamental para o desenvolvimento e compreensão das equações subsequentes. Seja $\mathcal{A} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_P}$ um tensor de ordem P e $\mathcal{B} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_Q}$ um tensor de ordem Q . O produto diádico $\mathcal{A} \circ \mathcal{B}$ é um tensor \mathcal{C} de ordem $P + Q$. No contexto de vetores, o produto diádico resulta em uma matriz. Para tensores de ordem superior, o produto diádico gera um tensor de ordem superior, cujos elementos são definidos da seguinte forma:


$$c_{i_1, i_2, \dots, i_p, j_1, j_2, \dots, j_q} = a_{i_1, i_2, \dots, i_p} b_{j_1, j_2, \dots, j_q}. \quad (3.1)$$

Para melhor compreensão acerca das decomposições tensoriais, inseridas no contexto da álgebra multilinear, outras definições são relevantes: os modos, fatias, matricização, *rank* e *rank* do modo- N de um tensor.

Modo: Os modos de um tensor referem-se às diferentes dimensões de um tensor ao longo das quais as operações podem ser realizadas. Em um tensor de ordem N , existem N modos, cada um correspondendo a uma dimensão específica do tensor. Como exemplo, um tensor de terceira ordem, o modo-1, modo-2 e modo-3 podem referir-se, respectivamente, às operações ao longo da altura, largura e profundidade. A manipulação de dados em um determinado modo envolve operações ao longo dessa dimensão específica, mantendo fixas as outras dimensões.

Fatia: As fatias são obtidas fixando todos os índices exceto dois. Isso significa que uma fatia de um tensor \mathcal{T} de terceira ordem é uma matriz, conforme mostrado na Figura 13. Uma fatia horizontal, também conhecida como modo-1, pode ser representada pelos elementos $t_{i::}$, onde o índice i varia e os outros dois índices (j, k) são fixados. Uma fatia vertical, ou modo-2, denotada por $t_{:j}$, onde o índice j varia enquanto os outros dois índices (i, k) são mantidos fixos. Finalmente, uma fatia frontal, ou modo-3, é expressa como $t_{::k}$, onde o índice k varia e os outros dois índices (i, j) são fixados.

Figura 13 – Fatias de um tensor \mathcal{X} de ordem 3.




Fonte: (Kolda; Bader, 2009).

Matricização: É uma operação matemática que envolve a transformação de um tensor multidimensional em uma matriz. Este processo, também é conhecido como desdobramento ou achatamento, ou do inglês, respectivamente, como *unfolding* ou *flattening*. Seguindo as definições de matricização em (Kolda; Bader, 2009), ao reorganizar os elementos de um tensor ao longo de modos ou dimensões específicas, a matricização no modo- N de um tensor

$\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_N}$, representado por $\mathcal{T}^{(n)}$, é obtido empilhando todas as fatias da matriz, no modo específico do tensor. A Figura 14 ilustra o processo em todos os modos de um tensor \mathcal{T} .

Figura 14 – O processo de matricização de um tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times I_3}$.



Fonte: Elaborado pelo autor.

Rank: Um tensor de *rank* 1 é um tensor $\mathcal{D} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_N}$ que pode ser escrito como o produto diádico de N vetores, ou seja, pode ser desenvolvido pela expressão: $\mathcal{D} = \mathbf{d}_1 \circ \mathbf{d}_2 \circ \dots \circ \mathbf{d}_n$, onde \mathbf{d}_1 , \mathbf{d}_2 e \mathbf{d}_n são vetores, ou também, denominados como componentes de \mathcal{D} . O *rank* de um tensor \mathcal{T} , denotado por $\text{rank}(\mathcal{T})$, é definido como o número mínimo de tensores \mathcal{D} de *rank* 1 necessários para expressar o tensor \mathcal{T} (Comon, 2014). Com isso, o menor valor de R para que a seguinte equação seja válida:

$$\mathcal{T} = \sum_{r=1}^R \lambda_r \mathcal{D}_{(r)}. \quad (3.2)$$

é chamado de *rank* do tensor \mathcal{T} .

O conceito de *rank* tensorial, não obstante recordar sobre a classificação matricial (ou posto matricial), apresenta algumas distinções em suas propriedades: determinar o *rank* de um tensor é caracterizado como uma tarefa NP-difícil, além disso, o *rank* de um tensor \mathcal{T}

pode ser maior do que suas próprias dimensões. Essas características destacam a complexidade e a natureza peculiar da análise tensorial, onde as propriedades dos tensores podem diferir significativamente das propriedades matriciais tradicionais.

Rank dos modos: Também denominado como *rank* multilinear, geralmente é expresso por R_n . É denotado pelo *rank* (posto) da matriz desdobrada de um dado tensor \mathcal{T} no modo- N .

3.6.2 Decomposições Tensoriais


As decomposições tensoriais buscam expressar um tensor por meio de objetos matemáticos mais simples, comumente denominados fatores. Dentre as técnicas, destaca-se a decomposição PARAFAC, que significa *PARAllel* (paralelos) *FACTors* (fatores), ou fatores paralelos (Hitchcock, 1927). A decomposição PARAFAC é obtida através da soma de R tensores de *rank*-1, particularmente, se R for o mínimo possível, então a decomposição é chamada de Decomposição Canônica Poliádica, ou do inglês, *Canonical Polyadic Decomposition* (CPD), revelando o *rank* do tensor (Comon, 2014). A unicidade implica que os fatores obtidos da PARAFAC são únicos até em operações de permutação entre colunas e escalonamento por um mesmo escalar, onde seria obtida uma representação equivalente do tensor original. No trabalho de (Kruskal, 1977), foi demonstrado que a unicidade é preservada sob condições relativamente relaxadas. Essas condições são necessárias e suficientes para a unicidade quando $R = 2$, mas não são necessárias quando $R = 1$. Deste modo, a decomposição PARAFAC propõe a representação de um tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times I_3}$ de terceira ordem da seguinte forma:

$$\mathcal{T} = \sum_{r=1}^R \mathbf{a}_r \circ \mathbf{b}_r \circ \mathbf{c}_r, \quad (3.3)$$

em que R é o rank do tensor, $\mathbf{a}_r \in \mathbb{R}^{I_1}$, $\mathbf{b}_r \in \mathbb{R}^{I_2}$ e $\mathbf{c}_r \in \mathbb{R}^{I_3}$ são vetores que podem ser combinados em matrizes, resultando nos componentes $\mathbf{A} = [a_1, a_2, \dots, a_R]$, $\mathbf{B} = [b_1, b_2, \dots, b_R]$ e $\mathbf{C} = [c_1, c_2, \dots, c_R]$, representados na Figura 15.

Na decomposição de *Tucker*, introduzida em (Tucker, 1966), um tensor \mathcal{T} de ordem N é decomposto em um tensor núcleo e em N matrizes fatores, que correspondem a diferentes transformações do núcleo ao longo de cada modo. A decomposição de *Tucker* representa uma extensão da CPD, pois, quando o tensor núcleo assume a forma de um tensor identidade, essa decomposição torna-se equivalente à CPD. A Figura 16 ilustra a decomposição *Tucker* para um


Figura 15 – Representação visual do processo de decomposição PARAFAC.



Fonte: Elaborado pelo autor.

tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times I_3}$ de terceira ordem.

Figura 16 – Representação visual do processo de decomposição Tucker.



Fonte: Elaborado pelo autor.

Ao considerar a decomposição ilustrada na Figura 16, pode-se desenvolver o método por meio da seguinte expressão:

$$t_{ijk} = \sum_{p=1}^P \sum_{q=1}^Q \sum_{r=1}^R a_{ip} \cdot b_{jq} \cdot c_{kr} \cdot g_{pqr}, \quad (3.4)$$

com P , Q e R configurando-se como os *ranks* de cada modo, determinando assim o tamanho das componentes matriciais $\mathbf{A}^{I_1 \times P}$, $\mathbf{B}^{I_2 \times Q}$ e $\mathbf{R}^{I_3 \times R}$, correspondentes às matrizes fatores associadas a cada modo do tensor \mathcal{T} . Além disso, \mathcal{G}_{pqr} é o componente tensor núcleo, com $\mathcal{G} \in \mathbb{R}^{P \times Q \times R}$.

3.6.3 Decomposição em Termos de Blocos (BTD)

Em (Lathauwer, 2008) é introduzida a BTD, onde um tensor $\mathcal{T} \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_N}$ é representado como uma soma de tensores de menor ordem visando combinar as técnicas de decomposição abordadas anteriormente: a CPD e a decomposição Tucker. A singularidade da BTD está na característica de que seus componentes matemáticos possuem baixo *rank* multilinear. A BTD também pode ser definida e representada no caso particular onde cada termo possui o *rank* multilinear $(L_r, L_r, 1)$ (Lathauwer, 2008). Este caso específico tem atraído maior interesse

devido à sua ocorrência mais frequente em aplicações e à existência de condições de unicidade mais relaxadas e fáceis de verificar. Com isso, considerando um tensor $\mathcal{T} \in \mathbb{R}^{I \times J \times K}$ de terceira ordem, a BTM com rank $(L_r, L_r, 1)$ é descrita a seguir:


$$\mathcal{T} = \sum_{r=1}^R \mathbf{E}_r \circ \mathbf{c}_r, \quad (3.5)$$

em que $\mathbf{E}_r \in \mathbb{R}^{I \times J}$ é uma matriz com rank L_r e $\mathbf{c}_r \in \mathbb{R}^K$ é um vetor. Realizando uma fatoração em \mathbf{E}_r , resulta em $\mathbf{A}_r \mathbf{B}_r^T$, onde $\mathbf{A}_r \in \mathbb{R}^{I \times L}$ e $\mathbf{B}_r \in \mathbb{R}^{J \times L}$, da seguinte forma:

$$\mathcal{T} = \sum_{r=1}^R (\mathbf{A}_r \mathbf{B}_r^T) \circ \mathbf{c}_r. \quad (3.6)$$

A representação visual da BTM é vista na Figura 17.

Figura 17 – Representação visual da decomposição BTM em termos de *rank* $(L_r, L_r, 1)$.



Fonte: Elaborado pelo autor.

Em (Lathauwer, 2008), especificamente no Teorema 4.1, são discutidas as condições necessárias para que a decomposição BTM de *rank* $(L_r, L_r, 1)$ seja essencialmente única:

1. Considerando as matrizes fatores $\mathbf{A} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \dots \ \mathbf{a}_R]$ e $\mathbf{B} = [\mathbf{b}_1 \ \mathbf{b}_2 \ \dots \ \mathbf{b}_R]$, estes componentes precisam possuir um *rank* completo de coluna, ou seja, as colunas precisam ser linearmente independentes. Adicionalmente, para que essa condição ocorra, é necessário que $\min(I, J) \geq \sum_{r=1}^R L_r$, o que pode ser facilmente atendido em aplicações onde R e L_r são pequenos (Rontogiannis *et al.*, 2021).
2. A matriz $\mathbf{C} = [\mathbf{c}_1 \ \mathbf{c}_2 \ \dots \ \mathbf{c}_R]$ não deve possuir colunas colineares.

Para o cálculo do tensor estimado através da decomposição BTM com *rank* $(L_r, L_r, 1)$, especificamente na Seção 2 do trabalho (Lathauwer; Nion, 2008), é proposta a utilização do algoritmo de Mínimos Quadrados Alternados, em inglês, *Alternating Least Squares* (ALS). O algoritmo ALS é uma abordagem iterativa que busca minimizar a função de erro quadrático entre os dados observados e a representação aproximada através da modelagem tensorial BTM.

Posteriormente, em (Sorber *et al.*, 2013), é empregado o método de Mínimos Quadrados Não Lineares, do inglês, *Nonlinear Least Squares* (NLS). Essa abordagem na modelização BTM se destaca por ser menos sensível ao tipo de inicialização, fornecendo uma estrutura para resolver problemas de otimização com relações não lineares entre variáveis. Geralmente, os algoritmos *Gauss-Newton* e *Levenberg-Marquardt* são técnicas de otimização específicas projetadas para resolver problemas de NLS.

3.7 Separação cega de fontes em ECG

A separação cega de fontes, ou mais conhecida do inglês como *Blind Source Separation* (BSS), é uma técnica que visa identificar e recuperar sinais de origem, ou fontes, sem o conhecimento prévio da matriz de mistura, contando apenas com a informação transportada pelos próprios sinais recebidos (Belouchrani *et al.*, 1997), fato que denota o termo "cego".

No contexto de sinais de ECG, os sinais provenientes de AA e Atividade Ventricular (AV) são misturados nas saídas dos eletrodos. No entanto, em (Rieta *et al.*, 2004), é exposto que, durante a FA, esses sinais são considerados desacoplados, ou independentes. Isso permite que o problema de extração da fonte AA seja interpretado como um problema BSS. Em termos matemáticos, temos uma matriz de fontes denotada por $\mathbf{S} = [\mathbf{s}_1 \ \mathbf{s}_2 \ \dots \ \mathbf{s}_n] \in \mathbb{R}^{R \times N}$, onde R representa a quantidade de fontes com N amostras de tempo, e cada \mathbf{s}_n representa uma fonte que pode ser originada de AA, AV, ruído, respiração, atividade muscular, entre outras. Quando o sinal chega ao receptor, a matriz \mathbf{S} sofre uma combinação, que pode ser representada pela matriz de mistura $\mathbf{M} \in \mathbb{R}^{K \times R}$, onde K é a quantidade de derivações que o sinal ECG possui. As matrizes \mathbf{S} e \mathbf{M} , uma vez combinadas, produzem sinais misturados e podem ser representadas por $\mathbf{Y} = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_n] \in \mathbb{R}^{K \times N}$. Em resumo, têm-se que:

$$\mathbf{Y} = \mathbf{MS} \in \mathbb{R}^{K \times N}, \quad (3.7)$$

em que o objetivo está em estimar \mathbf{M} e \mathbf{S} a partir da matriz \mathbf{Y} . Para tal feito, geralmente são utilizadas técnicas matriciais como: a análise de componentes independentes, do inglês, *Independent Component Analysis* (ICA) e a análise de componentes principais, do inglês, *Principal Component Analysis* (PCA).


As decomposições tensoriais, especialmente a BTM, tem sido considerada uma técnica promissora na análise do sinal de ECG para FA, com o objetivo de resolver o problema

de BSS e realizar a extração do sinal de AA de forma não invasiva. Esta abordagem supera as limitações das técnicas matriciais, oferece maior estabilidade temporal e unicidade em condições menos restritivas. No entanto, um pré-processamento denominado tensorização é exigido, pois prepara os dados brutos que são coletados dos repositórios de sinais de ECG. A tensorização permite uma extração adequada da AA a partir da BTD e será abordada na próxima subseção.

3.8 Tensorização

A tensorização corresponde ao processo de transformação dos dados com o objetivo de alterar a ordem dos dados de entrada. Por outro lado, uma vez que o conjunto de dados tenha passado pelo processo de tensorização através de um mapeamento não bijetivo, é possível recuperar o conjunto original de ordem inferior por meio da detensorização. A Figura 18 desenvolve uma aplicação de tensorização no contexto de sinais de ECG, sendo estes sinais representados pela matriz \mathbf{S} , onde foi elaborada a partir de N derivações (ou expressas através de N vetores). Admitindo-se o processo de tensorização nos vetores $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_N$, temos N matrizes (ou fatias do tensor \mathcal{H}), ilustradas na Figura 18 por $\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_N$. Uma vez estas N matrizes empilhadas é obtido o tensor \mathcal{H} , ou também, $\mathcal{H}_{..n} = \mathbf{H}_n$.

Figura 18 – Aplicação de tensorização no contexto de sinais de ECG.



Fonte: Elaborado pelo autor.

No contexto dos problemas envolvendo BSS em sinais de ECG, os principais métodos de tensorização podem ser subdivididos em: determinísticos ou baseados em estatística. Uma descrição mais aprofundada dessas técnicas é visto em (Debals; Lathauwer, 2015).

3.8.1 Hankelização

Entre as abordagens utilizadas no processo de tensorização, a hankelização é considerada uma técnica determinística e consiste na transformação dos dados com o objetivo de alterar sua ordem por meio da matriz de Hankel. O processo de hankelização, em segunda ordem,

é definido pela seguinte regra de correspondência:

$$h_{i,j} = v_{i+j-1}, \quad (3.8)$$

em que (3.8) transforma um vetor $\mathbf{v} \in \mathbb{R}^N$ em uma matriz de Hankel $\mathbf{H} \in \mathbb{R}^{I \times J}$, com $N = I + J - 1$, e $\forall i = 1, 2, \dots, I$ e $j = 1, 2, \dots, J$. Para exemplificar o processo de hankelização e escolhendo $N = 10$, pode-se impor as dimensões de \mathbf{H} : $I = 6$ e $J = 5$. Dessa forma, o mapeamento para uma matriz de Hankel $\mathbf{H} \in \mathbb{R}^{6 \times 5}$ é ilustrado a seguir:

$$\mathbf{H} = \begin{bmatrix} v_1 & v_2 & v_3 & v_4 & v_5 \\ v_2 & v_3 & v_4 & v_5 & v_6 \\ v_3 & v_4 & v_5 & v_6 & v_7 \\ v_4 & v_5 & v_6 & v_7 & v_8 \\ v_5 & v_6 & v_7 & v_8 & v_9 \\ v_6 & v_7 & v_8 & v_9 & v_{10} \end{bmatrix}.$$

A matriz \mathbf{H} resultante é a representação hankelizada do vetor \mathbf{v} , e como é evidente, cada anti-diagonal da matriz é constante.

3.8.2 *Hankel-BTD*

A Hankel-BTD, também conhecida como BTD baseada em Hankel, é proposta em (Lathauwer, 2011) como uma técnica para problemas BSS e aplicada em sinais de ECG de curta duração para extração de AA, especificamente em registros com episódios de FA persistente de um único paciente em (Ribeiro *et al.*, 2015). No estudo, foi relatado um desempenho superior em problemas BSS em comparação com as abordagens matriciais. A técnica Hankel-BTD baseia-se em (3.7) com o propósito de obter um tensor $\mathcal{H} \in \mathbb{R}^{I \times J \times K}$ a partir da matriz \mathbf{Y} . O tensor \mathcal{H} é desenvolvido a partir de N matrizes Hankel $\mathbf{H}_{\mathbf{Y}}^{(n)} \in \mathbb{R}^{I \times J}$ elaboradas por cada n -ésima linha de \mathbf{Y} . Cada elemento (i, j) da matriz hankelizada $\mathbf{H}_{\mathbf{Y}}^{(n)}$ é representado pelo seguinte mapeamento:

$$h_{i,j}^{(n)} = y_{n,i+j-1} \quad (3.9)$$

onde $i = 1, 2, \dots, I$, $j = 1, 2, \dots, J$, e $n = 1, 2, \dots, N$. O tensor \mathcal{H} é então montado fazendo um empilhamento ao longo do terceiro modo (como visto, a partir de fatias frontais), resultando em

$\mathcal{H} = [\mathbf{H}_Y^{(1)} \quad \mathbf{H}_Y^{(2)} \quad \dots \quad \mathbf{H}_Y^{(N)}]$, ou $\mathcal{H}_{..n} = \mathbf{H}_Y^{(n)}$. Em sua forma escalar pode-se representar \mathcal{H} da seguinte forma:

$$h_{i,j,n} = \sum_{r=1}^R m_{n,r} s_{n,i+j-1}. \quad (3.10)$$

Com isso, a n -ésima fatia do tensor \mathcal{H} pode ser representada por:

$$h_{..n} = \sum_{r=1}^R m_{n,r} h_S^{(r)}, \quad (3.11)$$

Pode-se observar que, para cada r , o produto diádico entre a matriz $\mathbf{H}_S^{(r)}$ e a r -ésima coluna de M , ou seja, \mathbf{m}_r , é realizado para obter a contribuição de cada fonte para o tensor observado. Dessa maneira, o tensor de terceira ordem T pode ser expresso como:

$$\mathcal{H} = \sum_{r=1}^R \mathbf{H}_S^{(r)} \circ \mathbf{m}_r. \quad (3.12)$$

Conclui-se que o tensor \mathcal{H} , visto em (3.12), elaborado com auxílio do processo de hankelização, segue um modelo de tensor BTD desenvolvido através de (3.5). Desse forma, é permitido então obter as fontes estimadas pelo modelo em $\mathbf{H}_S^{(r)}$.

3.9 Métricas de Avaliação

A avaliação de desempenho de um modelo discriminante é essencial para entender quão bem este modelo generaliza para novos dados. Nesta seção, apresentamos a fundamentação conceitual das métricas abordadas nos experimentos deste trabalho.

3.9.1 Matriz de Confusão

A separação entre duas classes distintas geralmente é definida como uma classificação binária. No contexto desta pesquisa, que abordará os trechos, ou aqui denominados segmentos de sinal ECG, estes podem ser rotulados com as classes FA ou NSR. A matriz de confusão, apresentada na Tabela 1, ilustra as situações resultantes desse processo de classificação.

As possibilidades resultantes deste tipo de classificação são definidas à seguir:

- **Verdadeiro Positivo (VP):** Corresponde aos casos em que o modelo rotula corretamente um segmento de sinal de ECG como positivo para FA, quando de fato ele anteriormente foi diagnosticado com a condição.

Tabela 1 – Matriz de confusão.

	Predito Positivo	Predito Negativo
Real Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
Real Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Elaborado pelo autor.

- **Verdadeiro Negativo (VN):** Refere-se aos casos em que o modelo rotula corretamente um segmento de sinal de ECG como negativo para FA, quando de fato ele não foi diagnosticado com FA.
- **Falso Positivo (FP):** Conhecido também como erro do tipo I, ocorre quando o modelo rotula erroneamente um segmento de sinal de ECG como possuindo FA, mesmo que este anteriormente não tenha sido diagnosticado com FA.
- **Falso Negativo (FN):** Conhecido também como erro do tipo II, acontece quando o modelo falha em rotular um segmento de sinal de ECG que realmente foi diagnosticado com a condição FA, classificando-o como negativo.

3.9.2 Métricas Tradicionais

Nesta subseção, são apresentadas métricas de avaliação comumente utilizadas em modelos de classificação, como a Acurácia (ACC), Sensibilidade (SEN), Especificidade (SPE), Precisão e *FI-Score*. Essas métricas utilizam as informações obtidas na matriz de confusão e são essenciais para avaliar o desempenho de um modelo.

- **Acurácia.** Definida como a proporção de amostras corretamente classificadas pelo modelo em relação ao total de amostras, essa métrica é comprometida por dados desbalanceados.

$$ACC = \frac{VP + VN}{VP + FN + FP + VN}. \quad (3.13)$$

- **Sensibilidade.** Também definida como revogação, ou do inglês, *recall*, revela a proporção de amostras positivas que foram corretamente identificadas pelo modelo.

$$SEN = \frac{VP}{VP + FN}. \quad (3.14)$$

- **Especificidade.** A proporção de amostras negativas que foram corretamente identificadas pelo modelo.

$$SPE = \frac{VN}{FP + VN}. \quad (3.15)$$

- **Precisão.** Revela a proporção entre os positivos identificados corretamente (VP) e todos os positivos identificados. É calculada pela fórmula:

$$PRE = \frac{VP}{VP + FP}. \quad (3.16)$$

- **F1-Score.** A média harmônica entre a sensibilidade e a precisão. É calculado pela fórmula:

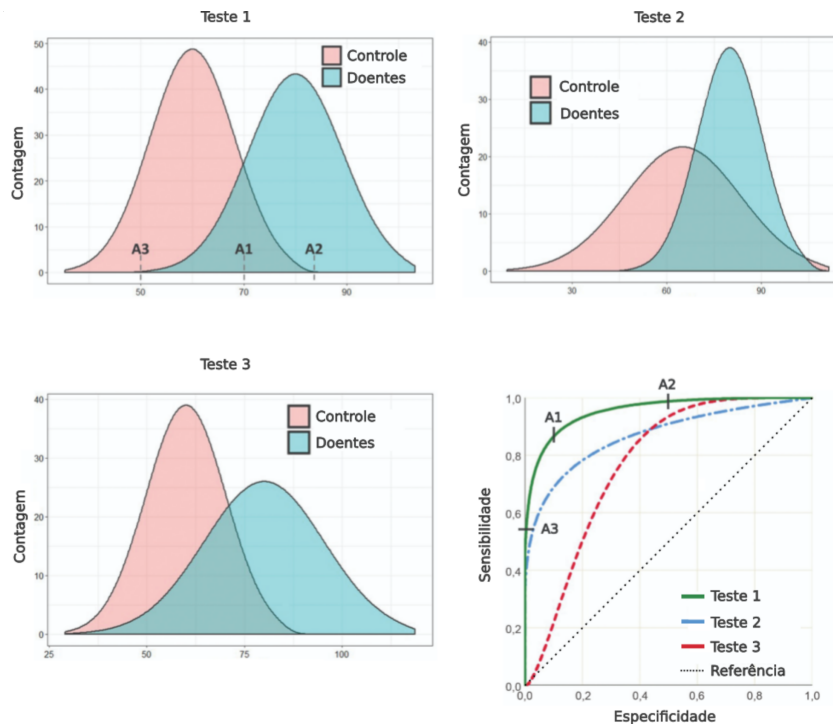
$$F1-Score = 2 \times \frac{SEN \times PRE}{SEN + PRE} \quad (3.17)$$

3.9.3 Curva ROC

A Curva Característica de Operação do Receptor, ou do inglês, Curva *Receiver Operating Characteristic* (ROC), é uma ferramenta gráfica utilizada para avaliar o desempenho de sistemas de classificação do tipo binário, seu comportamento é melhor ilustrado na Figura 19. Os testes 1, 2 e 3 são testes hipotéticos que em cada um apresentam duas curvas de distribuição de resultados para doentes e saudáveis. No Teste 1, pontos de cortes entre as classes foram realizados. O ponto A1 é o ponto de máximo desempenho, considerando as taxas de falsos positivos e falsos negativos. O ponto A2 possui a maior especificidade, já que nenhum falso negativo é classificado acima dele. Por sua vez, o ponto A3 resulta em uma maior sensibilidade, pois nenhum falso positivo é classificado abaixo dele.

A curva ROC acabou ganhando destaque em diversas áreas da medicina que envolve aplicações do aprendizado de máquina, devido à sua capacidade de representar a relação entre a Sensibilidade (eixo Y) e a Especificidade (eixo X) de um classificador. A área sob a curva ROC, do inglês *Area Under the ROC Curve* (AUC), é considerada também um indicador quantitativo da acurácia do classificador. Um valor de AUC de 1 indica um classificador perfeito, ou seja, é capaz de separar com total precisão todas as instâncias positivas das negativas. Por outro lado, um AUC de 0,5 sugere um desempenho não distante de uma classificação aleatória. Dessa forma, a curva ROC e o AUC são medidas que auxiliam para a avaliação de algoritmos de classificação.

Figura 19 – Curva ROC.



Fonte: Adaptado de (Polo; Miot, 2020).

3.10 Classificadores

A seleção dos algoritmos de classificação que foram utilizados considerou dois critérios principais: desempenho (acurácia, sensibilidade e especificidade) e eficiência (tempo de processamento). Observou-se que, dentre as diversas aplicações de aprendizado de máquina, as técnicas baseadas em Árvore de Decisão se destacaram nos dois critérios mencionados. Essa constatação também foi verificada nos trabalhos de (Hirsch *et al.*, 2021; Patel *et al.*, 2023).

A Árvore de Decisão é uma técnica amplamente utilizada no aprendizado de máquina para tarefas de classificação ou regressão. Ela consiste em um sistema de decisão composto por nós de decisão, ramos e folhas, formando um grafo estruturado. Os nós representam testes em características (geralmente acompanhados por um limiar de decisão), os ramos representam resultados possíveis e as folhas representam os rótulos das classes. Esse modelo é popularmente conhecido em tarefas do aprendizado de máquina pela sua interpretação intuitiva em comparação com modelos mais complexos (Guidotti *et al.*, 2018).

Com isso, os algoritmos utilizados na etapa de classificação dos vetores de características deste trabalho são dispostos a seguir.

- Floresta Aleatória (Breiman, 2001): É um método de aprendizado de máquina que opera

construindo múltiplas árvores de decisão. Também é considerado um algoritmo do tipo *ensemble*, pois, através dos métodos *bootstrap* e *bagging*, é realizada uma combinação de múltiplos modelos individuais e seus resultados geralmente são obtidos por meio de uma estratégia de votação (Dietterich, 2000).

- *Boosting* de Gradiente (Friedman, 2001), ou mais conhecido do inglês como *Gradient Boosting*. No contexto de aprendizado de máquina, o *boosting* se refere a uma técnica que busca melhorar a precisão e a performance preditiva dos modelos (Freund; Schapire, 1999).
- Árvores Extremamente Randomizadas (Geurts *et al.*, 2006): Conhecido pelo nome em inglês *Extremely Randomized Trees* ou *Extra-trees*, este método introduz maior aleatoriedade na construção das árvores de decisão. Diferentemente da Floresta Aleatória, ele seleciona aleatoriamente os pontos de divisão dos dados, o que pode levar a uma maior diversificação das árvores e um melhor desempenho.
- *Boosting* de Gradiente Extremo (Chen; Guestrin, 2016): Conhecido pelo nome em inglês *Extreme Gradient Boosting* (XGB), este método é uma implementação avançada do *boosting* de gradiente, que inclui otimizações para desempenho computacional e escalabilidade. Ele é largamente utilizado em tarefas que envolvem grandes conjuntos de dados e problemas de alta dimensionalidade devido ao seu desempenho superior.
- Máquina de *Boosting* de Gradiente Leve (Ke *et al.*, 2017): Conhecida pelo nome em inglês *Light Gradient Boosting Machine* (LightGBM), esta técnica é projetada para uma melhor otimização em termos de tempo e memória. Pois, utiliza uma abordagem baseada em histogramas para encontrar os melhores pontos de divisão.

4 TRABALHOS RELACIONADOS

Este capítulo inicia-se destacando os principais obstáculos enfrentados em técnicas de detecção de FA encontrados na literatura. Posteriormente, é apresentada uma revisão bibliográfica sobre o uso das principais técnicas aplicadas em sinais de ECG para a detecção de FA. Uma seção será destinada aos trabalhos que envolvem a separação cega de fontes para extração da AA e que envolvem o uso da BTD. Além disso, este capítulo tem o objetivo de identificar as tendências atuais dos esforços neste campo.

4.1 Desafios enfrentados na detecção de FA

A detecção automática da FA em sinais de ECG representa uma ferramenta significativa no monitoramento da saúde cardiovascular de pacientes afetados por essa condição cardíaca. Como exemplo, novas tecnologias não invasivas em desenvolvimento já foram integradas em programas de triagem em larga escala, apresentando resultados promissores em fases de investigação (Zink *et al.*, 2018). No entanto, essa inovação enfrenta alguns desafios que são relatados pelas diversas metodologias já desenvolvidas.


- **Detecção Precoce.** Uma detecção em tempo real da condição cardíaca FA se apresenta como uma nova demanda no cenário clínico atual. Por meio de dispositivos vestíveis, é possível realizar um diagnóstico e tratamento mais rápidos para o paciente (Prasitlumkum *et al.*, 2021). Dessa forma, a detecção precoce aliada a um tratamento ágil, pode resultar em uma redução significativa de 70% no risco de acidente vascular cerebral. No entanto, há diversos desafios associados aos dispositivos vestíveis, pois espera-se alta precisão dos modelos, sejam adequados para dispositivos de monitoramento de baixa energia (Gibson *et al.*, 2023), e que também possam estabelecer uma comunicação estável sem fio com um servidor em nuvem, viabilizando a transmissão de possíveis sinais de alerta ao profissional especialista. Além disso, as técnicas elaboradas para a detecção de FA frequentemente fazem uso de modelos inseridos no aprendizado de máquina supervisionado, o que implica a necessidade de grandes volumes de dados previamente armazenados, organizados, pré-processados e rotulados para avaliar seu desempenho discriminante, e este processo demanda tempo e poder computacional.
- **Biomarcadores Digitais.** Um biomarcador digital é uma atributo mensurável, coletado através de dados digitais brutos (como exemplo, os sinais ECG), e são utilizados para

auxílio de diagnóstico, monitoramento e prognóstico de doenças. No contexto de sinais de ECG, esses atributos podem ter diferentes origens, são eles: os biomarcadores atriais, biomarcadores ventriculares e as características do sinal. Respectivamente, esses conjuntos referem-se a características associadas à atividade elétrica dos átrios, à atividade elétrica dos ventrículos e às características extraídas do próprio sinal de ECG.

No entanto, um problema significativo associado aos biomarcadores extraídos através do ECG é a propensão de serem compartilhados entre diferentes tipos de arritmias. Por exemplo, uma extração errônea do biomarcador ventricular RRIs, ou seja, uma identificação incorreta dos picos R a partir de um segmento de ECG, aumenta a possibilidade de o classificador rotular um segmento como indicativo da presença de FA, quando, na realidade, um diagnóstico positivo para esse segmento pode ter sido causado por outra condição, como a flutuação atrial. Os RRIs também são destacados no estudo de (Tsipouras *et al.*, 2005), onde são explorados como uma característica única para a classificação entre diversas arritmias cardíacas. De fato, os RRIs tem sido amplamente utilizado em diversos trabalhos ao longo de décadas (Tateno; Glass, 2001; Lian *et al.*, 2011; Duan *et al.*, 2022).


- **Interferências de Sinal.** Os sinais de ECG também estão sujeitos a diversos tipos de ruídos e artefatos (Kher *et al.*, 2019). Esses elementos muitas vezes se misturam com o sinal de ECG, tornando mais desafiadora a tarefa de realizar diagnósticos precisos pelos médicos. Uma breve descrição de cada tipo de interferência do sinal ECG é apresentada a seguir.
 - **O sinal eletromiográfico:** O Eletromiográfico (EMG), são artefatos resultantes da atividade elétrica dos músculos durante os períodos de contração ou devido à um movimento súbito do corpo. Esse tipo de ruído pode alterar significativamente a forma das ondas do traçado eletrocardiográfico, visto que a faixa de frequência do EMG se sobrepõe consideravelmente à do traçado de ECG, de 0,01 a 100 Hz. O EMG é ilustrado na Figura 20.
 - **Interferência da linha de energia.** Outro tipo comum de ruído encontrado é o gerado pelos campos eletromagnéticos provenientes das linhas de energia, caracterizada por perturbações sinusoidais a 50 ou 60 Hz. Esse tipo de interferência se sobrepõe às ondas de ECG de baixa frequência, à exemplo, a onda P e a onda T. A Figura 21 ilustra um sinal típico de ECG afetado pelo ruído em questão.
 - **Flutuação da linha de base.** Por fim, o ruído geralmente reconhecido como flutuação,

Figura 20 – Sinal de ECG com ruído Eletromiográfico (EMG).



Fonte: (Maggio *et al.*, 2012)


Figura 21 – Sinal de ECG com ruído interferência da linha de energia.



Fonte: (Maggio *et al.*, 2012)

ou deslocamento, da linha de base, é ilustrado na Figura 22 e caracterizado por apresentar baixa frequência, operando geralmente em frequências abaixo de 1,5 Hz (Romero *et al.*, 2018). Alguns dos fatores que originam esse tipo de ruído, são: movimentos respiratórios, alterações na posição corporal, cicatrizes na pele, esgotamento do gel ou má conexão dos eletrodos com a pele devido à transpiração.

Figura 22 – Sinal de ECG com deslocamento da linha da base.



Fonte: (Maggio *et al.*, 2012)

A utilização de etapas de pré-processamento em sinais para análise de ECG desempenha o papel de lidar com a questão dos ruídos (Sörnmo; Laguna, 2006). Além disso, visa aprimorar a acurácia dos modelos, pois consegue revelar propriedades dinâmicas do sinal. Esta fase é composta essencialmente por um conjunto de algoritmos aplicados antes dos dados serem introduzidos em um algoritmo classificador, sendo adaptada de acordo com a aplicação e a base de dados utilizada. A Tabela 2 resume os ruídos apresentados e algumas

das propostas encontradas na literatura para lidar com a supressão ou a suavização da interferência detectada.

Tabela 2 – Tipos comuns de ruídos em ECG e soluções potenciais de filtragem.

Tipo de Interferência	Soluções propostas
Sinal Eletromiográfico (EMG)	Transformada Discreta de <i>Wavelet</i> (Joy; Manimegalai, 2013; Jenkal <i>et al.</i> , 2016; Marouf <i>et al.</i> , 2017); Filtros passa-baixa; Filtro de Aproximação Dependente da Inclinação do Sinal (Christov; Daskalov, 1999)
Interferência da linha de energia	Isolamento adequado e aterramento de fios e equipamentos; Filtro passa-banda; Transformada Discreta de <i>Wavelet</i> (Jenkal <i>et al.</i> , 2016), (Belgurzi; Elshafiey, 2017); Filtro Adaptativo (Wanl, 2006; Belgurzi; Elshafiey, 2017); Procedimento de Subtração (Levkov <i>et al.</i> , 2005)
Flutuação da linha de base	Filtros passa-alta lineares; Filtros polinomiais (Maggio <i>et al.</i> , 2012)

Fonte: Adaptado de (Rizwan *et al.*, 2021).

- **Variabilidade paciente-paciente.** Por fim, buscando uma realização eficiente da detecção automática de FA em sinais de ECG, é fundamental utilizar dados de diversos pacientes, uma vez que as condições de FA podem variar de um paciente para outro. Pois, ao incluir informações provenientes de diferentes características fisiológicas e condições de saúde, é possível obter resultados mais confiáveis, promovendo uma generalização mais abrangente do modelo computacional gerado. Dessa forma, a diversidade na base de dados contribui para aprimorar a capacidade do sistema de detecção em geral, tornando-o mais adaptável a uma ampla variedade de possíveis cenários clínicos. Isso se mostra essencial para a aplicabilidade do sistema em diferentes contextos clínicos.

4.2 Estudos relevantes em detecção FA

No contexto de detecção de FA em sinais de ECG, diversos métodos e tecnologias vêm sendo aplicados e desenvolvidas há muitas décadas, variando em termos dos atributos usados e que geralmente operam em diversos domínios: domínio do tempo, domínio da frequência, morfologia do sinal, características não lineares, extração de características automatizada e por fim, a mesclagem entre essas diferentes abordagens. A seguir, serão discutidos os trabalhos relevantes inseridos na detecção de FA em sinais de ECG que exploram estes domínios mencionados.

O trabalho de (Young *et al.*, 1999), desenvolvido em 1999, apresenta um dos estudos considerados pioneiros neste tema, que utilizou o método estocástico denominado Modelos

Ocultos de Markov, ou *Hidden Markov Models* (HMM). A pesquisa utilizou a base de dados AFDB e descobriu que o HMM superou outras características extraídas baseadas em entropia. A abordagem proposta alcançou 94,75% de Acurácia (ACC), 93,5% em termos de Especificidade (SPE) e 91,38% em Sensibilidade (SEN), e também apresentou melhor desempenho comparado às outras abordagens relacionadas.

No trabalho de (Tateno; Glass, 2001), foi introduzido o histograma de densidade dos RRI's e Δ RR (diferença entre dois RRI's sucessivos). O estudo demonstrou uma SEN de 94,4% e uma SPE de 97,2% quando testado no banco de dados de AFDB. Além disso, no trabalho, foi utilizado o teste de Kolmogorov-Smirnov para comparar de forma binária os histogramas extraídos com a condição de FA, e outro sem o diagnóstico.

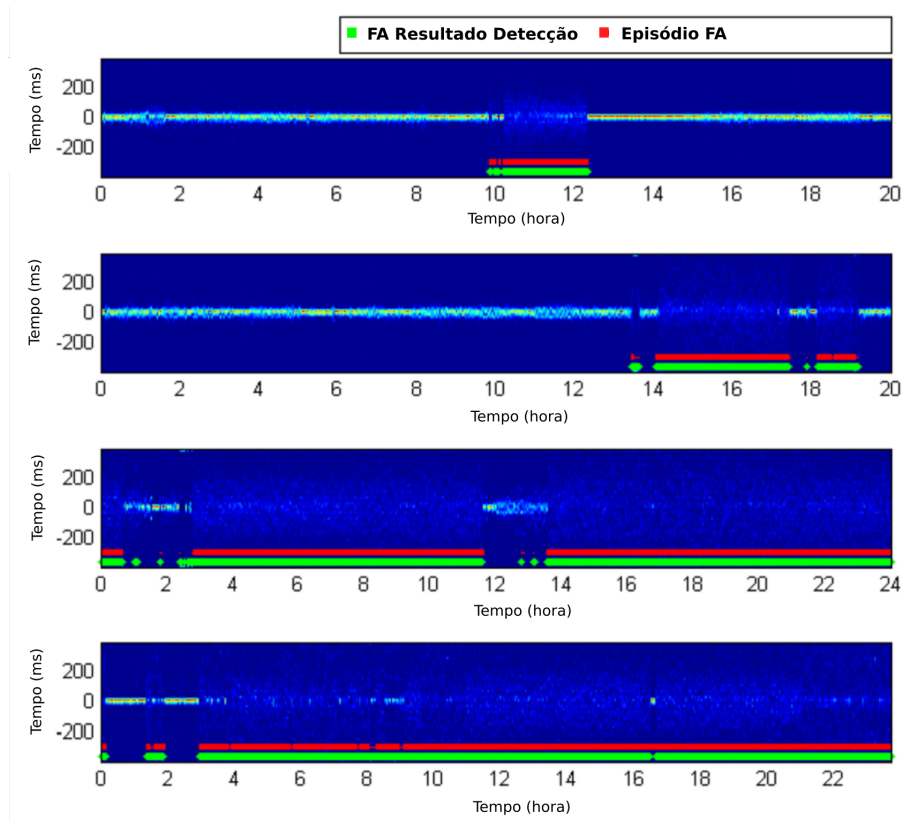
A pesquisa em (Li *et al.*, 2017) apresenta um método baseado em imagem usando Δ RR plotados em painéis de grade. O estudo também investiga características como a entropia e a distribuição de densidade de probabilidade de Δ RR. A Figura 23 ilustra a capacidade de detecção em quatro gravações da base de dados LTAfDB. O método emprega o vetor de máquina de suporte linear, ou *Linear Support Vector Machine* (LSVM), como é mais conhecido em inglês. O classificador conseguiu alcançar na base LTAfDB os seguintes resultados: 93,7% de ACC, 95,1% de SEN e 92,0% de SPE, com as amostras dispostas com um comprimento de passo de 60 segundos.

Em (Czabanski *et al.*, 2020), foram utilizadas as características da HRV que refletem a irregularidade ou variabilidade dos intervalos de tempo entre os batimentos cardíacos. O trabalho fez uso do classificador LSVM para rotulação do vetor de características, este, composto por dezesseis informações sobre irregularidade batimento a batimento propostas na literatura. O estudo demonstrou uma ACC de 98,6%, SEN de 98,9% e SPE de 98,4%. A base de dados utilizada foi a AFDB.

Análises no domínio da frequência, como a transformada rápida de Fourier e a análise Wavelet, foram exploradas para identificação de assinaturas espectrais características da FA (Houben *et al.*, 2010). No estudo de (Hu *et al.*, 2020), além da irregularidade dos RRI's, foi proposta uma característica adicional para a detecção: a amplitude máxima no espectro de frequência. O algoritmo de classificação utilizado foi a árvore de decisão, empregado com a base de dados AFDB. A ACC, SEN e SPE atingidas foram de, respectivamente, 98,9%, 97,93% e 99,63%.

O estudo em (Lown *et al.*, 2020) apresenta uma metodologia utilizando um gráfico

Figura 23 – Análise final do mapa dividido em painéis de grade (com resolução fixa de 20 ms no eixo y e comprimento de passo de 15 a 60 s no eixo x).



Fonte: (Li *et al.*, 2017).

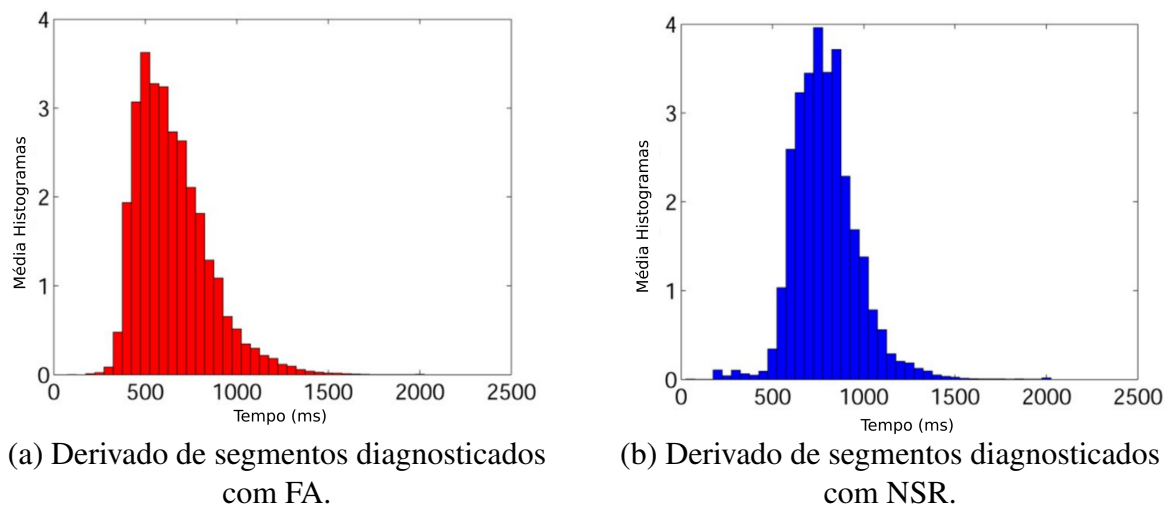
de Lorenz descorrelacionado de 60 RRIs consecutivos. O algoritmo compacta as imagens resultantes usando uma transformação *wavelet* e emprega o classificador *Support Vector Machine* (SVM). Os dados de treinamento consistiram nas bases AFDB e *Arrhythmia Database* (ADB), enquanto os dados de validação incluíram o RRI de um monitor de frequência cardíaca de consumo Polar-H7. Os resultados são: 100% de SEN e SPE de 97,6% nos dados de validação.

O trabalho em (Hirsch *et al.*, 2021) desenvolveu e avaliou um esquema híbrido usando o banco de dados AFDB. A técnica empregada combinou um total de 24 características extraídas dos RRIs e da AA derivadas de sinais de ECG. O estudo faz uso de diversos classificadores, mas ressalta o método Floresta Aleatória, por apresentar melhor desempenho para predição de FA. Os resultados foram: SEN de 98,0%, SPE de 97,4%, ACC de 97,6% e a pontuação *F1-Score* de 97,1%.

Em (Duan *et al.*, 2022), os autores propõem o uso da densidade de probabilidade dos RRIs em vez de características numéricas, como geralmente proposto em outros trabalhos. Essa metodologia se baseia em histogramas, que conseguem unificar várias informações estatísticas

em apenas um indicador. As Figuras 24 (a) e 24 (b) ilustram as médias de diversos histogramas. A Figura 24 (a) foi construída somente com segmentos diagnosticados com FA, enquanto a Figura 24 (b) foi construída a partir de segmentos diagnosticados com NSR, ou seja, sem anomalias rítmicas cardíacas. O trabalho também propõe o uso do classificador SVM com três bases de dados: AFDB, LTAfDB e NSRDB. Essa técnica alcançou uma ACC de 96,97%, SEN de 95,24% e SPE de 99,94%.

Figura 24 – A média dos histogramas de RRIs.



Fonte: (Duan *et al.*, 2022)

Em resumo, foi demonstrado nesta subseção que a detecção automatizada de FA em sinais de ECG é uma área de pesquisa em constante desenvolvimento e evolução, abrangendo um amplo ferramental que é continuamente explorado nos diversos domínios. Os estudos apresentados revelaram essa evolução significativa, onde os resultados obtidos mostram um avanço nas métricas dos sistemas de detecção e são melhores resumidos na Tabela 3. Finalmente, é evidente que, na maioria das abordagens apresentadas, a informação advinda dos RRIs é relevante e ainda está sendo explorada em trabalhos recentes, mostrando-se como uma característica importante para a atual e futuras pesquisas.

No entanto, desafios como a detecção precoce, a supressão de interferências de sinal e a necessidade de biomarcadores digitais mais específicos para uma determinada condição ainda são áreas que exigem mais investigação. A integração de novas tecnologias, como dispositivos vestíveis, análise de diversas bases de dados e o crescente uso da aprendizagem profunda, tem se mostrado propostas promissoras para aprimorar a detecção e o monitoramento da FA.

Tabela 3 – Resultados dos trabalhos relacionados (em ordem cronológica crescente).

	AFDB	NSRDB	LTAfDB	ADB	ACC (%)	SEN (%)	SPE (%)
(Young <i>et al.</i> , 1999)	✓				94,75	91,38	93,5
(Tateno; Glass, 2001)	✓				-	94,4	97,2
(Li <i>et al.</i> , 2017)				✓	93,7	95,1	92,0
(Czabanski <i>et al.</i> , 2020)	✓				98,6	98,9	98,4
(Hu <i>et al.</i> , 2020)	✓				98,9	97,93	99,63
(Lown <i>et al.</i> , 2020)	✓			✓	-	100	97,6
(Hirsch <i>et al.</i> , 2021)	✓				97,6	98,0	97,4
(Duan <i>et al.</i> , 2022)	✓	✓	✓		96,97	95,24	99,94

Fonte: Elaborado pelo autor.

4.2.1 Extração da AA em sinais ECG

Esta seção se dedica a apresentar a evolução nos estudos que se esforçaram em compreender os mecanismos da FA através da extração e análise da AA, uma vez que, durante a FA, os sinais independentes da AA, AV e entre outros ruídos, são misturados. Sendo assim, é permitido uma formulação como um problema de BSS para realizar a extração do sinal de interesse.

O estudo de (Rieta *et al.*, 2004) apresenta a utilização da técnica de ICA para reconstruir as fontes independentes de toda atividade cardíaca, demonstrando que a fonte da AA pode ser identificada por meio de um reordenamento baseado na curtose dos sinais separados, seguido por análise espectral das fontes sub-gaussianas. O trabalho se baseia na validação de três hipóteses para a aplicabilidade da técnica proposta neste contexto: AA e AV são geradas por fontes bioelétricas independentes; AA e AV possuem distribuição não gaussiana; e a geração de potenciais de ECG de superfície a partir de fontes cardioelétricas pode ser considerada um processo de propagação linear de banda estreita.

Em (Lathauwer, 2011), foi proposta uma modelagem de BSS através da BTM com um *rank* multilinear de $(Lr, Lr, 1)$. Para isso, definiu-se que as fontes poderiam ser extraídas a partir de um tensor de terceira ordem, construído a partir da estrutura de matrizes Hankel. Posteriormente, a aplicação desenvolvida em (Ribeiro *et al.*, 2015) abordou, pela primeira vez, a extração não invasiva da AA durante um episódio de FA sob a perspectiva tensorial, utilizando a decomposição de tensores por meio da Hankel-BTD. Os experimentos realizados demonstraram que a BTM apresenta desempenho superior a métodos baseados em matrizes, especialmente em cenários ruidosos e sob certas restrições. Posteriormente, em (Ribeiro *et al.*, 2016), foi proposta uma etapa de pré-processamento utilizando a PCA para atenuar os componentes ventriculares do

signal. A atenuação da AV e a preservação da AA melhoram o desempenho da BTM, permitindo a extração mais eficiente da AA em comparação com outros métodos.

Em (Oliveira; Zarzoso, 2018a) é realizada uma avaliação das fontes estimadas que são identificadas como potenciais sinais que podem representar a AA. É ressaltado também que os métodos clássicos de avaliação não funcionam em todas as ocasiões, mesmo quando utilizando as tradicionais técnicas matriciais de BSS. Para resolver, são propostos dois novos parâmetros, o primeiro consiste na força de contribuição da fonte extraída ao sinal original ECG. O segundo parâmetro é baseado na curtose do sinal no domínio da frequência. O método foi validado através de diversas técnicas envolvidas no contexto de BSS: PCA, RobustPCA-f (Zarzoso; Comon, 2010) e a BTM.

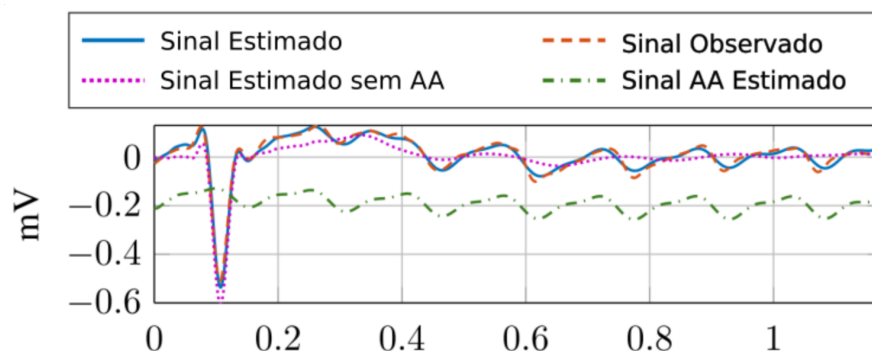
Na pesquisa em (Oliveira; Zarzoso, 2018c), buscou-se avaliar a estabilidade temporal da técnica Hankel-BTM, que em trabalhos anteriores mostrou-se uma promissora abordagem para problemas de BSS. Para isso, são realizados diversos experimentos em segmentos de um único trecho coletados de um único paciente com FA persistente. Este estudo é relevante pela sua contribuição na estimativa das fontes provenientes de ECG. Ao contrário de outros trabalhos realizados anteriormente, que foram limitados a apenas segmentos curtos.

No trabalho (Oliveira; Zarzoso, 2019), são discutidas as características da FA persistente, que geralmente se manifesta por curtos RRIs e um sinal proveniente da AA desorganizado e de baixa amplitude. Essas características dificultam a extração utilizando a técnica Hankel-BTM, que apresenta melhor desempenho em sinais com RRIs longos e uma AA bem definida. Para superar essas limitações, os fatores do modelo tensorial de terceira ordem são calculados usando a estrutura de matriz *Löwner* (Debals *et al.*, 2016). Experimentos realizados em simulações de Monte Carlo mostraram um melhor desempenho em relação à qualidade da extração da AA da BTM baseada em *Löwner* em comparação com outras abordagens desenvolvidas anteriormente, como a partir de matrizes de Hankel e das conhecidas técnicas baseadas em matrizes PCA e *RobustPCA-f*.

A pesquisa em (Goulart *et al.*, 2020) apresenta um novo método para calcular o tensor estimado através da BTM. O estudo destaca as dificuldades associadas ao uso do tradicional do algoritmo *Alternating Least Squares - Enhanced Line Search* (ALS-ELS) (Lathauwer; Nion, 2008), cujo desempenho pode ser comprometido pela escolha de parâmetros estruturais como: a quantidade de blocos R e do rank multilinear $(L_r, L_r, 1)$. Também é identificada uma sensibilidade à inicialização do algoritmo, que pode levar à degeneração do modelo, resultando

em uma estimação de blocos quase colineares sem interpretação física. Para superar esses problemas, o trabalho propõe o algoritmo de Grupo Lasso Alternado, conhecido em inglês como *Alternating Group Lasso* (AGL), juntamente com sua variante restrita, a *Constrained Alternating Group Lasso* (CAGL), que lida melhor com restrições lineares sobre matrizes de bloco. Aqui, *Lasso* significa *Least Absolute Shrinkage and Selection Operator*, ou Operador de Redução e Seleção Mínima Absoluta, uma técnica de análise de regressão que combina seleção e regularização de variáveis para melhorar a precisão da previsão e a interpretabilidade do modelo. Os experimentos realizados demonstraram a superioridade da técnica CAGL, sem a necessidade de definir anteriormente os parâmetros estruturais R e L_r . Além disso, em relação à inicialização dos parâmetros do modelo, o CAGL também se mostrou significativamente mais robusto em comparação com o ALS-ELS. Na Figura 25, os sinais estimados da AA estão representados graficamente, com o eixo x em segundos e deslocados verticalmente por $-0,2$ mV.

Figura 25 – Sinais observados e estimados a partir da derivação V1.



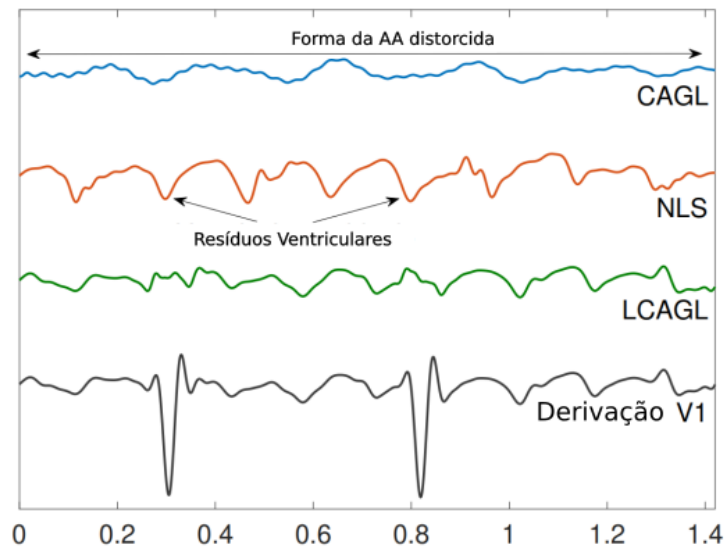
Fonte: Adaptado de (Goulart *et al.*, 2020).

No estudo de (Oliveira *et al.*, 2021), é explorada pela primeira vez uma aplicação do tensor BTD acoplado em sinais ECG, onde o acoplamento de BTDs é realizado a partir de BTDs individuais desenvolvidos por (Sørensen *et al.*, 2015). A técnica foi validada através de dados sintéticos que simulam uma FA e com dados reais de dois pacientes com FA persistente. Observou-se, referente à extração da AA, uma extração com desempenho superior a um custo computacional inferior comparada à abordagem utilizando Hankel-BTD.

Em (Oliveira *et al.*, 2022), é proposta uma nova abordagem denominada *Löwner Constrained Alternating Group Lasso* (LCAGL), que utiliza a estrutura de matriz *Löwner* em conjunto com o algoritmo CAGL para o cálculo da BTD. A estratégia adotada é realizar uma extração da AV em vez da AA, pois é comum em episódios de FA persistente que o sinal da AA

torne-se muito difícil de ser extraído e selecionado corretamente, devido à sua baixa amplitude ou a RRI curtos. A AV estimada pelo *Löwner*-BTD é então subtraída do sinal original ECG, resultando em um sinal que contém principalmente AA. A vantagem desta estratégia é a obtenção direta do sinal desejado (AA), pois não é necessária nenhuma técnica de seleção da fonte atrial. Os resultados demonstraram uma extração bem-sucedida da AA como pode ser ilustrado na Figura 26, mesmo utilizando um segmento com RRIs curtos, como um único batimento cardíaco, revelando que o método tem potencial para realizar a análise de FA. As estimativas do sinal AA foram deslocadas verticalmente para maior clareza.

Figura 26 – Contribuição obtida e estimada das fontes atriais para a derivação V1.



Fonte: Adaptado de (Oliveira *et al.*, 2022).

Como visto, os trabalhos apresentados anteriormente nesta subseção foram aplicações que se especializaram no uso da abordagem tensorial, especificamente com a técnica BTD, para realizar uma separação cega de fontes em sinais ECG. Além disso, essas pesquisas propuseram métricas para avaliar as fontes extraídas, com o objetivo de obter atributos e identificar a fonte que mais se assemelha à AA. Dessa forma, os cardiologistas podem realizar análises mais aprofundadas. No entanto, ainda não houve pesquisas envolvendo essa abordagem para detectar a condição de FA, ou seja, discriminar segmentos de sinais com FA ou sem a condição cardíaca. Portanto, este trabalho tem como objetivo utilizar toda essa base de conhecimento para realizar a extração de atributos a partir do sinal ECG e sua posterior classificação.

4.2.2 *Aprendizagem Profunda*

Abordando outras perspectivas, as técnicas de aprendizagem profunda são cada vez mais utilizadas para detectar a FA usando dados advindos de sinais de ECG. Esses métodos geralmente empregam redes neurais convolucionais, ou do inglês, *Convolutional Neural Network* (CNN), que buscam uma extração automatizada de características complexas dos sinais de ECG relacionadas à atividade atrial ou resposta ventricular, ou também uma combinação de ambos (Rizwan *et al.*, 2021), suportando o reconhecimento de padrões além da identificação humana (Siontis *et al.*, 2021; Khurshid *et al.*, 2022). O uso desta metodologia mostra-se promissora na detecção e contribui significativamente para o avanço clínico neste ramo (Lyon *et al.*, 2018), podendo ser combinada com diversas características extraídas manualmente, ou seja, usando métodos tradicionais de processamento de sinais. Essa abordagem atualmente demonstra potencial para aprimorar a precisão na detecção automatizada (Chen *et al.*, 2022), através da elevada capacidade em detectar segmentos diagnosticados com FA a partir de sinais de ECG.

Como exemplo, o estudo em (Andersen *et al.*, 2019) apresenta um modelo de aprendizagem profunda que utiliza uma combinação de CNNs e as Redes Neurais Recorrentes, ou do inglês, *Recurrent Neural Networks* (RNNs). O modelo foi treinado e validado em três bases de dados diferentes (AFDB, NSRDB e ADB), alcançando SEN e SPE de 98,98% e 96,95%.

Atualmente, esses sistemas têm demonstrado desempenho superior em comparação com métodos estatísticos tradicionais, evidenciando o potencial da aprendizagem profunda para aprimorar o diagnóstico de FA (Passman, 2021). Além disso, para aprimorar esses modelos, estão sendo desenvolvidas novas técnicas para suprimir o *overfitting* (Zhang *et al.*, 2021), um obstáculo presente em modelos complexos e caracterizado pelo ajuste excessivo aos dados de treinamento, capturando ruídos e padrões específicos desse conjunto. Essas técnicas podem ser aplicadas a dados comprimidos de ECG sem a necessidade de reconstrução (Cheng *et al.*, 2020). Por fim, há um crescente interesse dos pesquisadores em aplicações com essa nova abordagem, como evidenciado em (Liaqat *et al.*, 2020; Fujita; Cimr, 2019; Acharya *et al.*, 2017), abrindo caminho para melhores resultados clínicos no tratamento de doenças cardiovasculares.

5 TÉCNICA PROPOSTA

Este capítulo aborda a metodologia proposta para a detecção de FA a partir de sinais de ECG. Na Figura 27, é apresentada a estrutura do sistema desenvolvido, destacando os estágios fundamentais para a sua execução.

Figura 27 – Panorama da metodologia proposta.



Fonte: Elaborado pelo autor.

As seções a seguir abordam os seguintes tópicos:

- **Bases de Dados (Seção 5.1):** Apresenta as bases de dados selecionadas, as quais são: AFDB, LTAfDB e NSRDB.
- **Pré-processamento (Seção 5.2):** Descreve a preparação dos dados brutos para interpretação e consumo nas fases posteriores da metodologia.
- **Extração de Características (Seção 5.3):** Aborda a construção do vetor de características proposto para detecção de FA, incluindo os detalhes da nova proposta introduzida neste trabalho, que são os indicadores de convergência e otimização da BTd que serão conjuntamente dispostos com os RRIs de cada segmento.
- **Classificação:** Esta etapa utiliza os vetores de características obtidos anteriormente e será detalhada no Capítulo 6.

5.1 Bases de Dados

A obtenção de estimativas precisas e a realização de análises detalhadas são influenciadas pelos dados utilizados durante uma pesquisa, tanto em termos de quantidade, quanto de qualidade. Com grandes quantidades de dados, padrões mais robustos podem ser identificados, levando a melhores resultados no geral (Halevy *et al.*, 2009). Além disso, um conjunto amplo de bases de dados é fundamental para reconhecer a natureza complexa do assunto em estudo. Neste trabalho, três bases de dados foram selecionadas para auxiliar na validação da abordagem sugerida. As bases são:

- **MIT-BIH Fibrilação Atrial (AFDB)** (Goldberger *et al.*, 2000): O banco de dados inclui 25 gravações, principalmente de FA paroxística. Os registros 00735 e 03665 não foram inclusos pois possuem batimentos cardíacos que não foram auditados, ou seja, não possuem as informações necessárias para a extração dos RRIs. Cada gravação possui 10 horas de duração e contém duas derivações do ECG, os sinais foram amostrados em 250 Hz com resolução de 12 bits em uma faixa de ± 10 mV.
- **MIT-BIH Fibrilação Atrial de Longa Duração (LTAfDB)** (Goldberger *et al.*, 2000): Este banco de dados contém 84 gravações de longa duração de indivíduos que sofreram FA paroxística ou persistente. Cada gravação é composta por duas derivações de ECG, ambos digitalizados na frequência de 128 Hz e resolução de 12 bits, abrangendo uma faixa de ± 20 mV. A duração das gravações podem variar, mas geralmente dura entre 24 e 25 horas.
- **MIT-BIH Ritmo Sinusal Normal (NSRDB)** (Goldberger *et al.*, 2000): O banco de dados contém registros de ECG de pacientes em ritmo sinusal normal, ou seja, sem anormalidades cardíacas. Esta base de dados contém 18 registros de duas derivações ECGs, cada gravação possui duração entre 20 e 24 horas. A frequência de amostragem da base é de 128 Hz.

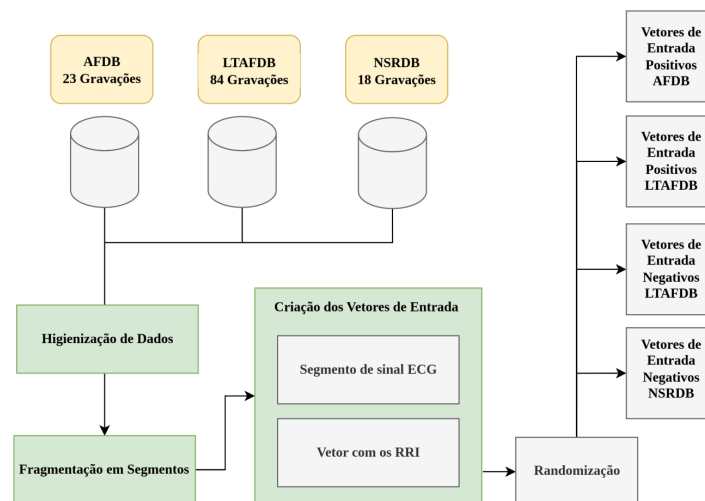
Dentre estas bases, cada registro é acompanhado por um arquivo de cabeçalho com o formato *.hea*. Esses arquivos fornecem metadados básicos sobre os sinais contidos em cada arquivo de gravação, pois contém informações sobre as características do sinal de ECG, tais como: taxa de amostragem do sinal, resolução da amostragem, número de derivações, entre outras informações. Muitas ferramentas de *software* e bibliotecas de processamento de sinais de ECG suportam a leitura e interpretação destes cabeçalhos de gravação, facilitando o trabalho dos pesquisadores. Já os arquivos de anotação (*.atr* e *.qrs*) fornecem informações sobre os eventos específicos e marcações temporais associadas aos registros de ECG, tais como: a presença de batimentos cardíacos, complexos QRS, início e fim do diagnóstico de condições cardíacas (como a FA) e outros eventos de interesse clínico. Estas marcações são essenciais para uma extração adequada dos RRIs, descartando a possibilidade de utilização de um algoritmo especializado somente para realizar a detecção das ondas R.

5.2 Pré-processamento

A etapa de coleta e preparação dos dados consiste em uma série de procedimentos que visam garantir a consistência dos dados e aumentar a variabilidade entre as gravações para as fases subsequentes da técnica proposta. O diagrama de fluxo apresentado na Figura 28 auxilia

na compreensão desses procedimentos. Assim, a ideia central desta fase é criar um vetor de entrada para a etapa de extração de atributos a partir de cada segmento de todas as gravações. Nesse contexto, o vetor de entrada refere-se ao conjunto de dados formado pelo segmento do sinal ECG e seus respectivos RRIs do segmento, os quais são coletados do arquivo de cabeçalho da gravação.

Figura 28 – Procedimentos voltados para a coleta e preparação dos vetores de entrada.




Fonte: Elaborado pelo autor.

Como ilustrado, o processo se inicia com a transferência das bases de dados selecionadas para o ambiente local de trabalho, as quais já possuem as gravações por paciente separadas em cada arquivo *.dat*. Em seguida, as gravações são submetidas a uma etapa de higienização, na qual são removidas aquelas que não possuem os sinais auditados. Posteriormente, os trechos de gravações que são de interesse para a pesquisa, trechos diagnosticados com FA ou NSR, foram separados para a próxima etapa, que consiste na segmentação em trechos de 5 batimentos por segmento, ou RRIs. Um trecho de ECG é ilustrado na Figura 29.

A configuração adotada para o tamanho de trecho do sinal usado nesta pesquisa se deve ao fato de que a metodologia de extração de atributos investiga duas características de naturezas distintas (parâmetros BTB e os RRIs), as quais, em trabalhos relacionados são abordadas com diferentes tamanhos de segmento. Os RRIs são frequentemente explorados de diversas formas, principalmente em termos de histograma, o que leva à escolha de segmentos de sinal de maior comprimento. Por exemplo, em (Duan *et al.*, 2022), foi proposta uma segmentação com 30 RRIs para elaboração dos histogramas. Por outro lado, torna-se computacionalmente impraticável calcular o tensor estimado em grandes segmentos de sinal usando a BTB. Em

Figura 29 – Um trecho de sinal diagnosticado com FA composto por 5 batimentos.



Fonte: Elaborado pelo autor.

trabalhos relacionados a problemas envolvendo BSS, que buscam a extração da AA através da BTD, apenas uma única batida cardíaca (o complexo QRS em conjunto com o segmento TQ) é selecionada, conforme evidenciado em (Oliveira; Zarzoso, 2018a; Oliveira; Zarzoso, 2018b; Oliveira *et al.*, 2021). Nestes trabalhos, também é mencionado que a vantagem dos métodos tensoriais em comparação aos baseados em matrizes, em especial com a BTD, é o seu desempenho na extração da AA a partir de registros de ECG de curta duração (Oliveira *et al.*, 2021).


Finalmente, após a criação dos pacotes de dados (vetores de entrada) formados pela combinação do sinal ECG e seus respectivos RRIs, foi então aplicado um passo de randomização com o objetivo de aumentar a generalização entre os segmentos obtidos e evitar o sobreajuste do modelo resultante. Esse processo também levou em consideração a origem da gravação, garantindo que segmentos de uma mesma gravação não fossem selecionados com uma maior frequência para a etapa de extração de características. A Tabela 4 apresenta uma análise quantitativa dos segmentos de ECG classificados por tipo de ritmo cardíaco (FA e NSR) nas bases de dados selecionadas (AFDB, LTAfDB e NSRDB). A Figura 30 ilustra as distribuições (em termos de porcentagem) dos dados expostos na Tabela 4.

Tabela 4 – Total dos vetores de entrada extraídos (por diagnóstico) das bases de dados selecionadas.

Base de dados	Quant. Segmentos (FA)	Quant. Segmentos (NSR)	Total
AFDB	101497	-	101497
LTAfDB	618183	538877	1157060
NSRDB	-	361348	361348
Total	719680 (44,43 %)	900225 (55,57 %)	1619905

Fonte: Elaborado pelo autor.

Figura 30 – Distribuição (em termos de porcentagem) da quantidade total de segmentos coletados.



Fonte: Elaborado pelo autor.

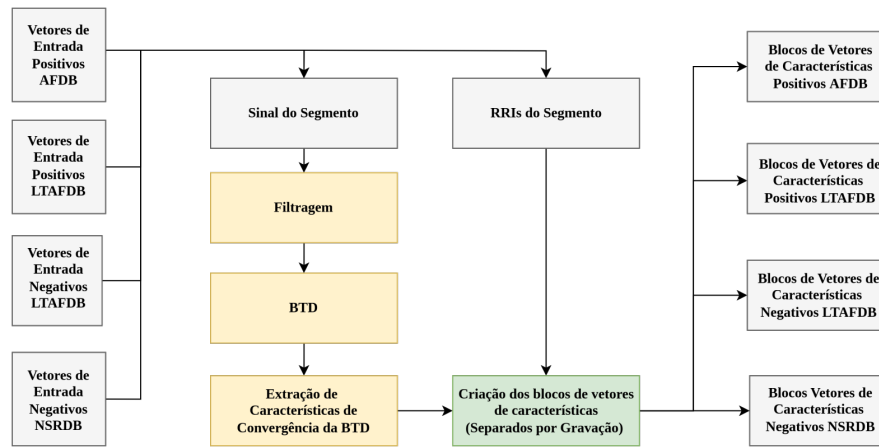
5.3 Extração de Características

As próximas etapas estão relacionadas à obtenção dos vetores de características a partir dos vetores de entrada coletados na etapa anterior. A Figura 31 resume os procedimentos aplicados por meio de um diagrama de fluxo.

Aqui, o sinal é extraído de cada vetor de entrada para ser utilizado nas etapas de filtragem, hankelização, execução da BTD e, finalmente, extração de características relacionadas à convergência da decomposição. Para a filtragem, foi utilizado um filtro *Chebyshev* passa-banda tipo II, que eliminou frequências inferiores a 0,35 Hz e superiores a 70 Hz. A Subseção 5.3.1 detalha as etapas da BTD e os parâmetros empregados.

A Tabela 5 apresenta a distribuição dos vetores de características prontos para

Figura 31 – Procedimentos voltados para a preparação dos vetores de características.



Fonte: Elaborado pelo autor.

validação, os quais estão separados por gravação das bases de dados LTAfDB, NSRDB e AFDB.

5.3.1 Extração de Características de Convergência da BTD

Esta pesquisa propõe uma nova técnica de detecção de FA que baseia-se nos indicadores de otimização e convergência da BTD. A abordagem pressupõe que a decomposição de um segmento com FA pela BTD não tenha desempenho semelhante a um segmento de ritmo cardíaco saudável, o qual convergirá de forma menos eficiente. Isso se refletiria nos indicadores de convergência e otimização do algoritmo, permitindo uma separação efetiva. A motivação por trás desta hipótese é que a decomposição tensorial Hankel-BTD com sinais ECG só possui garantia de unicidade quando aplicada em sinais com presença de FA. Isso se deve ao fato de que, quando o sinal ECG possui FA, as fontes atriais presentes podem ser modeladas por modelos do tipo só-polos (*all-pole filters*) (Zarzoso, 2017), também conhecidos como modelo exponencial, da seguinte forma:

$$s_{r,n} = \sum_{l=1}^{L_r} \lambda_{l,r} z_{l,r}^{(n-1)} \quad (5.1)$$

para $r = 1, \dots, R$, sendo r a r -ésima fonte atrial estimada, $n = 1, \dots, N$, n representa o índice de tempo discreto, L_r é o número de termos exponenciais, $z_{l,r}$ é o l -ésimo polo da r -ésima fonte, e $\lambda_{l,r}$ é o coeficiente de escala.

Esta modelagem das fontes atriais garante que as condições de unicidade da decomposição Hankel-BTD sejam satisfeitas. De fato, pode-se demonstrar que, quando as fontes

Tabela 5 – Distribuição dos vetores de características prontos para validação (separados por gravação).

Base	Classe	Gravação	Nº Segmentos / Gravação	Total
AFDB	FA	04126, 04746, 04908, 04936, 05121, 06426, 06995, 07162, 07859, 07879, 07910, 08215, 08219, 08378, 08405, 08434 e 08455	200	3400
		04043	1000	1000
		05261	178	178
		04048	158	158
		04015	99	99
		06453	84	84
		05091	22	22
NSRDB	NSR	16265, 16272, 16273, 16420, 16483, 16539, 16773, 16786, 16795, 17052, 17453, 18177, 18184, 19088, 19090, 19093, 19140 e 19830	200	3600
LTAfDB	NSR	00, 01, 03, 05, 06, 07, 08, 10, 100, 101, 102, 103, 104 e 105	200	2800
LTAfDB	FA	00, 01, 03, 06, 07, 100, 101, 102, 103 e 104	200	2000
		08	34	34
		05	11	11
Total				13386

Fonte: Elaborado pelo autor.

atriais são aproximadas por modelos tipo só-polos, as matrizes de Hankel usadas no método Hankel-BTD podem ser expressas através da decomposição de Vandermonde, como mostrado em (5.2). Em (3.12), o $\mathbf{H}_S^{(r)}$ desenvolvido é uma matriz de Hankel construída a partir da r -ésima linha de \mathbf{S} , onde $\mathbf{S} \in \mathbb{R}^{I \times J}$.

$$\mathbf{H}_S^{(r)} = V_r \text{diag}(\lambda_{1,r}, \lambda_{2,r}, \dots, \lambda_{L,r}) \hat{V}_r^T, \quad (5.2)$$

com

$$V_r = \begin{bmatrix} 1 & 1 & \dots & 1 \\ z_{1,r} & z_{2,r} & \dots & z_{L_r,r} \\ \vdots & \vdots & \ddots & \vdots \\ z_{1,r}^{I-1} & z_{2,r}^{I-1} & \dots & z_{L_r,r}^{I-1} \end{bmatrix} \in \mathbb{R}^{I \times L_r}, \quad (5.3)$$

e

$$\hat{V}_r = \begin{bmatrix} 1 & 1 & \dots & 1 \\ z_{1,r} & z_{2,r} & \dots & z_{L_r,r} \\ \vdots & \vdots & \ddots & \vdots \\ z_{1,r}^{J-1} & z_{2,r}^{J-1} & \dots & z_{L_r,r}^{J-1} \end{bmatrix} \in \mathbb{R}^{J \times L_r}. \quad (5.4)$$

Em caso de polos diferentes, tal como descrito em (Zarzoso, 2017), a matriz de Vandermonde com $L_r \leq I, J$ terá posto completo nas colunas L_r , então se M não tiver colunas proporcionais, a BTD desenvolvida em (3.12) será essencialmente única. No caso de polos iguais, condições mais brandas podem garantir a unicidade de (3.12). Os resultados experimentais de trabalhos anteriores demonstram a relevância dessa abordagem e sua superioridade potencial sobre sinais ECG com a condição cardíaca de FA (Oliveira; Zarzoso, 2018c; Oliveira; Zarzoso, 2019). Especificamente, ao estimar o tensor em um segmento de sinal que não possui FA, não há uma garantia de unicidade da decomposição, o que espera-se que os parâmetros de cálculo da BTD sejam divergentes dos segmentos que foram diagnosticados com FA.

Para realizar o cálculo da BTD, foi empregado o *software* MATLAB em conjunto com a *toolbox* TensorLab (Vervliet *et al.*, 2016). O Tensorlab abrange um conjunto de implementações destinadas à análise de dados multidimensionais, destacando-se como uma ferramenta amplamente utilizada para lidar com a natureza complexa dos tensores, especialmente na aplicação de algoritmos envolvendo decomposições tensoriais. Em particular, o método empregado nos procedimentos experimentais desta pesquisa, para a decomposição Hankel-BTD de ordem $(L_r, L_r, 1)$, foi o método NLS, fazendo uso do algoritmo de *Gauss-Newton* (Ribeiro *et al.*, 2015). Para a execução do algoritmo, é preciso inicialmente obter as matrizes fatores iniciais para o cálculo da BTD, para isso, foi utilizada a função *lll_rnd* que gera a estrutura pré-definida e pseudoaleatória a partir dos parâmetros estruturais: *rank* R (número de blocos) e o rank multilinear $(L_r, L_r, 1)$ de cada bloco. Os detalhes da utilização da função são melhores definidas na Tabela 6.

Cada bloco contém exatamente quatro componentes: duas matrizes, um vetor e um tensor central. É importante ressaltar que a função *lll_rnd*, dentre outras com a abordagem

Tabela 6 – Especificações da função *lll_rnd* (Tensorlab).

Nome da Função	@ <i>lll_rnd</i>
Propósito	Inicialização pseudoaleatória para a decomposição $(L_r, L_r, 1)$ de um tensor.
Entrada	<ul style="list-style-type: none"> – <i>size_tens</i>: Dimensões do tensor a ser estimado. – <i>L</i>: Vetor de tamanho R, onde cada posição é L_r de cada bloco. – <i>options</i> (opcional): Opções para a geração dos termos.
Saída	<ul style="list-style-type: none"> – U_{init}: Matrizes fatores iniciais pseudoaleatórias correspondentes à decomposição $(L_r, L_r, 1)$.
Uso	$[U_{init}] = \text{lll_rnd}(\text{size_tens}, L)$.

$(L_r, L_r, 1)$, normalizam o tensor central para a matriz identidade. Nos experimentos, o parâmetro R foi fixado em 5, o rank multilinear L_r estabelecido em 17 e, o número máximo de iterações foi limitado a 1000 execuções. Essa configuração foi baseada no trabalho de (Zarzoso, 2017), no qual esses ajustes forneceram os melhores resultados para a estimativa do sinal AA a partir do ECG. A Tabela 7 especifica a função *lll_nls*, responsável por computar a BTM e gerar os parâmetros de interesse desta pesquisa. Esta função utiliza as matrizes fatores iniciais obtidas a partir da Tabela 6 e o tensor \mathcal{T} , construído a partir do segmento ECG que sofre o processo de Hankelização.

A abordagem selecionada retorna resultados específicos referente à sua execução, os quais são os indicadores utilizados neste trabalho. Esses indicadores são:

- **relfval**: A diferença no valor da função objetivo entre duas iterações sucessivas, em relação ao seu valor inicial;
- **relerr**: O erro relativo entre o tensor original e seu modelo BTM estimado.
- **fval**: O valor da função objetivo em cada iteração;
- **relstep**: O tamanho do passo em relação à norma da iteração atual em cada iteração;
- **delta**: O raio da região de confiança em cada iteração;
- **rho**: A confiabilidade em cada tentativa de iteração;
- **iter**: Número de iterações até atingir **fval**;

A seguir, serão apresentados alguns indicadores que conseguem expressar a relevância da utilização desses indicadores de convergência da BTM para a distinção entre FA e NSR. A Figura 32 ilustra, de forma gráfica, a evolução dos valores de cada amostra para os parâmetros da BTM, onde é possível visualizar a possibilidade de implementação de uma abordagem capaz

Tabela 7 – Especificações da função *lll_nls* (Tensorlab).

Nome da Função	@ <i>lll_nls</i>
Propósito	Calcular a decomposição em termos de blocos com <i>rank multilinear</i> ($L_r, L_r, 1$) a partir do tensor \mathcal{T} usando o método dos mínimos quadrados não lineares.
Entrada	<ul style="list-style-type: none"> – \mathcal{T}: Tensor a ser estimado. – U_{init}: Estimativa inicial para as matrizes de fatores. – L_r (opcional): Número de colunas em cada matriz fator. – <i>algorithm</i>: Escolha do método de otimização (<i>@nls_gndl</i>, <i>@nls_gncgs</i>, <i>@nls_lm</i>). – <i>output format</i>: Formato de saída (<i>btd</i> ou <i>cpd</i>). Se não for fornecido, o mesmo formato da entrada será utilizado. – Outras opções podem ser repassadas através do método de otimização selecionado em <i>algorithm</i>.
Saída	<ul style="list-style-type: none"> – U: Matrizes fatores correspondentes à decomposição ($L_r, L_r, 1$). – <i>output</i>: Parâmetros de otimização e convergência obtidos na última iteração do cálculo.
Uso	$[U, output] = lll_nls(T, U_{init})$.

Fonte: Elaborado pelo autor.

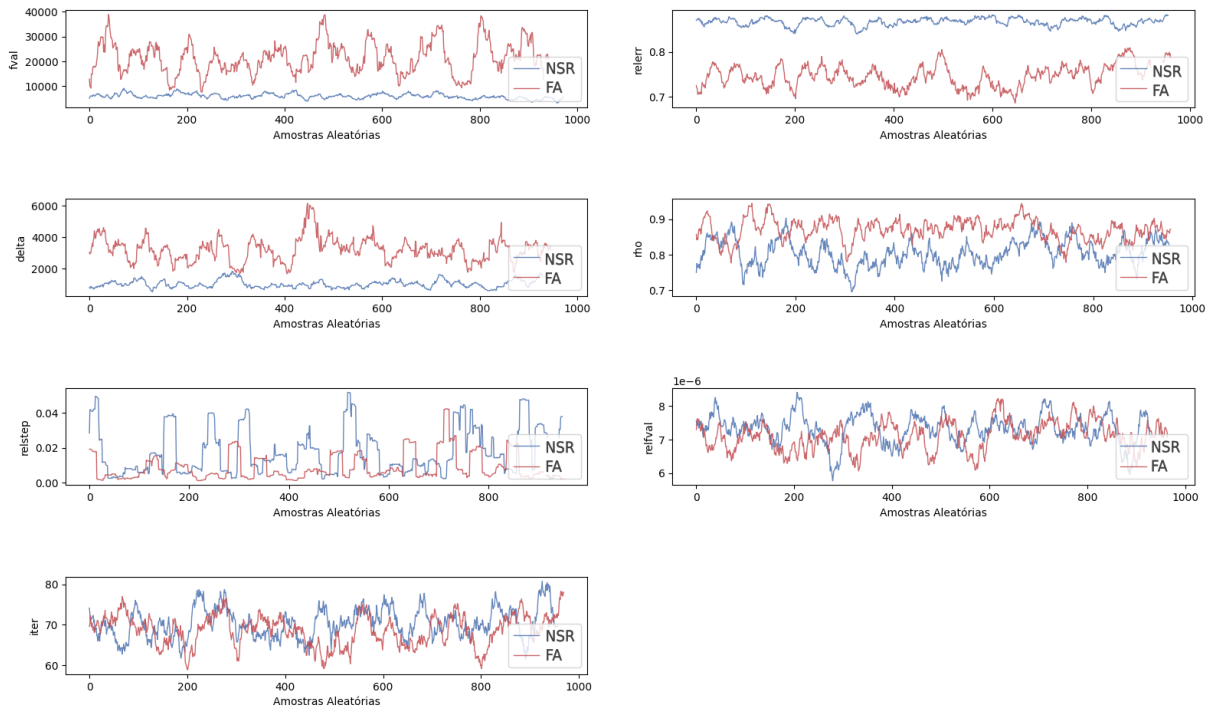
de realizar a discriminação entre as duas classes, NSR e FA.

Entretanto, alguns passos foram necessários para obtenção destes resultados evidenciados na Figura 32, os procedimentos foram:

- **Seleção das Amostras:** Foram selecionados 1000 conjuntos aleatórios de parâmetros extraídos dos dados obtidos e descritos na Tabela 5.
- **Filtro Z-score:** O *Z-score*, também conhecido como *escore padrão*, é um valor que indica quantos desvios padrão um ponto de dados está acima ou abaixo da média. O limite estabelecido para a filtragem foi o valor 3.
- **Convolução:** O resultado final foi gerado por meio de uma janela de convolução de tamanho 25 dentre as amostras selecionadas.
- **Média do sinal:** Esse procedimento foi repetido 1000 vezes e em seguida, foi calculada a média das execuções para a plotagem do gráfico.

O potencial de separação de cada parâmetro também pode ser consultado a partir das métricas que foram coletadas e ilustradas na Figura 33, onde as pontuações de relevância de detecção foram ressaltadas para cada uma das características. Essas pontuações foram obtidas através do algoritmo *XGBoost* e têm como base a frequência de uso de cada recurso nas divisões


Figura 32 – Evolução dos valores de cada parâmetro BTD.



Fonte: Elaborado pelo autor.

dos dados em todas as árvores do conjunto.

Figura 33 – Pontuações médias de relevância das características em *XGBoost* para detecção de FA.



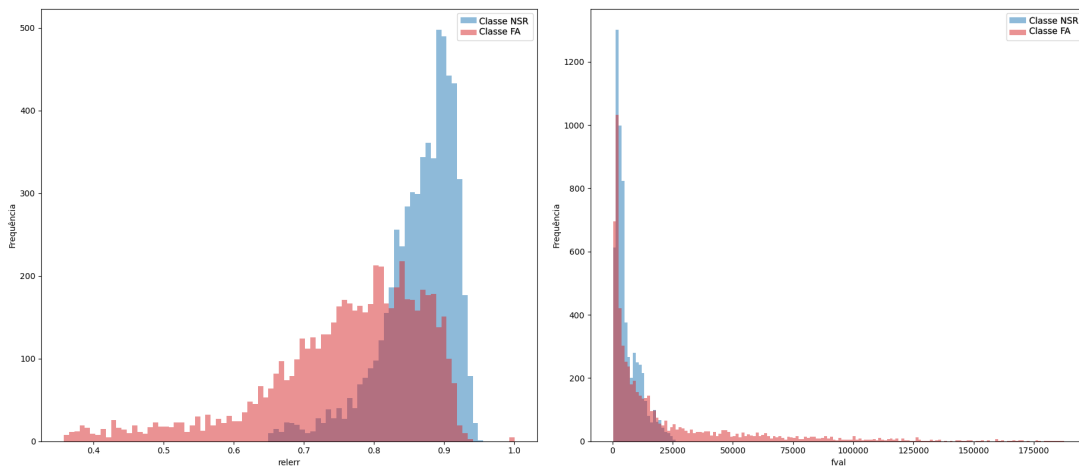
Fonte: Elaborado pelo autor.

A importância de cada recurso é calculada como a redução total normalizada do critério conduzido por uma determinada característica, sendo também conhecida como índice de

Gini. Essas pontuações proporcionam uma compreensão sobre a influência de cada característica no processo de tomada de decisão do modelo gerado. Geralmente, características com pontuações de importância mais altas são consideradas mais relevantes para a classificação. Esses resultados foram obtidos a partir de todas as amostras coletadas (Tabela 5) e utilizando uma validação cruzada com 10 *folds*, dessa forma, após processar cada *fold*, foi calculada a média e o desvio padrão das pontuações médias de importância, que são evidenciadas logo acima de cada barra da Figura 33.

Já na Figura 34, foram gerados os histogramas que comparam as distribuições das duas classes distintas dos dados com base nas características *relerr* e *fval*, que apresentaram maior relevância discriminatória de acordo com as métricas obtidas nas Figuras 32 e 33. Esse tipo de visualização é comumente usado em análise de dados para comparar distribuições e identificar padrões ou diferenças entre classes. Os dados passaram por uma normalização, de forma que a média seja zero e o desvio padrão seja igual a um. Como resultado, observa-se que seus histogramas possuem uma morfologia ligeiramente diferente, sugerindo que as classes FA e NSR podem ser discriminadas com base nessas características quando utilizadas em conjunto.

Figura 34 – Histogramas obtidos a partir do parâmetro *relerr* para as classes FA e NSR.



Fonte: Elaborado pelo autor.

Em ambos os indicadores coletados nas Figuras 32, 33 e 34, foi observado que os três parâmetros que mais contribuem para a realização de uma possível separação entre as classes FA e NSR são, respectivamente, os atributos *relerr*, *fval* e *delta*. Esses indicadores serão explorados nas simulações realizadas e descritas no próximo capítulo, com o intuito de coletar os resultados desta pesquisa. Por outro lado, os indicadores que não contribuem de forma significativa e não serão utilizados posteriormente são: *relfval*, *rho*, *relstep* e *iter*.

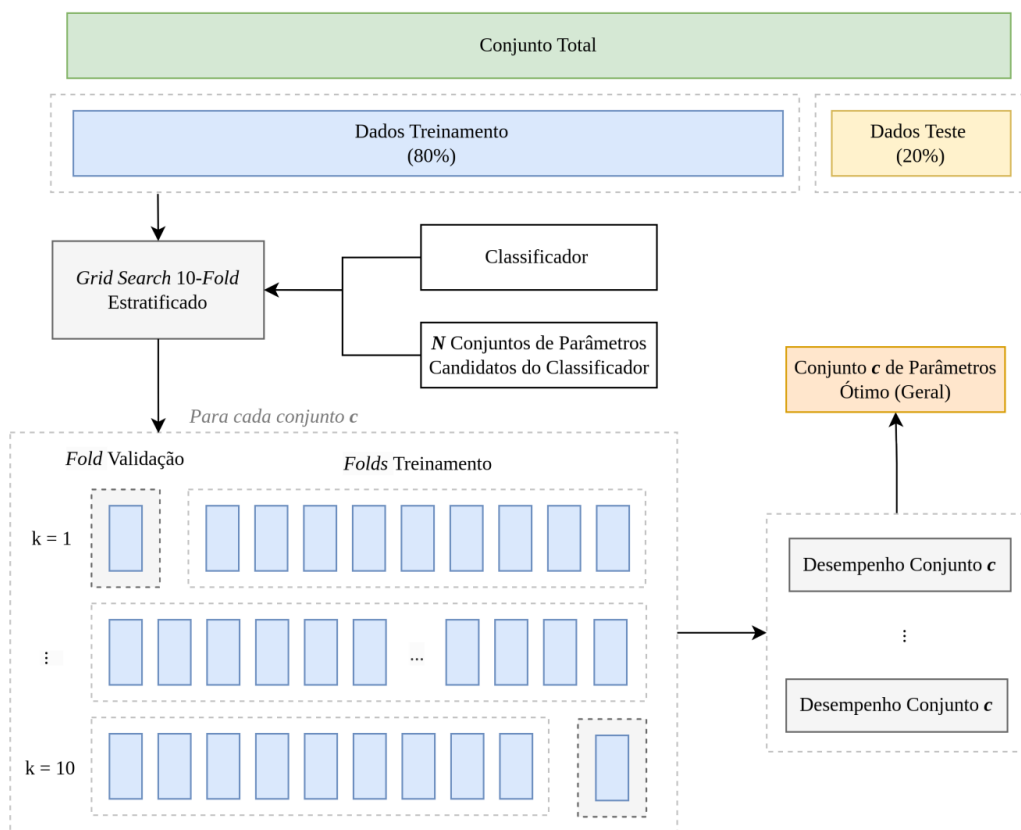
6 RESULTADOS

Este capítulo apresenta os resultados de simulação obtidos sobre diferentes perspectivas, com o objetivo de avaliar o desempenho e o comportamento da técnica proposta.

6.1 Configuração dos classificadores

Esta seção explora a estratégia adotada para ajustar os hiperparâmetros dos classificadores (apresentados na Seção 3.10), com o objetivo de extrair os melhores resultados de cada algoritmo. Os ajustes realizados em cada hiperparâmetro foram feitos com a técnica de busca em grade (ou do inglês, *grid search*). Esta técnica é uma abordagem clássica para ajustar os hiperparâmetros aos dados em um modelo de aprendizado de máquina, pois realiza todas as combinações possíveis entre as configurações especificadas, avaliando o desempenho com base na taxa de acerto (ou outra métrica de interesse) do modelo. Embora computacionalmente custosa, a técnica de busca em grade garantiu resultados mais confiáveis para a detecção de FA. A estrutura apresentada na Figura 35 ilustra a estratégia de ajuste implementada.

Figura 35 – Abordagem elaborada para ajuste de hiperparâmetros.



Fonte: Elaborado pelo autor.

Como ilustrado na Figura 35, esta etapa destina-se exclusivamente à seleção dos hiperparâmetros usando validação cruzada com *k-fold*. Os dados utilizados para este procedimento foram previamente selecionados a partir de uma porção de 80% do conjunto total, enquanto os 20% restantes foram mantidos separados como conjunto de teste, ou seja, uma porção de dados que serão usados somente para avaliar o desempenho do modelo em dados não vistos. Aqui, a técnica *grid search* foi combinada com a validação cruzada *k-fold* ($k = 10$) na porção de 80% dos dados, permitindo, uma busca mais consistente pelos hiperparâmetros mais adequados para os dados fornecidos. A amostragem empregada durante o *k-fold* foi o método estratificado, garantindo a preservação da distribuição de amostras de cada classe em cada *fold* em relação ao conjunto total de amostras. A Tabela 8 apresenta os valores candidatos que foram usados para cada hiperparâmetro. Os valores configurados por padrão pela biblioteca de origem estão destacados em negrito.

Tabela 8 – Parametrização dos classificadores.

Algoritmo	Hiperparâmetro	Valores Candidatos	Ajustados
Floresta Aleatória (1944 Conjuntos)	<i>n_estimators</i>	100 , 200, 300	200
	<i>max_depth</i>	Nenhum, 10, 20, 30	Nenhum
	<i>min_samples_split</i>	2 , 5, 10	2
	<i>min_samples_leaf</i>	1 , 2, 4	1
	<i>max_features</i>	Nenhum, sqrt , <i>log2</i>	<i>log2</i>
	<i>criterion</i>	gini , <i>entropy</i>	<i>gini</i>
Boosting de Gradiente (972 Conjuntos)	<i>n_estimators</i>	50, 100 , 200	200
	<i>learning_rate</i>	0.1 , 0,01, 0,001	0,1
	<i>max_depth</i>	Nenhum, 3 , 7	Nenhum
	<i>criterion</i>	friedman_mse , <i>squared_error</i>	<i>friedman_mse</i>
	<i>min_samples_split</i>	2 , 5, 10	2
	<i>max_features</i>	Nenhum, <i>sqrt</i> , <i>log2</i>	<i>log2</i>
Árvores Extremamente Aleatórias (648 Conjuntos)	<i>n_estimators</i>	100 , 200, 300	100
	<i>criterion</i>	gini , <i>entropy</i>	<i>entropy</i>
	<i>max_depth</i>	Nenhum, 10, 20, 30	Nenhum
	<i>min_samples_split</i>	2 , 5, 10	2
	<i>min_samples_leaf</i>	1 , 2, 4	1
	<i>max_features</i>	Nenhum, <i>sqrt</i> , <i>log2</i>	Nenhum
Boosting de Gradiente Extremo (1296 Conjuntos)	<i>booster</i>	gbtree , <i>gblinear</i> , <i>dart</i>	<i>gbtree</i>
	<i>learning_rate</i>	0,05, 0,1, 0.3	0,1
	<i>gamma</i>	0 , 0,1, 1	0
	<i>max_depth</i>	6 , 10, 15	15
	<i>reg_lambda</i>	0, 0,1, 1 , 10	1
	<i>reg_alpha</i>	0 , 0,1, 1, 10	0
Máquina de Boosting de Gradiente Leve (256 Conjuntos)	<i>num_leaves</i>	20, 31 , 40, 50	50
	<i>learning_rate</i>	0,0001, 0,001, 0,01, 0.1	0,1
	<i>max_depth</i>	Nenhum, 5, 10, 15	Nenhum
	<i>n_estimators</i>	50, 100 , 200, 300	300

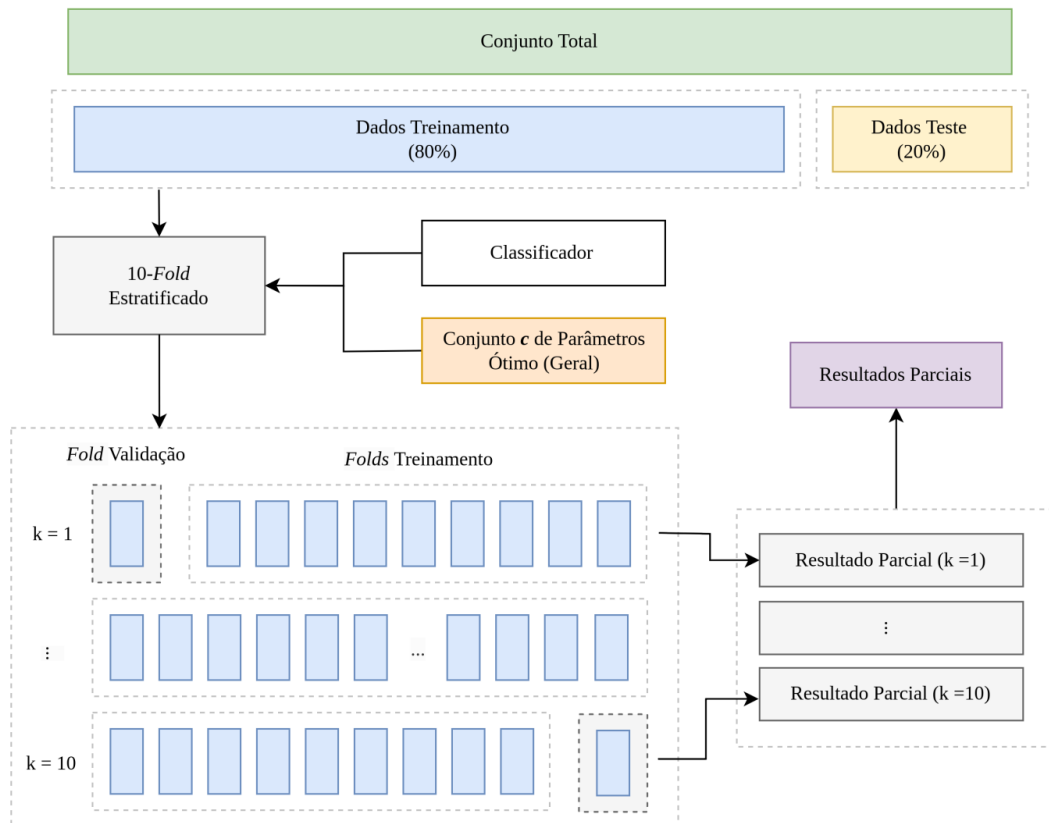
Fonte: Elaborado pelo autor.

Após a obtenção do desempenho de cada conjunto de hiperparâmetro, o conjunto que obteve a maior pontuação em termos de acurácia foi separado (coluna Ajustados). Os classificadores e a técnica *grid search* foram implementados utilizando a biblioteca *scikit-learn* (versão 1.2.2), uma ferramenta de código aberto amplamente utilizada para aprendizado de máquina para a linguagem de programação *Python*, que oferece uma variedade de algoritmos de classificação, pré-processamento de dados e métricas de avaliação. Mais especificamente, para utilizar os algoritmos LightGBM e *XGBoost*, foram empregadas as bibliotecas *Python* de código aberto *lightgbm* (versão 4.3.0) e *xgboost* (versão 1.7.6), respectivamente.

6.2 Resultados com Validação Cruzada

Após encontrar os conjuntos de hiperparâmetros que mais se ajustaram aos dados em cada classificador, esta seção apresenta os resultados preliminares da pesquisa e valida o método utilizado anteriormente para seleção dos hiperparâmetros. A Figura 36 ilustra a abordagem de validação adotada, onde foi realizado o método de validação cruzada *k-fold* estratificado.

Figura 36 – Abordagem para obtenção dos resultados com validação cruzada.



Fonte: Elaborado pelo autor.

Após a execução da abordagem ilustrada na Figura 36, os resultados obtidos por cada classificador combinado com seu respectivo conjunto de hiperparâmetros ótimo são apresentados na Tabela 9. Nesta Tabela são destacados os *fold*s que obtiveram o melhor desempenho em cada simulação em termos de sensibilidade, juntamente com a média e o desvio padrão em relação aos demais *fold*s de cada simulação. A sensibilidade foi escolhida como métrica para a seleção do *fold*, devido à sua capacidade de capturar a proporção de amostras positivas corretamente identificadas pelo modelo, sendo relevante para destacar a quantidade de falsos negativos no teste. Além disso, a sensibilidade é uma métrica para lidar com conjuntos de dados desbalanceados, nos quais há uma divergência na proporção das amostras de diferentes rótulos.

Tabela 9 – Resultados obtidos com hiperparâmetros ajustados.


Boosting de Gradiente					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
3	97,16	97,68	96,56	96,99	97,34
Média	95,97 ± 0,63	96,70 ± 0,68	95,14 ± 0,97	95,77 ± 0,82	96,23 ± 0,59
Floresta Aleatória					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
4	96,87	98,04	95,56	96,15	97,08
Média	95,72 ± 0,86	96,89 ± 0,79	94,40 ± 1,22	95,15 ± 1,03	96,01 ± 0,79
Árvores Extremamente Aleatórias					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
9	97,82	98,18	97,43	97,65	97,91
Média	96,66 ± 0,60	97,42 ± 0,46	95,84 ± 1,28	96,24 ± 1,12	96,82 ± 0,55
Boosting de Gradiente Extremo					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
10	97,34	98,57	95,95	96,50	97,53
Média	97,21 ± 0,42	97,81 ± 0,58	96,54 ± 0,63	96,98 ± 0,54	97,39 ± 0,40
Máquina de Boosting de Gradiente Leve					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
4	98,01	98,92	96,99	97,35	98,13
Média	97,48 ± 0,43	97,86 ± 0,74	97,05 ± 0,52	97,38 ± 0,45	97,62 ± 0,41

Fonte: Elaborado pelo autor.

A ordem dos algoritmos na Tabela 9 é baseada na média das sensibilidades alcançadas nos *fold*s de cada experimento. Observa-se que, em cada *fold* selecionado nas simulações, a sensibilidade apresentou o melhor desempenho em comparação com as outras métricas. Por outro lado, a especificidade foi a métrica com pior desempenho em todas as simulações. Essas observações indicam que os modelos possuem uma capacidade elevada de detectar verdadeiros positivos em relação a verdadeiros negativos, o que é essencialmente relevante no contexto da

saúde digital. A Figura 37 fornece uma visualização mais esclarecedora das métricas obtidas (média das sensibilidades alcançadas nos *fold*s) e que foram apresentadas na Tabela 9.

Figura 37 – Comparação dos classificadores com os resultados da validação cruzada.



Fonte: Elaborado pelo autor.

Como ilustrado na Figura 37, cada simulação sugere um padrão de progressão das métricas, tendo como exceção, o algoritmo Floresta Aleatória que foi a única técnica que apenas em termos de sensibilidade superou a técnica *Boosting* de Gradiente, seja no *fold* escolhido ou na média obtida. Como observado também na Figura 37, o algoritmo de Máquina de *Boosting* de Gradiente Leve alcançou o melhor desempenho em todas as métricas. A Tabela 10 apresenta a matriz de confusão referente ao *fold* destacado na Tabela 9, que foi obtido através da técnica de Máquina de *Boosting* de Gradiente Leve.

Tabela 10 – Matriz de confusão com os resultados da validação cruzada.

	Predito Positivo	Predito Negativo
Real Positivo	551	6
Real Negativo	15	483

Fonte: Elaborado pelo autor.

Na Tabela, observa-se uma consonância com a sensibilidade apresentada na Tabela

9, configurando-se como a melhor métrica obtida. Isso se deve ao fato de que houve uma baixa incidência de falsos negativos (6 episódios), sugerindo que o modelo apresentou um melhor desempenho em identificar corretamente as amostras positivas, minimizando assim os erros de classificação mais críticos.

6.2.1 Comparativo sem etapa de ajuste dos hiperparâmetros

Esta subseção apresenta os resultados obtidos sem a etapa de ajuste dos hiperparâmetros, destacando o desempenho inicial dos classificadores. Em seguida, busca-se validar a abordagem sugerida na seção anterior, discutindo o ganho de desempenho após a realização dos procedimentos de ajuste. Os resultados para realizar as devidas comparações estão apresentados na Tabela 11.

Tabela 11 – Resultados obtidos com hiperparâmetros padrão.

Boosting de Gradiente					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
4	90,90	91,58	90,14	91,25	91,41
Média	91,25 ± 0,58	89,98 ± 1,14	92,67 ± 1,48	93,27 ± 1,23	91,58 ± 0,55
Árvores Extremamente Aleatórias					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
6	95,45	97,12	93,59	94,41	95,75
Média	94,69 ± 0,66	95,95 ± 0,78	93,28 ± 0,69	94,09 ± 0,60	95,01 ± 0,62
Boosting de Gradiente Extremo					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
3	96,49	97,15	95,75	96,29	96,72
Média	95,59 ± 0,50	96,20 ± 0,54	94,90 ± 0,80	95,54 ± 0,67	95,87 ± 0,46
Máquina de Boosting de Gradiente Leve					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
7	96,02	97,31	94,57	95,26	96,28
Média	95,13 ± 0,62	95,86 ± 0,95	94,30 ± 0,98	94,98 ± 0,81	95,42 ± 0,59
Floresta Aleatória					
Fold	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
4	95,55	97,49	93,36	94,28	95,86
Média	94,90 ± 0,38	96,31 ± 0,67	93,32 ± 0,70	94,19 ± 0,57	95,23 ± 0,35

Fonte: Elaborado pelo autor.


A sensibilidade foi novamente escolhida como métrica para a seleção do *fold*, e os classificadores foram ordenados de acordo com seu desempenho médio nessa métrica. Ao comparar os resultados apresentados nas Tabelas 9 e 11, observa-se um incremento no desempenho

na grande maioria das métricas de todas as simulações realizadas. Também foi identificado que os classificadores não seguiram a mesma ordem em relação ao desempenho médio das métricas coletadas anteriormente. Por exemplo, o classificador que obteve os melhores resultados sem ajustes foi a Floresta Aleatória. No entanto, após a etapa de ajuste, embora seus resultados tenham melhorado, não alcançaram níveis tão relevantes em comparação com as outras técnicas.

Para facilitar a visualização destes ganhos, serão plotados os *boxplots* gerados a partir das métricas de avaliação coletadas em cada *fold* de cada simulação. Essas simulações correspondem às apresentadas nas Tabelas 9 e 11, que, respectivamente, mostram os resultados com e sem ajuste de hiperparâmetros. Cada Figura é composta por cinco subfiguras, cada uma representando uma métrica e exibindo dois *boxplots* lado a lado. O primeiro *boxplot* mostra o desempenho do classificador com hiperparâmetros não ajustados, enquanto o segundo mostra o desempenho com hiperparâmetros ajustados. Além disso, em cada *boxplot*, são apresentadas linhas verticais de erro (em vermelho) que representam a média e o desvio padrão dos resultados obtidos.

As Figuras contendo os *boxplots* para cada classificador estão dispostas a seguir e foram organizadas na mesma ordem da Tabela 11, em ordem, são: *Boosting* de Gradiente (Figura 38), Floresta Aleatória (Figura 39), Árvore Extremamente Aleatórias (Figura 40), *Boosting* de Gradiente Extremo (Figura 41) e Máquina de *Boosting* de Gradiente Leve (Figura 42).

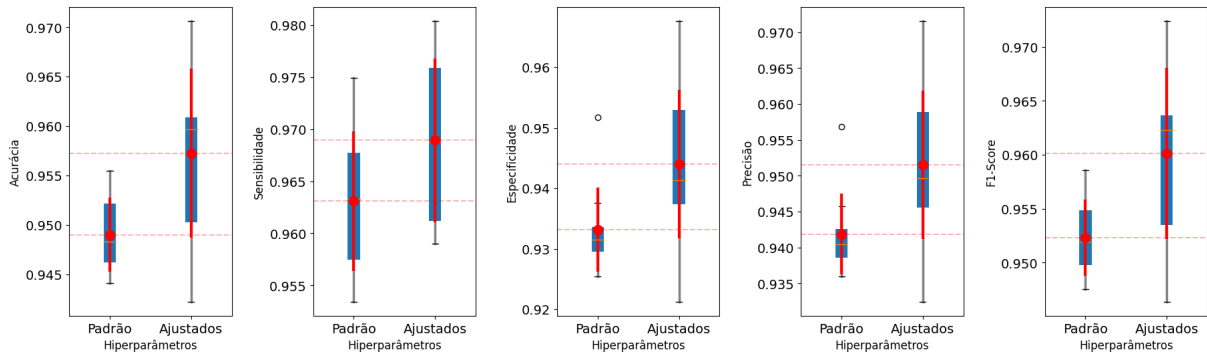
Figura 38 – *Boxplots* comparativos das simulações com e sem ajuste dos hiperparâmetros (*Boosting* de Gradiente).



Fonte: Elaborado pelo autor.


Em todos os *boxplots* apresentados anteriormente, foi identificado um aumento significativo de desempenho, entretanto, sem ganhos semelhantes entre os classificadores. O maior aumento de desempenho é observado na Figura 38, através da técnica de *Boosting* de

Figura 39 – *Boxplots* comparativos das simulações com e sem ajuste dos hiperparâmetros (Floresta Aleatória).




Fonte: Elaborado pelo autor.

Figura 40 – *Boxplots* comparativos das simulações com e sem ajuste dos hiperparâmetros (Árvores Extremamente Aleatórias).




Fonte: Elaborado pelo autor.

Figura 41 – *Boxplots* comparativos das simulações com e sem ajuste dos hiperparâmetros (Boosting de Gradiente Extremo).



Fonte: Elaborado pelo autor.

Figura 42 – *Boxplots* comparativos das simulações com e sem ajuste dos hiperparâmetros (Máquina de *Boosting* de Gradiente Leve).



Fonte: Elaborado pelo autor.

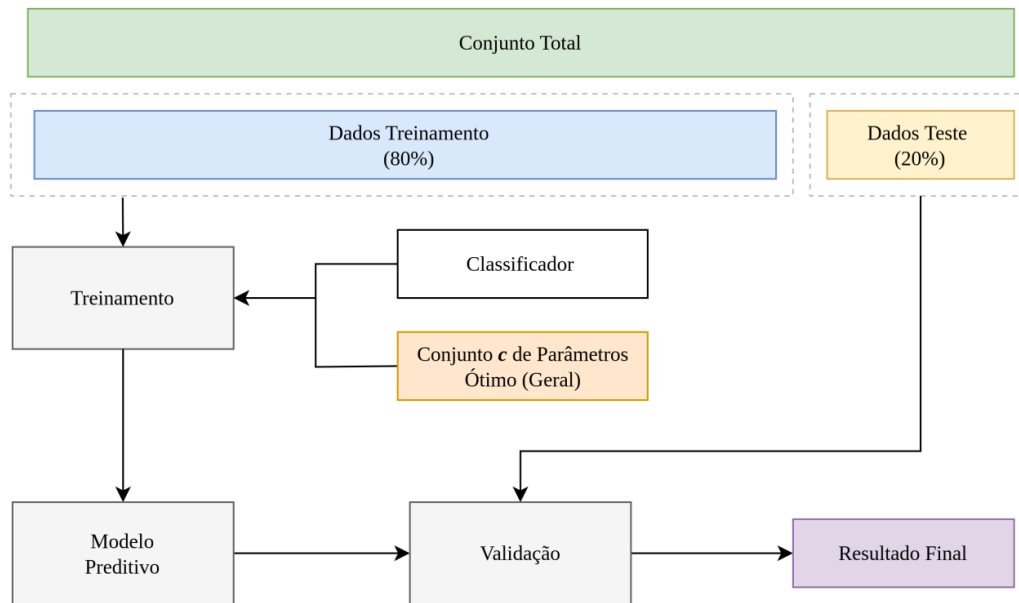
Gradiente, com um aumento percentual geral de 6,8% na média das sensibilidades dos *folders*. O menor incremento percentual geral das sensibilidades foi identificado na técnica Floresta Aleatória, com um aumento de 0,58%, e visto na Figura 39. Observa-se também, em todas as Figuras, que nos *boxplots* referentes aos resultados sem o ajuste de parâmetros, há uma incidência maior de *outliers*, revelando que o modelo construído a partir dos parâmetros escolhidos é menos propenso a ruídos nos dados.

Em geral, os resultados obtidos e apresentados nesta seção validaram a metodologia adotada. Além disso, foi realizada uma comparação dos resultados após o ajuste dos hiperparâmetros, revelando-se uma etapa valiosa para aprimorar o reconhecimento dos padrões dos dados pelo modelo e obter um ganho satisfatório de desempenho. Na próxima seção, novos experimentos serão conduzidos com os dados de teste utilizando os classificadores e ajustes estabelecidos nesta seção.

6.3 Resultados com dados de teste (*hold-out*)

Nesta seção, serão apresentados os resultados dos experimentos realizados com os classificadores e seus hiperparâmetros ajustados. Entretanto, neste momento, todas as amostras utilizadas na seção anterior, serão reunidas e utilizadas agora para realizar o treinamento do modelo, ou seja, serão destinadas uma quantidade de 10548 amostras para treinamento. Como exposto na Figura 43, os modelos criados serão validados através dos dados de teste (20%) que representam uma quantidade de 2637 amostras. Estes dados ainda não foram usados para treinamento em nenhuma simulação desta pesquisa.

Figura 43 – Abordagem para obtenção dos resultados finais.



Fonte: Elaborado pelo autor.

A Tabela 12 apresenta os resultados finais obtidos nesta pesquisa. Esses resultados forneceram as métricas que revelam o desempenho dos diferentes algoritmos a partir da técnica de validação *hold-out* e serão discutidos adiante.

Tabela 12 – Resultados finais.


Classificador	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
Floresta Aleatória	94,65	95,66	93,51	94,38	95,01
<i>Boosting</i> de Gradiente	95,11	95,30	94,89	95,50	95,40
Árvores Extremamente Aleatórias	95,90	97,07	94,59	95,29	96,17
<i>Boosting</i> de Gradiente Extremo	96,63	96,93	96,28	96,73	96,83
Máquina de <i>Boosting</i> de Gradiente Leve	97,04	97,44	96,59	97,02	97,23

Fonte: Elaborado pelo autor.

Com base nos resultados apresentados na Tabela 12, a Máquina de *Boosting* de Gradiente Leve demonstrou o melhor desempenho em todas as métricas. Por outro lado, a Floresta Aleatória teve um desempenho ligeiramente inferior em comparação com os outros algoritmos, exceto pela sensibilidade. Para melhor ilustrar essas informações, a Figura 44 utiliza

o mesmo recurso adotado na Figura 37, representando graficamente os desempenhos médios das métricas (obtidos a partir de todo conjunto de teste), permitindo uma visualização comparativa do desempenho de cada classificador.

Figura 44 – Comparação dos classificadores com os resultados finais.



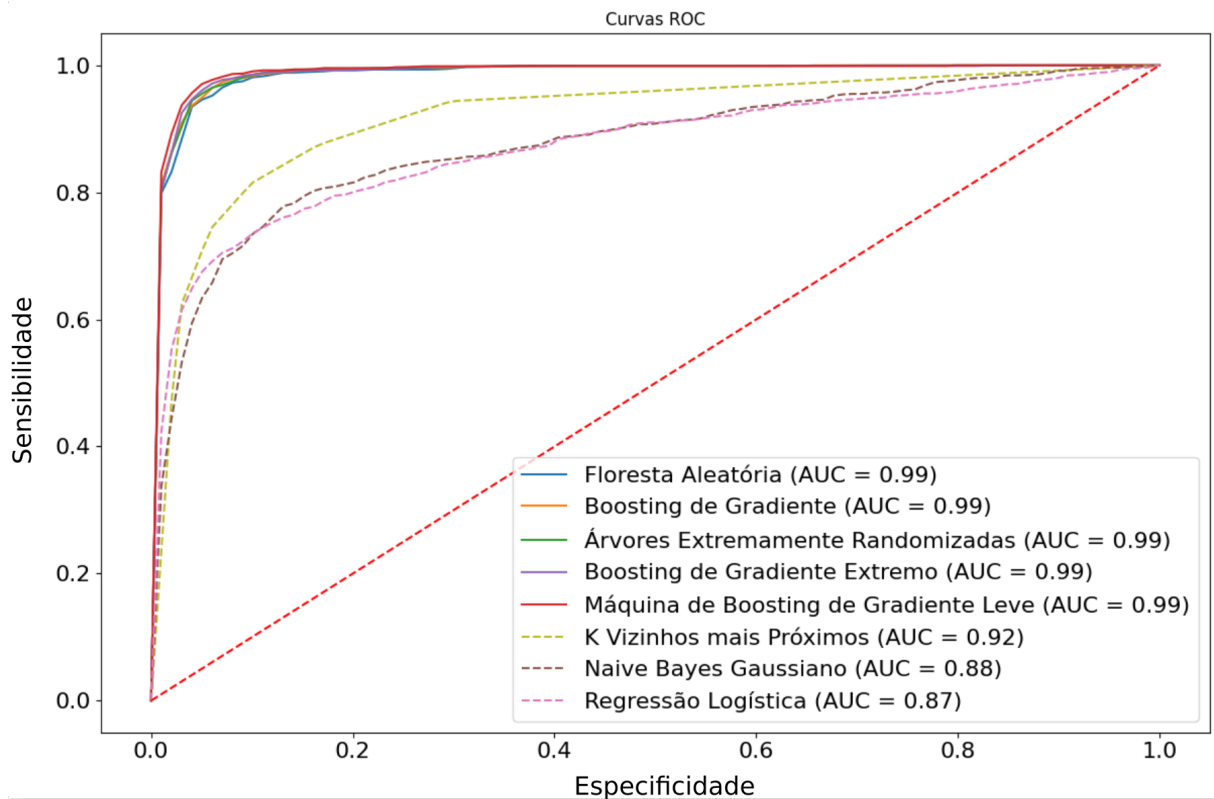
Fonte: Elaborado pelo autor.

Na Figura 44, são observadas duas tendências distintas entre as métricas. A primeira tendência é composta pelo *Boosting* de Gradiente, *Gradiente* de Boosting Extremo e Máquina de *Boosting* de Gradiente Leve. Este primeiro conjunto mostra métricas mais estabilizadas. Por outro lado, a segunda tendência, formada pelos classificadores Floresta Aleatória e Árvores Extremamente Aleatórias, apresenta uma alta discrepância entre sensibilidade e especificidade nas simulações, com diferenças de 2,15% e 2,48%, respectivamente, entre as métricas mencionadas. Isso revela uma ocorrência de falsos negativos inferior à de falsos positivos.

As curvas ROC dos modelos gerados para os classificadores selecionados são apresentadas na Figura 45, juntamente com as curvas para outras técnicas amplamente utilizadas em tarefas de classificação, como K-Vizinhos mais próximos, Regressão Logística e *Naive Bayes*

Gaussiano. As curvas dessas técnicas foram incluídas para fins de comparação.

Figura 45 – Curvas ROC obtidas de todos os algoritmos.



Fonte: Elaborado pelo autor.

Os classificadores utilizados nesta pesquisa alcançaram um AUC de 0,99, indicando um desempenho satisfatório na tarefa de classificação binária, com uma capacidade elevada de distinguir entre as classes FA e NSR. Além disso, as curvas ROC plotadas revelam a adaptação destacada dos algoritmos baseados em árvores aos dados fornecidos. Os classificadores utilizados apenas para fins comparativos não alcançaram resultados promissores, a técnica de Regressão Logística, por exemplo, atingiu uma acurácia de 76,68% e sua AUC foi de 0,87. O classificador baseado em *Naive Bayes* Gaussiano obteve uma acurácia de 82,18% e sua AUC foi de 0,88. Por fim, a técnica dos K-Vizinhos mais próximos alcançou uma acurácia de 85,59% e sua AUC foi de 0,92.

6.4 Resultado Conclusivo

Em resumo, tanto os resultados da validação cruzada quanto do método de *hold-out*, utilizando dados de teste, indicaram que o algoritmo de Máquina de *Boosting* de Gradiente Leve,

com os hiperparâmetros ótimos descritos na Tabela 8, superou as demais técnicas empregadas na classificação do vetor de características extraído de um segmento de sinal ECG entre FA e NSR. Essa superioridade é também evidente nas Figuras 37 e 44. Dessa forma, esta pesquisa considera os resultados apresentados na Tabela 13 para o classificador Máquina de *Boosting* de Gradiente Leve, como o resultado conclusivo da técnica proposta. Já na Tabela 14, é apresentada a matriz de confusão referente a essa execução destacada como a melhor.

Tabela 13 – Resultado conclusivo alcançado nesta pesquisa.

Classificador	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)
Máquina de <i>Boosting</i> de Gradiente Leve	97,04	97,44	96,6	97,02	97,23

Fonte: Elaborado pelo autor.

Tabela 14 – Matriz de confusão.

	Predito Positivo	Predito Negativo
Real Positivo	1368	36
Real Negativo	44	1191

Fonte: Elaborado pelo autor.

Na Tabela 14, destaca-se a diferença na quantidade de classes corretamente rotuladas: 1368 (VP) e 1191 (VN). O total de amostras testadas foi de 2559 (100%), sendo 1404 (53,2%) rotuladas como FA e 1235 (46,8%) como NSR. Os resultados demonstraram o desempenho superior do modelo na identificação das amostras positivas, mais uma vez, minimizando os erros críticos de classificação. Isso é evidenciado pela baixa incidência de falsos negativos (36 episódios), mesmo com a quantidade de amostras rotuladas positivamente sendo levemente superior (3,2%). A Tabela 15 resume os resultados dos trabalhos relacionados a esta pesquisa. O estudo a ser utilizado como referência comparativa é apresentado em (Duan *et al.*, 2022), pois utiliza as mesmas bases de dados.

A Tabela 15 revela o aumento obtido no desempenho em termos de sensibilidade em relação ao trabalho do estado da arte desenvolvido por (Duan *et al.*, 2022). Observa-se também que o trabalho utiliza um comprimento de 30 RRIs de segmento de sinal ECG para elaborar o vetor de características apresentado ao classificador, enquanto que no presente trabalho foi utilizado um segmento de sinal de tamanho 5 RRIs, representando uma redução de 16,67% no tamanho do segmento de sinal em comparação com a técnica apresentada por (Duan *et al.*, 2022).

Tabela 15 – Resultados dos trabalhos relacionados (em ordem cronológica crescente).

	AFDB	NSRDB	LTAfDB	ADB	ACC (%)	SEN (%)	SPE (%)
(Young <i>et al.</i> , 1999)	✓				94,75	91,38	93,5
(Tateno; Glass, 2001)	✓					94,4	97,2
(Li <i>et al.</i> , 2017)				✓	93,7	95,1	92,0
(Czabanski <i>et al.</i> , 2020)	✓				98,6	98,9	98,4
(Hu <i>et al.</i> , 2020)	✓				98,9	97,93	99,63
(Lown <i>et al.</i> , 2020)	✓			✓		100	97,6
(Hirsch <i>et al.</i> , 2021)	✓				97,6	98,0	97,4
(Duan <i>et al.</i> , 2022)	✓	✓	✓		96,97	95,24	99,94
Presente Trabalho	✓	✓	✓		97,04	97,44	96,59

Fonte: Elaborado pelo autor.

6.4.1 Intervalo de Confiança

Foram também calculados os intervalos de confiança para o classificador e o ajustes de hiperparâmetros que levaram ao resultado conclusivo desta pesquisa. Um intervalo de confiança é uma faixa de valores que indica a probabilidade de um parâmetro populacional estar contido nesse intervalo. Para realizar o cálculo, foi utilizado o método de amostragem denominado *bootstrap*, que consiste na obtenção de amostras aleatórias a partir da amostra original. Após 1000 simulações, envolvendo uma amostragem de *bootstrap* a cada iteração, foram obtidos os limites inferiores e superiores para o intervalo de confiança de 95% para cada métrica de avaliação, dispostos na Tabela 16.

Tabela 16 – Métricas de avaliação obtidas a partir do intervalo de confiança 95%.

Métrica	Limite Inferior 95%	Limite Superior 95%
ACC (%)	97,03	97,07
SEN (%)	97,48	97,54
SPE (%)	96,51	96,57
PRE (%)	95,20	96,93
F1-Score (%)	95,90	97,23

Fonte: Elaborado pelo autor.

Com base nos experimentos realizados e com os resultados obtidos para cada métrica de avaliação, em ordem decrescente, as amplitudes dos intervalos de confiança de 95% são as seguintes: Precisão (PRE) com 1,73%, Pontuação F1-Score com 1,33%, Sensibilidade (SEN) com 0,06%, Especificidade (SPE) com 0,06% e Acurácia (ACC) com 0,04%. As métricas ACC, SEN e SPE apresentaram menores variações, sugerindo uma estimativa mais precisa nos resultados apresentados para essas métricas. Enquanto que a Precisão e F1-Score tem um

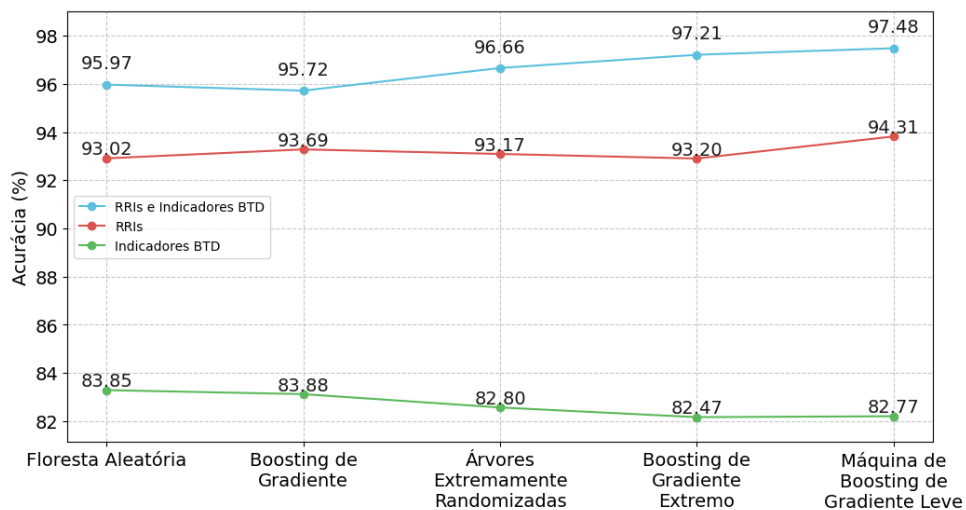
intervalo de confiança mais amplo, o que indica uma maior incerteza na estimativa dessa métrica no modelo e que são mais sensíveis a variações nos dados.

Por fim, esta seção apresentou os resultados conclusivos, os quais foram resumidos na Tabela 13. Esses resultados representam uma contribuição significativa para a detecção de FA por meio de dados do ECG, sendo relevantes para o avanço do conhecimento nessa área, uma vez que promovem a utilização desta metodologia e incentivam futuras pesquisas e aplicações.

6.5 Contribuição dos parâmetros BTD

Esta subseção concentra-se em destacar a contribuição da detecção de FA por meio da utilização dos parâmetros de convergência e otimização da BTD. Isso será realizado por meio da comparação de resultados entre três configurações de características sob as mesmas condições. As configurações das simulações foram: a utilização apenas dos RRIs, a utilização apenas dos parâmetros de convergência da BTD e, finalmente, a combinação dos RRIs com os parâmetros da BTD, sendo este último o conjunto de características proposto na metodologia desta pesquisa. A Figura 46 ilustra esses experimentos e um comparativo entre todas as técnicas de classificação abordadas neste trabalho. As simulações foram realizadas utilizando o método de validação cruzada *k-fold*, com $k = 10$, para todo o conjunto de dados obtido.

Figura 46 – Comparativo entre as configurações de características (classificadores).




Fonte: Elaborado pelo autor.

A Figura 46 apresenta as médias das acurácias alcançadas em cada simulação. Também é ilustrado que a abordagem utilizando somente os RRIs já possui relevância na detecção de FA, o que também é relatado em trabalhos relacionados. Entretanto, ao combinar

os RRIs com os parâmetros da BTM, houve melhora no desempenho da acurácia em todas as técnicas. Na Máquina de *Boosting* de Gradiente Leve, houve um aumento significativo de 3,17%.

Na Figura 47, foram realizadas simulações envolvendo a técnica *hold-out*. Neste experimento, toda a base de dados também foi empregada e estipulado um ajuste dinâmico no tamanho dos dados de treinamento, resultando em 13 simulações para cada configuração de características, totalizando 39 simulações. Cada curva inicia com 20% e chega até 80%. As simulações foram realizadas utilizando a técnica: Máquina de *Boosting* de Gradiente Leve.

Figura 47 – Comparativo entre as configurações de características (variação na porção de treinamento).



Fonte: Elaborado pelo autor.

A Figura 47 ilustra a tendência crescente e esperada ao adicionar uma quantidade maior de dados de treinamento. Também é evidenciando o aumento de desempenho resultante da combinação entre as características de naturezas distintas propostas neste trabalho. Na última simulação, envolvendo 80% dos dados de treinamento, foi obtido um aumento de 1,63% ao combinar os RRIs com os parâmetros da BTM.

Finalmente, a partir das Figuras 46 e 47, observa-se um aumento em todas as simulações quando ocorre a combinação entre características, ressaltando a relevância e o impacto positivo da proposta apresentada nesta pesquisa.

7 CONCLUSÃO

Neste capítulo, são apresentadas as conclusões obtidas a partir da aplicação do método proposto na detecção de FA, destacando as principais contribuições, resultados obtidos e os trabalhos futuros para continuação desta linha de pesquisa, que está inserida na detecção automatizada de FA a partir de sinais ECG.

7.1 Objetivos

Todos os objetivos propostos neste trabalho foram atendidos, contribuindo para a detecção de FA em monitoramento cardíaco utilizando gravações de ECG. Dentre os objetivos, esta pesquisa incluiu:

- Exploração das bases de dados AFDB, NSRDB e LTAFDB.
- Aplicação de etapas de pré-processamento, incluindo filtragem de ruídos e segmentação do sinal.
- Preparo de um repositório de dados a partir dos sinais de ECG pré-processados e segmentados por paciente para posteriores extrações.
- Reprodução do método de extração dos RRIs, uma característica do segmento de sinal amplamente difundida na literatura para detecção de arritmias cardíacas.
- Apresentação de uma nova técnica para detecção de FA em sinais ECG, baseada em uma abordagem tensorial, utilizando parâmetros de convergência e otimização do cálculo da BTD a partir dos segmentos de sinal ECG.
- Seleção de classificadores baseados em árvores para validar a metodologia proposta.
- Realização de uma etapa para ajustar os hiperparâmetros dos algoritmos classificadores, onde foi verificado um ganho expressivo de desempenho.
- Divisão dos resultados em três categoriais: resultados com validação cruzada, resultados com dados de teste e resultado conclusivo, demonstrando a capacidade do método proposto na identificação da presença de FA a partir do ECG.
- Análise comparativa da utilização dos parâmetros da BTD propostos neste trabalho, ressaltando sua relevância na detecção de FA quando utilizados em conjunto com os RRIs.

7.2 Resultados

Em resumo, utilizando o método de avaliação *k-fold*, os melhores resultados foram obtidos com o algoritmo de Máquina de *Boosting* de Gradiente Leve. Observou-se uma acurácia média de 97,48%, sensibilidade de 97,86%, especificidade de 97,05%, precisão de 97,38% e *F1-Score* de 97,62%. Para a técnica *hold-out*, o mesmo algoritmo classificador apresentou os melhores resultados, com uma acurácia de 97,04%, sensibilidade de 97,44%, especificidade de 96,59%, precisão de 97,02% e *F1-Score* de 97,23%. Nesta última análise, foi ilustrada a área sob a curva ROC (Figura 45) e calculado o intervalo de confiança para as métricas (Tabela 15). Esses resultados também revelaram que a inclusão dos parâmetros de convergência e otimização da BTD contribuíram para a melhoria na tarefa de detecção de FA em sinais de ECG, indicando que essas novas características propostas carregam padrões associados a essa condição clínica.

7.3 Trabalhos Futuros

Diante das discussões e estudos levantados nesta pesquisa, o problema de detecção de FA em ECG ainda possui lacunas e desafios a serem abordados. Algumas sugestões para estudos futuros seguindo essa linha de pesquisa são listadas a seguir:

- Validação da proposta envolvendo bases de dados que utilizam os 12 derivações do ECG.
- Exploração de técnicas de pré-processamento para melhorar a qualidade das características que serão extraídas a partir dos sinais ECG.
- Para a seleção de hiperparâmetros, avaliar a utilização da biblioteca *Optuna* em vez do *grid search*, devido à sua maior eficiência e proposta de ganho de desempenho.
- Aumentar a quantidade de amostras a partir das bases empregadas na pesquisa. Também há a possibilidade de exploração de outros conjuntos de dados, como exemplo, a ADB.
- Realizar experimentos com aplicação dos recentes avanços envolvendo a decomposição BTD e que foram descritas na Seção 4.2.1. Estas abordagens podem fornecer parâmetros mais discriminantes no contexto de classificação de FA.
- Agregar outras características, além dos RRIs e os parâmetros BTD, que sejam relevantes e podem ser extraídas a partir de um segmento de sinal ECG.
- Como descrito na Seção 4.2.2, as propostas envolvendo aprendizagem profunda podem ser promissoras para a tarefa de classificação envolvendo os parâmetros BTD.
- Propor uma abordagem orientada ao aprendizado por transferência (*transfer learning*).

REFERÊNCIAS

- ACHARYA, U. R.; FUJITA, H.; LIH, O. S.; HAGIWARA, Y.; TAN, J. H.; ADAM, M. Automated detection of arrhythmias using different intervals of tachycardia ecg segments with convolutional neural network. **Information Sciences**, Elsevier BV, v. 405, p. 81–90, set. 2017. ISSN 0020-0255. Disponível em: <http://dx.doi.org/10.1016/j.ins.2017.04.012>.
- Afya. **Curso básico de eletrocardiograma – Parte 04**. <https://papers.afya.com.br/blog/curso-basico-de-eletrocardiograma-parte-04>. Acesso em: 28 dez. 2023.
- ANDERSEN, R. S.; PEIMANKAR, A.; PUTHUSSERYPADY, S. A deep learning approach for real-time detection of atrial fibrillation. **Expert Systems with Applications**, Elsevier BV, v. 115, p. 465–473, jan. 2019. Disponível em: <https://doi.org/10.1016/j.eswa.2018.08.011>.
- ANDERSON, R. H.; YANNI, J.; BOYETT, M. R.; CHANDLER, N. J.; DOBRZYNSKI, H. The anatomy of the cardiac conduction system. **Clinical Anatomy**, Wiley, v. 22, n. 1, p. 99–113, set. 2008. ISSN 1098-2353. Disponível em: <http://dx.doi.org/10.1002/ca.20700>.
- ARFELLI, J. C. **Manual Prático de Eletrocardiograma**. 3. ed. São Paulo: Atheneu, 2010. ISBN 9788538803546.
- BELGURZI, A. N. S.; ELSHAFIEY, I. A power line interference canceler using wavelet transform and adaptive filter for ecg signal. In: **2017 International Conference on Computer and Applications (ICCA)**. IEEE, 2017. Disponível em: <http://dx.doi.org/10.1109/COMAPP.2017.8079764>.
- BELOUCHRANI, A.; ABED-MERAIM, K.; CARDOSO, J.-F.; MOULINES, E. A blind source separation technique using second-order statistics. **IEEE Transactions on Signal Processing**, Institute of Electrical and Electronics Engineers (IEEE), v. 45, n. 2, p. 434–444, 1997. ISSN 1053-587X. Disponível em: <http://dx.doi.org/10.1109/78.554307>.
- BREIMAN, L. **Machine Learning**, Springer Science and Business Media LLC, v. 45, n. 1, p. 5–32, 2001. ISSN 0885-6125. Disponível em: <http://dx.doi.org/10.1023/A:1010933404324>.
- CADOGAN, M. D. History of the electrocardiogram. **LITFL - Medical Eponym Library**, 2022. Acesso em: 02 fev. 2024. Disponível em: <https://litfl.com/history-of-the-electrocardiogram/>.
- CESARE, M. D.; PEREL, P.; TAYLOR, S.; KABUDULA, C.; BIXBY, H.; GAZIANO, T. A.; MCGHIE, D. V.; MWANGI, J.; PERVAN, B.; NARULA, J.; PINEIRO, D.; PINTO, F. J. The heart of the world. **Global Heart**, Ubiquity Press, Ltd., v. 19, n. 1, 2024. ISSN 2211-8179. Disponível em: <http://dx.doi.org/10.5334/gh.1288>.
- CHAUDHRY, R.; AFZAL, M. R.; CHAUDHRY, G. M.; RAZA, S. **Physiology, Cardiovascular**. Treasure Island (FL): StatPearls Publishing, 2022. Acesso em: 02 fev. 2024. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK538339/>.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. **CoRR**, abs/1603.02754, 2016. Disponível em: <http://arxiv.org/abs/1603.02754>.
- CHEN, Y.; ZHANG, C.; LIU, C.; WANG, Y.; WAN, X. Atrial fibrillation detection using a feedforward neural network. **Journal of Medical and Biological Engineering**, Springer Science and Business Media LLC, v. 42, n. 1, p. 63–73, fev. 2022. ISSN 2199-4757. Disponível em: <http://dx.doi.org/10.1007/s40846-022-00681-z>.

CHENG, Y.; HU, Y.; HOU, M.; PAN, T.; HE, W.; YE, Y. Atrial fibrillation detection directly from compressed ecg with the prior of measurement matrix. **Information**, MDPI AG, v. 11, n. 9, p. 436, set. 2020. ISSN 2078-2489. Disponível em: <http://dx.doi.org/10.3390/info11090436>.

CHRISTOV, I. I.; DASKALOV, I. K. Filtering of electromyogram artifacts from the electrocardiogram. **Medical Engineering and Physics**, Elsevier BV, v. 21, n. 10, p. 731–736, dez. 1999. ISSN 1350-4533. Disponível em: [http://dx.doi.org/10.1016/s1350-4533\(99\)00098-3](http://dx.doi.org/10.1016/s1350-4533(99)00098-3).

COLILLA, S.; CROW, A.; PETKUN, W.; SINGER, D. E.; SIMON, T.; LIU, X. Estimates of current and future incidence and prevalence of atrial fibrillation in the u.s. adult population. **The American Journal of Cardiology**, Elsevier BV, v. 112, n. 8, p. 1142–1147, out. 2013. ISSN 0002-9149. Disponível em: <http://dx.doi.org/10.1016/j.amjcard.2013.05.063>.

COMON, P. Tensors: A brief introduction. **IEEE Signal Processing Magazine**, Institute of Electrical and Electronics Engineers (IEEE), v. 31, n. 3, p. 44–53, maio 2014. ISSN 1053-5888. Disponível em: <http://dx.doi.org/10.1109/MSP.2014.2298533>.

CZABANSKI, R.; HOROBA, K.; WROBEL, J.; MATONIA, A.; MARTINEK, R.; KUPKA, T.; JEZEWSKI, M.; KAHANKOVA, R.; JEZEWSKI, J.; LESKI, J. Detection of atrial fibrillation episodes in long-term heart rhythm signals using a support vector machine. **Sensors**, MDPI AG, v. 20, n. 3, p. 765, jan. 2020. ISSN 1424-8220. Disponível em: <http://dx.doi.org/10.3390/s20030765>.

DEBALS, O.; BAREL, M. V.; LATHAUWER, L. D. Löwner-based blind signal separation of rational functions with applications. **IEEE Transactions on Signal Processing**, Institute of Electrical and Electronics Engineers (IEEE), v. 64, n. 8, p. 1909–1918, abr. 2016. ISSN 1941-0476. Disponível em: <http://dx.doi.org/10.1109/TSP.2015.2500179>.

DEBALS, O.; LATHAUWER, L. D. **Stochastic and Deterministic Tensorization for Blind Signal Separation**. Springer International Publishing, 2015. 3–13 p. ISSN 1611-3349. ISBN 9783319224824. Disponível em: http://dx.doi.org/10.1007/978-3-319-22482-4_1.

DELANEY, J. A.; YIN, X.; FONTES, J. D.; WALLACE, E. R.; SKINNER, A.; WANG, N.; HAMMILL, B. G.; BENJAMIN, E. J.; CURTIS, L. H.; HECKBERT, S. R. Hospital and clinical care costs associated with atrial fibrillation for medicare beneficiaries in the cardiovascular health study and the framingham heart study. **SAGE Open Medicine**, SAGE Publications, v. 6, p. 205031211875944, jan. 2018. ISSN 2050-3121. Disponível em: <http://dx.doi.org/10.1177/2050312118759444>.

DIETTERICH, T. G. Ensemble methods in machine learning. Springer Berlin Heidelberg, p. 1–15, 2000. ISSN 0302-9743. Disponível em: http://dx.doi.org/10.1007/3-540-45014-9_1.

Disciplina de Emergências Clínicas da FMUSP. **Fibrilação Atrial – Pérolas na Emergência**. 2017. <https://www.emergenciausp.com.br/fibrilacao-atrial-perolas-na-emergencia/>. Acesso em: 13 dez. 2023.

DRAWZ, P. E.; BABINEAU, D. C.; BRECKLIN, C.; HE, J.; KALLEM, R. R.; SOLIMAN, E. Z.; XIE, D.; APPLEBY, D.; ANDERSON, A. H.; RAHMAN, M. Heart rate variability is a predictor of mortality in chronic kidney disease: A report from the cric study. **American Journal of Nephrology**, S. Karger AG, v. 38, n. 6, p. 517–528, 2013. ISSN 1421-9670. Disponível em: <http://dx.doi.org/10.1159/000357200>.

DUAN, J.; WANG, Q.; ZHANG, B.; LIU, C.; LI, C.; WANG, L. Accurate detection of atrial fibrillation events with r-r intervals from ECG signals. **PLOS ONE**, Public Library of Science (PLOS), v. 17, n. 8, p. e0271596, ago. 2022. Disponível em: <https://doi.org/10.1371/journal.pone.0271596>.

DUPRE, A.; VINCENT, S.; IAIZZO, P. A. Basic ECG theory, recordings, and interpretation. In: **Handbook of Cardiac Anatomy, Physiology, and Devices**. Humana Press, 2005. p. 191–201. Disponível em: https://doi.org/10.1007/978-1-59259-835-9_15.

FARRELL, A. P.; JONES, D. R. The heart. In: **Fish physiology**. [S. l.]: Elsevier, 2023. v. 40, p. 91–172.

FREUND, Y.; SCHAPIRE, R. E. A short introduction to boosting. In: . [S. n.], 1999. Disponível em: <https://api.semanticscholar.org/CorpusID:9621074>.

FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. **The Annals of Statistics**, Institute of Mathematical Statistics, v. 29, n. 5, out. 2001. ISSN 0090-5364. Disponível em: <http://dx.doi.org/10.1214/aos/1013203451>.

FUJITA, H.; CIMR, D. Computer aided detection for fibrillations and flutters using deep convolutional neural network. **Information Sciences**, Elsevier BV, v. 486, p. 231–239, jun. 2019. ISSN 0020-0255. Disponível em: <http://dx.doi.org/10.1016/j.ins.2019.02.065>.

GARCIA, T. **12-lead ECG: The Art of Interpretation**. Jones & Bartlett Learning, 2015. (G - Reference, Information and Interdisciplinary Subjects Series). ISBN 9780763773519. Disponível em: <https://books.google.com.br/books?id=IfqwzgeEACAAJ>.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. **Machine Learning**, Springer Science and Business Media LLC, v. 63, n. 1, p. 3–42, mar. 2006. ISSN 1573-0565. Disponível em: <http://dx.doi.org/10.1007/s10994-006-6226-1>.

GIBSON, C. M.; STEINHUBL, S.; LAKKIREDDY, D.; TURAKHIA, M. P.; PASSMAN, R.; JONES, W. S.; BUNCH, T. J.; CURTIS, A. B.; PETERSON, E. D.; RUSKIN, J.; SAXON, L.; TARINO, M.; TARAKJI, K. G.; MARROUCHE, N.; PATEL, M.; HARXHI, A.; KAUL, S.; NIKOLOVSKI, J.; JUAN, S.; WILDENHAUS, K.; DAMARAJU, C.; SPERTUS, J. A. Does early detection of atrial fibrillation reduce the risk of thromboembolic events? rationale and design of the heartline study. **American Heart Journal**, Elsevier BV, v. 259, p. 30–41, maio 2023. ISSN 0002-8703. Disponível em: <http://dx.doi.org/10.1016/j.ahj.2023.01.004>.

GIEBEL, G. D.; GISSEL, C. Accuracy of mhealth devices for atrial fibrillation screening: Systematic review. **JMIR mHealth and uHealth**, JMIR Publications Inc., v. 7, n. 6, p. e13641, jun. 2019. ISSN 2291-5222. Disponível em: <http://dx.doi.org/10.2196/13641>.

GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. **Circulation**, v. 101, n. 23, p. e215–e220, 2000. Circulation Electronic Pages: <http://circ.ahajournals.org/content/101/23/e215.full> PMID:1085218; doi: 10.1161/01.CIR.101.23.e215.

GOULART, J. H. d. M.; OLIVEIRA, P. M. R. de; FARIAS, R. C.; ZARZOSO, V.; COMON, P. Alternating group lasso for block-term tensor decomposition and application to ecg

- source separation. **IEEE Transactions on Signal Processing**, Institute of Electrical and Electronics Engineers (IEEE), v. 68, p. 2682–2696, 2020. ISSN 1941-0476. Disponível em: <http://dx.doi.org/10.1109/TSP.2020.2985591>.
- GUIDOTTI, R.; MONREALE, A.; RUGGIERI, S.; TURINI, F.; GIANNOTTI, F.; PEDRESCHI, D. A survey of methods for explaining black box models. **ACM Computing Surveys**, Association for Computing Machinery (ACM), v. 51, n. 5, p. 1–42, ago. 2018. ISSN 1557-7341. Disponível em: <http://dx.doi.org/10.1145/3236009>.
- GUIMARÃES, D. T. **Dicionário de Termos Médicos e de Enfermagem**. 1. ed. São Paulo: Editora Rideel, 2002. 473 p. ISBN 9788533905252.
- HALEVY, A.; NORVIG, P.; PEREIRA, F. The unreasonable effectiveness of data. **IEEE Intelligent Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 2, p. 8–12, mar. 2009. Disponível em: <https://doi.org/10.1109/mis.2009.36>.
- HEART, L. N. N.; INSTITUTE, B. **Arrhythmias**. 2022. <https://www.nhlbi.nih.gov/health/arrhythmias>. Acesso em: 13 dez. 2023.
- HEIDT, S.; KRATZ, A.; NAJARIAN, K.; HASSETT, A.; ORAL, H.; GONZALEZ, R.; NALLAMOTHU, B.; CLAUW, D.; GHANBARI, H. Symptoms in atrial fibrillation: A contemporary review and future directions. **Journal of Atrial Fibrillation**, v. 9, p. 1422, 06 2016.
- HIRSCH, G.; JENSEN, S. H.; POULSEN, E. S.; PUTHUSSERYPADY, S. Atrial fibrillation detection using heart rate variability and atrial activity: A hybrid approach. **Expert Systems with Applications**, Elsevier BV, v. 169, p. 114452, maio 2021. ISSN 0957-4174. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2020.114452>.
- HITCHCOCK, F. L. The expression of a tensor or a polyadic as a sum of products. **Journal of Mathematics and Physics**, Wiley, v. 6, n. 1-4, p. 164–189, abr. 1927. Disponível em: <https://doi.org/10.1002/sapm192761164>.
- HOUBEN, R. P. M.; GROOT, N. M. S. de; ALLESSIE, M. A. Analysis of fractionated atrial fibrillation electrograms by wavelet decomposition. **IEEE Transactions on Biomedical Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 57, n. 6, p. 1388–1398, jun. 2010. ISSN 0018-9294. Disponível em: <http://dx.doi.org/10.1109/TBME.2009.2037974>.
- HU, Y.; ZHAO, Y.; LIU, J.; PANG, J.; ZHANG, C.; LI, P. An effective frequency-domain feature of atrial fibrillation based on time–frequency analysis. **BMC Medical Informatics and Decision Making**, Springer Science and Business Media LLC, v. 20, n. 1, nov. 2020. Disponível em: <https://doi.org/10.1186/s12911-020-01337-1>.
- JANUARY, C. T.; WANN, L. S.; ALPERT, J. S.; CALKINS, H.; CIGARROA, J. E.; CLEVELAND, J. C.; CONTI, J. B.; ELLINOR, P. T.; EZEKOWITZ, M. D.; FIELD, M. E.; MURRAY, K. T.; SACCO, R. L.; STEVENSON, W. G.; TCHOU, P. J.; TRACY, C. M.; YANCY, C. W. 2014 aha/acc/hrs guideline for the management of patients with atrial fibrillation: Executive summary: A report of the american college of cardiology/american heart association task force on practice guidelines and the heart rhythm society. **Circulation**, Ovid Technologies (Wolters Kluwer Health), v. 130, n. 23, p. 2071–2104, dez. 2014. ISSN 1524-4539. Disponível em: <http://dx.doi.org/10.1161/CIR.0000000000000040>.

- JENKAL, W.; LATIF, R.; TOUMANARI, A.; DLIYOU, A.; B'CHARRI, O. E.; MAOULAININE, F. M. An efficient algorithm of ecg signal denoising using the adaptive dual threshold filter and the discrete wavelet transform. **Biocybernetics and Biomedical Engineering**, Elsevier BV, v. 36, n. 3, p. 499–508, 2016. ISSN 0208-5216. Disponível em: <http://dx.doi.org/10.1016/j.bbe.2016.04.001>.
- JOY, J.; MANIMEGALAI, P. Wavelet based emg artifact removal from ecg signal. **Journal of Eng. Comp. & Appl. Sci**, v. 2, p. 55–58, 2013.
- KE, G.; MENG, Q.; FINLEY, T.; WANG, T.; CHEN, W.; MA, W.; YE, Q.; LIU, T.-Y. Lightgbm: A highly efficient gradient boosting decision tree. In: GUYON, I.; LUXBURG, U. V.; BENGIO, S.; WALLACH, H.; FERGUS, R.; VISHWANATHAN, S.; GARNETT, R. (Ed.). **Advances in Neural Information Processing Systems**. Curran Associates, Inc., 2017. v. 30. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf.
- KENNEDY, A.; FINLAY, D. D.; GULDENRING, D.; BOND, R.; MORAN, K.; MCLAUGHLIN, J. The cardiac conduction system. **Critical Care Nursing Clinics of North America**, Elsevier BV, v. 28, n. 3, p. 269–279, set. 2016. Disponível em: <https://doi.org/10.1016/j.cnc.2016.04.001>.
- KHER, R. *et al.* Signal processing techniques for removing noise from ecg signals. **jber**, v. 3, n. 101, p. 1–9, 2019. Disponível em: <http://dx.doi.org/10.17303/jber.2019.3.101>.
- KHURSHID, S.; FRIEDMAN, S.; REEDER, C.; ACHILLE, P. D.; DIAMANT, N.; SINGH, P.; HARRINGTON, L. X.; WANG, X.; AL-ALUSI, M. A.; SARMA, G.; FOULKES, A. S.; ELLINOR, P. T.; ANDERSON, C. D.; HO, J. E.; PHILIPPAKIS, A. A.; BATRA, P.; LUBITZ, S. A. Ecg-based deep learning and clinical risk factors to predict atrial fibrillation. **Circulation**, Ovid Technologies (Wolters Kluwer Health), v. 145, n. 2, p. 122–133, jan. 2022. ISSN 1524-4539. Disponível em: <http://dx.doi.org/10.1161/circulationaha.121.057480>.
- KOLDA, T. G.; BADER, B. W. Tensor decompositions and applications. **SIAM Review**, Society for Industrial & Applied Mathematics (SIAM), v. 51, n. 3, p. 455–500, ago. 2009. Disponível em: <https://doi.org/10.1137/07070111x>.
- KRIJTHE, B. P.; KUNST, A.; BENJAMIN, E. J.; LIP, G. Y. H.; FRANCO, O. H.; HOFMAN, A.; WITTEMAN, J. C. M.; STRICKER, B. H.; HEERINGA, J. Projections on the number of individuals with atrial fibrillation in the european union, from 2000 to 2060. **European Heart Journal**, Oxford University Press (OUP), v. 34, n. 35, p. 2746–2751, jul. 2013. ISSN 1522-9645. Disponível em: <http://dx.doi.org/10.1093/eurheartj/eh280>.
- KRUSKAL, J. B. Three-way arrays: rank and uniqueness of trilinear decompositions, with application to arithmetic complexity and statistics. **Linear Algebra and its Applications**, Elsevier BV, v. 18, n. 2, p. 95–138, 1977. ISSN 0024-3795. Disponível em: [http://dx.doi.org/10.1016/0024-3795\(77\)90069-6](http://dx.doi.org/10.1016/0024-3795(77)90069-6).
- LATHAUWER, L. D. Decompositions of a higher-order tensor in block terms—part ii: Definitions and uniqueness. **SIAM Journal on Matrix Analysis and Applications**, Society for Industrial Applied Mathematics (SIAM), v. 30, n. 3, p. 1033–1066, jan. 2008. ISSN 1095-7162. Disponível em: <http://dx.doi.org/10.1137/070690729>.
- LATHAUWER, L. D. Blind separation of exponential polynomials and the decomposition of a tensor in rank- $(l_r, l_r, 1)$ terms. **SIAM Journal on Matrix Analysis and Applications**,

Society for Industrial Applied Mathematics (SIAM), v. 32, n. 4, p. 1451–1474, out. 2011. ISSN 1095-7162. Disponível em: <http://dx.doi.org/10.1137/100805510>.

LATHAUWER, L. D.; NION, D. Decompositions of a higher-order tensor in block terms—part iii: Alternating least squares algorithms. **SIAM Journal on Matrix Analysis and Applications**, Society for Industrial Applied Mathematics (SIAM), v. 30, n. 3, p. 1067–1083, jan. 2008. ISSN 1095-7162. Disponível em: <http://dx.doi.org/10.1137/070690730>.

LEVKOV, C.; MIHOV, G.; IVANOV, R.; DASKALOV, I.; CHRISTOV, I.; DOTSINSKY, I. Removal of power-line interference from the ecg: a review of the subtraction procedure. **BioMedical Engineering OnLine**, Springer Science and Business Media LLC, v. 4, n. 1, ago. 2005. ISSN 1475-925X. Disponível em: <http://dx.doi.org/10.1186/1475-925X-4-50>.

LI, Y.; TANG, X.; WANG, A.; TANG, H. Probability density distribution of delta RR intervals: a novel method for the detection of atrial fibrillation. **Australasian Physical & Engineering Sciences in Medicine**, Springer Science and Business Media LLC, v. 40, n. 3, p. 707–716, jun. 2017. Disponível em: <https://doi.org/10.1007/s13246-017-0554-2>.

LIAN, J.; WANG, L.; MUESSIG, D. A simple method to detect atrial fibrillation using rr intervals. **The American Journal of Cardiology**, Elsevier BV, v. 107, n. 10, p. 1494–1497, maio 2011. ISSN 0002-9149. Disponível em: <http://dx.doi.org/10.1016/j.amjcard.2011.01.028>.

LIAQAT, S.; DASHTIPOUR, K.; ZAHID, A.; ASSALEH, K.; ARSHAD, K.; RAMZAN, N. Detection of atrial fibrillation using a machine learning approach. **Information**, MDPI AG, v. 11, n. 12, p. 549, nov. 2020. ISSN 2078-2489. Disponível em: <http://dx.doi.org/10.3390/info11120549>.

LIP, G. Y. H.; FAUCHIER, L.; FREEDMAN, S. B.; GELDER, I. V.; NATALE, A.; GIANNI, C.; NATTEL, S.; POTPARA, T.; RIENSTRA, M.; TSE, H.-F.; LANE, D. A. Atrial fibrillation. **Nature Reviews Disease Primers**, Springer Science and Business Media LLC, v. 2, n. 1, mar. 2016. ISSN 2056-676X. Disponível em: <http://dx.doi.org/10.1038/nrdp.2016.16>.

LOWN, M.; BROWN, M.; BROWN, C.; YUE, A. M.; SHAH, B. N.; CORBETT, S. J.; LEWITH, G.; STUART, B.; MOORE, M.; LITTLE, P. Machine learning detection of atrial fibrillation using wearable technology. **PLOS ONE**, Public Library of Science (PLoS), v. 15, n. 1, p. e0227401, jan. 2020. ISSN 1932-6203. Disponível em: <http://dx.doi.org/10.1371/journal.pone.0227401>.

LYON, A.; MINCHOLÉ, A.; MARTÍNEZ, J. P.; LAGUNA, P.; RODRIGUEZ, B. Computational techniques for ecg analysis and interpretation in light of their contribution to medical advances. **Journal of The Royal Society Interface**, The Royal Society, v. 15, n. 138, p. 20170821, jan. 2018. ISSN 1742-5662. Disponível em: <http://dx.doi.org/10.1098/rsif.2017.0821>.

MAGALHAES, L.; FIGUEIREDO, M.; CINTRA, F.; SAAD, E.; KUNIYOSHI, R.; TEIXEIRA, R.; FILHO, A. L.; D'AVILA, A.; PAOLA, A. de; KALIL, C.; MOREIRA, D.; FILHO, D. S.; STERNICK, E.; DARRIEUX, F.; FENELON, G.; LIMA, G.; ATIÉ, J.; MATEOS, J.; MOREIRA, J.; VASCONCELOS, J.; ZIMERMAN, L.; SILVA, L.; SILVA, M.; SCANAVACCA, M.; SOUZA, O. II diretrizes brasileiras de fibrilação atrial. **Arquivos Brasileiros de Cardiologia**, Sociedade Brasileira de Cardiologia, v. 106, n. 4, 2016. ISSN 0066-782X. Disponível em: <http://dx.doi.org/10.5935/abc.20160055>.

MAGGIO, A. C. V.; PAULA, M.; LACIAR, E.; DAVID, P. **Quantification of Ventricular Repolarization Dispersion Using Digital Processing of the Surface ECG**. InTech, 2012. Disponível em: <http://dx.doi.org/10.5772/23050>.

MANT, J.; FITZMAURICE, D. A.; HOBBS, F. D. R.; JOWETT, S.; MURRAY, E. T.; HOLDER, R.; DAVIES, M.; LIP, G. Y. H. Accuracy of diagnosing atrial fibrillation on electrocardiogram by primary care practitioners and interpretative diagnostic software: analysis of data from screening for atrial fibrillation in the elderly (SAFE) trial. *BMJ*, v. 335, n. 7616, p. 380, jun. 2007. Disponível em: <https://doi.org/10.1136/bmj.39227.551713.ae>.

MAROUF, M.; SARANOVAC, L.; VUKOMANOVIC, G. Algorithm for emg noise level approximation in ecg signals. **Biomedical Signal Processing and Control**, Elsevier BV, v. 34, p. 158–165, abr. 2017. ISSN 1746-8094. Disponível em: <http://dx.doi.org/10.1016/j.bspc.2017.02.002>.

MILLER, M. R.; BORTHWICK, S. J.; SHAW, C. A.; MCLEAN, S. G.; MCCLURE, D.; MILLS, N. L.; DUFFIN, R.; DONALDSON, K.; MEGSON, I. L.; HADOKI, P. W.; NEWBY, D. E. Direct impairment of vascular function by diesel exhaust particulate through reduced bioavailability of endothelium-derived nitric oxide induced by superoxide free radicals. **Environmental Health Perspectives**, Environmental Health Perspectives, v. 117, n. 4, p. 611–616, abr. 2009. ISSN 1552-9924. Disponível em: <http://dx.doi.org/10.1289/ehp.0800235>.

MILLER, M. R.; NEWBY, D. E. Air pollution and cardiovascular disease: car sick. **Cardiovascular Research**, Oxford University Press (OUP), out. 2019. ISSN 1755-3245. Disponível em: <http://dx.doi.org/10.1093/cvr/cvz228>.

MIRVIS, D. **Electrocardiography: A Physiologic Approach**. Mosby, 1993. ISBN 9780801674792. Disponível em: <https://books.google.com.br/books?id=v0xsAAAAMAAJ>.

MITCHELL, R. N.; SCHOEN, F. J. **Blood Vessels**. Elsevier, 2010. 487–528 p. ISBN 9781437707922. Disponível em: <http://dx.doi.org/10.1016/B978-1-4377-0792-2.50016-X>.

MIYASAKA, Y.; BARNES, M. E.; GERSH, B. J.; CHA, S. S.; BAILEY, K. R.; ABHAYARATNA, W. P.; SEWARD, J. B.; TSANG, T. S. Secular trends in incidence of atrial fibrillation in olmsted county, minnesota, 1980 to 2000, and implications on the projections for future prevalence. **Circulation**, Ovid Technologies (Wolters Kluwer Health), v. 114, n. 2, p. 119–125, jul. 2006. ISSN 1524-4539. Disponível em: <http://dx.doi.org/10.1161/CIRCULATIONAHA.105.595140>.

MORILLO, C. A.; BANERJEE, A.; PEREL, P.; WOOD, D.; JOUVEN, X. Atrial fibrillation: the current epidemic. **Journal of Geriatric Cardiology**, v. 14, n. 3, p. 195–203, Mar 2017. ISSN 1671-5411. PMID: PMC5460066. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/28592963/>.

NOORDERGRAAF, A. **Circulatory System Dynamics**. Elsevier Science, 1978. (Biophysics and Bioengineering Series : a series of monographs and edited treatises). ISBN 9780125209502. Disponível em: <https://books.google.com.br/books?id=j81qAAAAMAAJ>.

NPATCHETT. **Derivation of the limb leads**. 2015. Acesso em: 20 jan. 2024. Disponível em: https://commons.wikimedia.org/wiki/File:Limb_leads_of_EKG.png.

OLIVEIRA, P. M. R. de; GOULART, J. H. d. M.; FERNANDES, C. A. R.; ZARZOSO, V. Blind source separation in persistent atrial fibrillation electrocardiograms using block-term tensor decomposition with löwner constraints. **IEEE Journal of Biomedical and Health Informatics**, Institute of Electrical and Electronics Engineers (IEEE), v. 26, n. 4, p. 1538–1548, abr. 2022. ISSN 2168-2208. Disponível em: <http://dx.doi.org/10.1109/JBHI.2021.3108699>.

- OLIVEIRA, P. M. R. de; ZARZOSO, V. **Source Analysis and Selection Using Block Term Decomposition in Atrial Fibrillation**. Springer International Publishing, 2018. 46–56 p. ISSN 1611-3349. ISBN 9783319937649. Disponível em: http://dx.doi.org/10.1007/978-3-319-93764-9_5.
- OLIVEIRA, P. M. R. de; ZARZOSO, V. Temporal stability of block term decomposition in noninvasive atrial fibrillation analysis. In: **2018 52nd Asilomar Conference on Signals, Systems, and Computers**. IEEE, 2018. Disponível em: <http://dx.doi.org/10.1109/ACSSC.2018.8645164>.
- OLIVEIRA, P. M. R. de; ZARZOSO, V. Temporal stability of block term decomposition in noninvasive atrial fibrillation analysis. In: **2018 52nd Asilomar Conference on Signals, Systems, and Computers**. IEEE, 2018. Disponível em: <http://dx.doi.org/10.1109/ACSSC.2018.8645164>.
- OLIVEIRA, P. M. R. de; ZARZOSO, V. Löwner-based tensor decomposition for blind source separation in atrial fibrillation ecgs. In: **2019 27th European Signal Processing Conference (EUSIPCO)**. IEEE, 2019. Disponível em: <http://dx.doi.org/10.23919/EUSIPCO.2019.8902493>.
- OLIVEIRA, P. M. R. de; ZARZOSO, V.; FERNANDES, C. A. R. Coupled tensor model of atrial fibrillation ecg. In: **2020 28th European Signal Processing Conference (EUSIPCO)**. IEEE, 2021. Disponível em: <http://dx.doi.org/10.23919/Eusipco47968.2020.9287494>.
- PASSMAN, R. Mobile health technologies in the diagnosis and management of atrial fibrillation. **Current Opinion in Cardiology**, Ovid Technologies (Wolters Kluwer Health), v. 37, n. 1, p. 1–9, set. 2021. ISSN 1531-7080. Disponível em: <http://dx.doi.org/10.1097/hco.0000000000000930>.
- PATEL, S.; WANG, M.; GUO, J.; SMITH, G.; CHEN, C. A study of r-r interval transition matrix features for machine learning algorithms in AFib detection. **Sensors**, MDPI AG, v. 23, n. 7, p. 3700, abr. 2023. Disponível em: <https://doi.org/10.3390/s23073700>.
- PEREZ, M. V.; DEWEY, F. E.; MARCUS, R.; ASHLEY, E. A.; AL-AHMAD, A. A.; WANG, P. J.; FROELICHER, V. F. Electrocardiographic predictors of atrial fibrillation. **American Heart Journal**, Elsevier BV, v. 158, n. 4, p. 622–628, out. 2009. ISSN 0002-8703. Disponível em: <http://dx.doi.org/10.1016/j.ahj.2009.08.002>.
- POLLOCK, J. D.; MAKARYUS, A. A. N. Physiology, cardiac cycle. In: **StatPearls [Internet]**. Treasure Island, FL: StatPearls Publishing, 2022. Disponível em: <https://www.ncbi.nlm.nih.gov/books/NBK470527/>.
- POLO, T. C. F.; MIOT, H. A. Aplicações da curva roc em estudos clínicos e experimentais. **Jornal Vascular Brasileiro**, FapUNIFESP (SciELO), v. 19, 2020. ISSN 1677-5449. Disponível em: <http://dx.doi.org/10.1590/1677-5449.200186>.
- PRASITLUMKUM, N.; CHEUNGASITPORN, W.; CHOKESUWATTANASKUL, A.; THANGJUI, S.; THONGPRAYOON, C.; BATHINI, T.; VALLABHAJOSYULA, S.; KANITSORAPHAN, C.; LEESUTIPORNCHAI, T.; CHOKESUWATTANASKUL, R. Diagnostic accuracy of smart gadgets/wearable devices in detecting atrial fibrillation: A systematic review and meta-analysis. **Archives of Cardiovascular Diseases**, Elsevier BV, v. 114, n. 1, p. 4–16, jan. 2021. ISSN 1875-2136. Disponível em: <http://dx.doi.org/10.1016/j.acvd.2020.05.015>.
- PRYSTOWSKY, E. N.; PADANILAM, B. J.; FOGEL, R. I. Treatment of atrial fibrillation. **JAMA**, American Medical Association (AMA), v. 314, n. 3, p. 278, jul. 2015. ISSN 0098-7484. Disponível em: <http://dx.doi.org/10.1001/jama.2015.7505>.

Pulse Cardiology. **Difference Between Atrial Fibrillation and Atrial Flutter**. 2020. Acesso em: 28 fev. 2024. Disponível em: <https://pulse-cardiology.com/difference-between-atrial-fibrillation-atrial-flutter/>.

RENOUX, C.; PATENAUDE, V.; SUISSA, S. Incidence, mortality, and sex differences of non-valvular atrial fibrillation: A population-based study. **Journal of the American Heart Association**, Ovid Technologies (Wolters Kluwer Health), v. 3, n. 6, dez. 2014. ISSN 2047-9980. Disponível em: <http://dx.doi.org/10.1161/JAHA.114.001402>.

RIBEIRO, L. N.; ALMEIDA, A. L. F. de; ZARZOSO, V. Enhanced block term decomposition for atrial activity extraction in atrial fibrillation ecg. In: **2016 IEEE Sensor Array and Multichannel Signal Processing Workshop (SAM)**. IEEE, 2016. Disponível em: <http://dx.doi.org/10.1109/SAM.2016.7569709>.

RIBEIRO, L. N.; HIDALGO-MUNOZ, A. R.; ZARZOSO, V. Atrial signal extraction in atrial fibrillation electrocardiograms using a tensor decomposition approach. In: **2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE, 2015. Disponível em: <http://dx.doi.org/10.1109/EMBC.2015.7320000>.

RIETA, J.; CASTELLS, F.; SANCHEZ, C.; ZARZOSO, V.; MILLET, J. Atrial activity extraction for atrial fibrillation analysis using blind source separation. **IEEE Transactions on Biomedical Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 51, n. 7, p. 1176–1186, jul. 2004. Disponível em: <https://doi.org/10.1109/tbme.2004.827272>.

RIZWAN, A.; ZOHA, A.; MABROUK, I. B.; SABBOUR, H. M.; AL-SUMAITI, A. S.; ALOMAINY, A.; IMRAN, M. A.; ABBASI, Q. H. A review on the state of the art in atrial fibrillation detection enabled by machine learning. **IEEE Reviews in Biomedical Engineering**, Institute of Electrical and Electronics Engineers (IEEE), v. 14, p. 219–239, 2021. ISSN 1941-1189. Disponível em: <http://dx.doi.org/10.1109/RBME.2020.2976507>.

ROMERO, F. P.; ROMAGUERA, L.; SEISDEDOS, C. R.; FILHO, C.; COSTA, M.; NETO, J. Baseline wander removal methods for ecg signals: A comparative study. **arXiv preprint arXiv:1807.11359**, 07 2018. Disponível em: <https://arxiv.org/abs/1807.11359>.

RONTOGIANNIS, A. A.; KOFIDIS, E.; GIAMPOURAS, P. V. Block-term tensor decomposition: Model selection and computation. **IEEE Journal of Selected Topics in Signal Processing**, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 3, p. 464–475, abr. 2021. Disponível em: <https://doi.org/10.1109/jstsp.2021.3051488>.

SHIOGAI, Y.; STEFANOVSKA, A.; MCCLINTOCK, P. Nonlinear dynamics of cardiovascular ageing. **Physics Reports**, Elsevier BV, v. 488, n. 2–3, p. 51–110, mar. 2010. ISSN 0370-1573. Disponível em: <http://dx.doi.org/10.1016/j.physrep.2009.12.003>.

SIONTIS, K. C.; NOSEWORTHY, P. A.; ATTIA, Z. I.; FRIEDMAN, P. A. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. **Nature Reviews Cardiology**, Springer Science and Business Media LLC, v. 18, n. 7, p. 465–478, fev. 2021. ISSN 1759-5010. Disponível em: <http://dx.doi.org/10.1038/s41569-020-00503-2>.

SORBER, L.; BAREL, M. V.; LATHAUWER, L. D. Optimization-based algorithms for tensor decompositions: Canonical polyadic decomposition, decomposition in rank- $(l_r, l_r, 1)$ terms, and a new generalization. **SIAM Journal on Optimization**, Society for Industrial Applied Mathematics (SIAM), v. 23, n. 2, p. 695–720, jan. 2013. ISSN 1095-7189. Disponível em: <http://dx.doi.org/10.1137/120868323>.

SÖRNMO, L.; LAGUNA, P. **Electrocardiogram (ECG) Signal Processing**. Wiley, 2006. Disponível em: <http://dx.doi.org/10.1002/9780471740360.ebs1482>.

St John Ambulance. **Introduction to the ECG**. 2020. Acesso em: 23 mar. 2024. Disponível em: <https://clinical.stjohnwa.com.au/medical-library/ecg-library/introduction-overview/introduction-to-the-ecg>.

SØRENSEN, M.; DOMANOV, I.; LATHAUWER, L. D. Coupled canonical polyadic decompositions and (coupled) decompositions in multilinear rank- $(l_{r,n}, l_{r,n}, 1)$ terms—part ii: Algorithms. **SIAM Journal on Matrix Analysis and Applications**, Society for Industrial Applied Mathematics (SIAM), v. 36, n. 3, p. 1015–1045, jan. 2015. ISSN 1095-7162. Disponível em: <http://dx.doi.org/10.1137/140956865>.

TATENO, K.; GLASS, L. Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of rr and rr intervals. **Medical and Biological Engineering and Computing**, Springer Science and Business Media LLC, v. 39, n. 6, p. 664–671, nov. 2001. ISSN 1741-0444. Disponível em: <http://dx.doi.org/10.1007/BF02345439>.

THOSAR, S. S.; BUTLER, M. P.; SHEA, S. A. Role of the circadian system in cardiovascular disease. **Journal of Clinical Investigation**, American Society for Clinical Investigation, v. 128, n. 6, p. 2157–2167, jun. 2018. ISSN 1558-8238. Disponível em: <http://dx.doi.org/10.1172/jci80590>.

TISON, G. H.; SANCHEZ, J. M.; BALLINGER, B.; SINGH, A.; OLGIN, J. E.; PLETCHER, M. J.; VITTINGHOFF, E.; LEE, E. S.; FAN, S. M.; GLADSTONE, R. A.; MIKELL, C.; SOHONI, N.; HSIEH, J.; MARCUS, G. M. Passive detection of atrial fibrillation using a commercially available smartwatch. **JAMA Cardiology**, American Medical Association (AMA), v. 3, n. 5, p. 409, maio 2018. ISSN 2380-6583. Disponível em: <http://dx.doi.org/10.1001/jamacardio.2018.0136>.

TSIPOURAS, M.; FOTIADIS, D.; SIDERIS, D. An arrhythmia classification system based on the rr-interval signal. **Artificial Intelligence in Medicine**, Elsevier BV, v. 33, n. 3, p. 237–250, mar. 2005. ISSN 0933-3657. Disponível em: <http://dx.doi.org/10.1016/j.artmed.2004.03.007>.

TUCKER, L. R. Some mathematical notes on three-mode factor analysis. **Psychometrika**, Springer Science and Business Media LLC, v. 31, n. 3, p. 279–311, set. 1966. Disponível em: <https://doi.org/10.1007/bf02289464>.

UITTENBOGAART, S. B.; GURP, N. Verbiest-van; LUCASSEN, W. A. M.; WINKENS, B.; NIELEN, M.; ERKENS, P. M. G.; KNOTTNERUS, J. A.; WEERT, H. C. P. M. van; STOFFERS, H. E. J. H. Opportunistic screening versus usual care for detection of atrial fibrillation in primary care: cluster randomised controlled trial. **BMJ**, BMJ, p. m3208, set. 2020. ISSN 1756-1833. Disponível em: <http://dx.doi.org/10.1136/bmj.m3208>.

VERVLIET, N.; DEBALS, O.; LATHAUWER, L. D. Tensorlab 3.0 — numerical optimization strategies for large-scale constrained and coupled matrix/tensor factorization. In: **2016 50th Asilomar Conference on Signals, Systems and Computers**. IEEE, 2016. Disponível em: <http://dx.doi.org/10.1109/ACSSC.2016.7869679>.

WAGNER, G.; STRAUSS, D. **Marriott's Practical Electrocardiography**. Wolters Kluwer Health, 2014. (Online access with purchase: Lippincott, Williams & Wilkins Doody Collection). ISBN 9781451146257. Disponível em: <https://books.google.com.br/books?id=whueAgAAQBAJ>.

- WANL, H. The elimination of 50 hz power line interference from ecg using a variable step size lms adaptive filtering algorithm. In: . [S. n.], 2006. Disponível em: <https://typeset.io/papers/the-elimination-of-50-hz-power-line-interference-from-ecg-3m9umz1tix>.
- WEINHAUS, A. J.; ROBERTS, K. P. **Anatomy of the Human Heart**. Humana Press, 2009. 59–85 p. ISBN 9781603273725. Disponível em: http://dx.doi.org/10.1007/978-1-60327-372-5_5.
- YOUNG, B.; BRODNICK, D.; SPAULDING, R. A comparative study of a hidden markov model detector for atrial fibrillation. In: **Neural Networks for Signal Processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop (Cat. No.98TH8468)**. IEEE, 1999. (NNSP-99). Disponível em: <http://dx.doi.org/10.1109/NNSP.1999.788166>.
- ZARZOSO, V. Parameter estimation in block term decomposition for noninvasive atrial fibrillation analysis. In: **2017 IEEE 7th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)**. IEEE, 2017. Disponível em: <http://dx.doi.org/10.1109/CAMSAP.2017.8313173>.
- ZARZOSO, V.; COMON, P. Robust independent component analysis by iterative maximization of the kurtosis contrast with algebraic optimal step size. **IEEE Transactions on Neural Networks**, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 2, p. 248–261, fev. 2010. ISSN 1941-0093. Disponível em: <http://dx.doi.org/10.1109/TNN.2009.2035920>.
- ZHANG, X.; LI, J.; CAI, Z.; ZHANG, L.; CHEN, Z.; LIU, C. Over-fitting suppression training strategies for deep learning-based atrial fibrillation detection. **Medical amp; Biological Engineering amp; Computing**, Springer Science and Business Media LLC, v. 59, n. 1, p. 165–173, jan. 2021. ISSN 1741-0444. Disponível em: <http://dx.doi.org/10.1007/s11517-020-02292-9>.
- ZINK, M. D.; MARX, N.; CRIJNS, H. J. G. M.; SCHOTTEN, U. Opportunities and challenges of large-scale screening for atrial fibrillation. **Herzschrittmachertherapie + Elektrophysiologie**, Springer Science and Business Media LLC, v. 29, n. 1, p. 57–61, jan. 2018. ISSN 1435-1544. Disponível em: <http://dx.doi.org/10.1007/s00399-017-0550-y>.