



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Biológicas
Departamento de Computação



Classificação Automática de Arritmias Utilizando Mapeamento de Sinais de ECG em Grafos e Redes Neurais Convolucionais de Grafos

Rafael Francisco de Oliveira

Julho, 2023
Ouro Preto–MG



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Biológicas
Departamento de Computação



Classificação Automática de Arritmias Utilizando Mapeamento de Sinais de ECG em Grafos e Redes Neurais Convolucionais de Grafos

Orientador: Prof. Dr. Eduardo José da Silva Luz

Coorientador: Prof. Dr. Vander Luis de Souza Freitas

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Ciência da Computação da Universidade Federal de Ouro Preto, como parte dos requisitos necessários à obtenção do título de Mestre em Ciência da Computação.

Universidade Federal de Ouro Preto

Ouro Preto

Julho de 2023

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

O48c Oliveira, Rafael Francisco De.
Classificação automática de arritmias utilizando mapeamento de sinais de ECG em Grafos e Redes Neurais convolucionais de grafos.
[manuscrito] / Rafael Francisco De Oliveira. - 2023.
90 f.: il.: color., tab..

Orientador: Prof. Dr. Eduardo José da Silva Luz.
Coorientador: Prof. Dr. Vander Luis de Souza Freitas.
Dissertação (Mestrado Acadêmico). Universidade Federal de Ouro Preto. Departamento de Computação. Programa de Pós-Graduação em Ciência da Computação.
Área de Concentração: Ciência da Computação.

1. Arritmia. 2. Eletrocardiograma. 3. Redes Neurais. 4. Classificação. I. Luz, Eduardo José da Silva. II. Freitas, Vander Luis de Souza. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 004

Bibliotecário(a) Responsável: Luciana De Oliveira - SIAPE: 1.937.800



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO



FOLHA DE APROVAÇÃO

Rafael Francisco de Oliveira

Classificação automática de arritmias utilizando mapeamento de sinais de ECG em grafos e redes neurais convolucionais de grafos

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Mestre em Ciência da Computação

Aprovada em 21 de julho de 2023

Membros da banca

Prof. Dr. Eduardo José da Silva Luz - Orientador - Universidade Federal de Ouro Preto
Prof. Dr. Vander Luís de Souza Freitas - Co-Orientador - Universidade Federal de Ouro Preto
Profa. Dra. Andrea Gomes Campos Bianchi - Universidade Federal de Ouro Preto
Prof. Dr. Jadson Castro Gertrudes - Universidade Federal de Ouro Preto
Prof. Dr. Marcos Gonçalves Quiles - Universidade Federal de São Paulo

Prof. Dr. Eduardo José da Silva Luz, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 09/09/2023



Documento assinado eletronicamente por **Gladston Juliano Prates Moreira, COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**, em 13/09/2023, às 12:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Eduardo Jose da Silva Luz, VICE-COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO**, em 13/09/2023, às 13:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0588810** e o código CRC **DD746DAE**.

Este trabalho é dedicado primeiramente a Deus. O maior orientador da minha vida. Ele nunca me abandonou nos momentos de necessidade.

Aos meus pais, irmãos e a toda minha família que, com muito carinho e apoio, não mediram esforços para que eu chegasse até esta etapa de minha vida. Eles são os pilares da minha formação como ser humano.

A todos os professores que de alguma maneira me influenciaram na minha trajetória transmitindo seus conhecimentos.

Dedico a todos aqueles que de alguma forma contribuíram com meu desenvolvimento tanto direta e indiretamente em todos os momentos de minha formação.

Agradecimentos

A jornada nunca foi simples. Contudo, aquele que tem amigos nunca está sozinho. Agradeço a Deus, por ter permitido que eu tivesse saúde e determinação para não desanimar durante a realização desta dissertação.

Aos meus pais Márcia e José, meus irmãos Jaqueline, Marcelo, Andréia e Flávia (*in memoriam*) e todos os familiares que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu me dedicava à realização desta dissertação.

Aos professores, em especial aos meus orientadores Eduardo e Vander, pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho durante a realização desta jornada e aumentaram a qualidade desta dissertação. E aos que de alguma forma ajudaram no meu processo de formação.

Aos amigos de dentro e fora de casa, que sempre me dão força. Aos amigos do laboratório CISLab, por acompanharem a minha jornada. Aos amigos que não vejo há muito tempo, pois espero encontrá-los. Aos amigos que converso sempre, pois espero não perdê-los nos ciclos da vida.

E especial agradecimento ao meu marido, companheiro e melhor amigo Frances, que sempre me apoiou em todos os momentos. Obrigado pelo apoio, carinho e por estar sempre junto, oferecendo conselhos e me ajudando nos momentos de estresse. O modo difuso fez milagres!!!

Por fim, não menos importante, agradecimentos à *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior* - Brasil (CAPES) - Financiamento código 001, *Fundação de Amparo à Pesquisa do Estado de Minas Gerais* (FAPEMIG, APQ-01518-21), *Conselho Nacional de Desenvolvimento Científico e Tecnológico* (CNPq) e Universidade Federal de Ouro Preto (UFOP) pelo fomento à dissertação apresentada.

“It’s not that I’m so smart, it’s just that I stay with problems longer.”

— Albert Einstein (*1879 – †1955)

Resumo

Conforme a Organização Mundial da Saúde (OMS), as doenças cardíacas figuram como a principal causa de morte em âmbito global. Embora muitas dessas condições possam ser diagnosticadas antecipadamente, a incidência de casos segue em ascensão. Estimativas indicam que mais de 75% dos casos ocorrem em países de baixa renda ou em desenvolvimento, e 17,9 milhões de pessoas morreram de doenças cardíacas apenas em 2019, totalizando 32% das mortes globais. A persistência desse aumento de casos realça a necessidade de novas abordagens que automatizem a detecção de arritmias em sinais de eletrocardiograma (ECG). Na literatura, inúmeras técnicas de extração de características são utilizadas para representar o ECG como séries temporais unidimensionais, com o intuito de classificar padrões associados à arritmias. Notavelmente, abordagens baseadas em aprendizado profundo (redes de convolução) têm obtido resultados impressionantes para tal tarefa. Entretanto, abordagens baseadas em grafos e redes complexas foram recentemente investigadas como alternativas para aprimorar o desempenho na detecção de arritmias, porém, ainda se apresenta como um desafio mapear ou representar adequadamente sinais de ECG na forma de grafos. Assim, este estudo explora a representação dos sinais de ECG em grafos por meio do *Visibility Graph* (VG) e *Vector Visibility Graph* (VVG). Adicionalmente, utilizamos a estrutura de grafo para a classificação de arritmias com Redes Neurais Convolucionais de Grafos (*Graph Convolutional Networks* - GCNs). Experimentos envolvendo diferentes arquiteturas de GCNs foram avaliados no conjunto de dados MIT-BIH, seguindo os paradigmas *inter-patient* e *intra-patient*. Os resultados indicam que a representação dos sinais de ECG por meio de VG e VVG é promissora, e que o VG provou ser mais eficiente em comparação ao método VVG para as arquiteturas de GCNs exploradas. Em relação à classe de batimentos ectópicos supraventriculares (S), os resultados evidenciam que no paradigma *inter-patient* ainda há um grande desafio a ser superado. Arquiteturas mais simples de GCNs tiveram melhores resultados do que as complexas, indicando que sua simplicidade melhora a captura das características essenciais dos dados e evita ruídos. Essas arquiteturas também são mais eficientes computacionalmente, o que é importante em cenários de recursos limitados.

Palavras-chaves: Arritmia, Eletrocardiograma, Batimentos, Redes Neurais de Grafos, ECG, Classificação, Grafos.

Abstract

According to the World Health Organization (WHO), cardiovascular diseases are the leading cause of death globally. Although many of these conditions can be diagnosed in advance, the incidence of cases continues to rise. Estimates indicate that over 75% of cases occur in low-income or developing countries, and 17.9 million people died from cardiovascular diseases in 2019 alone, accounting for 32% of global deaths. The persistence of this increasing trend highlights the needs for new approaches that automate the detection of arrhythmias in electrocardiogram (ECG) signals. In the literature, numerous feature extraction techniques are used to represent the ECG as one-dimensional time series, with the aim of classifying patterns associated with arrhythmias. Notably, deep learning-based approaches (convolutional networks) have achieved impressive results for this task. However, graph-based and complex network approaches have recently been investigated as alternatives to improve performance in arrhythmia detection. Nonetheless, mapping or appropriately representing ECG signals in the form of graphs still presents a challenge. Thus, this study explores the representation of ECG signals as graphs through the Visibility Graph (VG) and Vector Visibility Graph (VVG). Additionally, we explore the graph structure for arrhythmia classification with Graph Convolutional Networks (GCNs). Experiments involving different GCN architectures are evaluated on the MIT-BIH dataset, following the inter-patient and intra-patient paradigms. The results indicate that the representation of ECG signals through VG and VVG is promising, and VG has proven to be more efficient compared to the VVG method for the explored GCN architectures. Regarding supraventricular ectopic class beats (S), the results demonstrate that there is still a significant challenge to overcome in the inter-patient paradigm. Simpler GCN architectures yielded better results than complex ones, indicating that their simplicity enhances capturing essential data features and avoids noise. These architectures are also computationally more efficient, which is important in scenarios with limited resources.

Keywords: Arrhythmia, Electrocardiogram, Beats, Graph Convolutional Networks, ECG, Classification, Graphs.

Sumário

	Lista de ilustrações	12
	Lista de tabelas	14
1	INTRODUÇÃO	16
1.1	Questões de pesquisa	18
1.2	Objetivos	18
1.3	Principais Contribuições	19
1.4	Organização	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Trabalhos Relacionados	20
2.1.1	Pré-processamento	22
2.1.2	Segmentação	24
2.1.3	Extração de atributos	26
2.1.3.1	Atributos P-QRS-T	26
2.1.3.2	Atributos Estatísticos	27
2.1.3.3	Atributos Morfológicos	27
2.1.3.4	Atributos Wavelet	28
2.1.3.5	Atributos baseados em grafos	29
2.1.3.6	Outros atributos	30
2.1.3.7	Seleção de atributos	31
2.1.4	Classificação	32
2.1.5	Trabalhos estado da arte	34
2.2	Redes Complexas e Teoria de Grafos	38
2.2.1	Conversão de séries temporais em grafos	40
2.2.1.1	Visibility Graph (VG)	41
2.2.1.2	Vector Visibility Graph (VVG)	43
2.3	Graph Neural Network (GNN)	44
3	METODOLOGIA	50
3.1	Conjunto de Dados e o Protocolo AAMI	51
3.2	Construção da metodologia	54
4	RESULTADOS E DISCUSSÕES	58
4.1	Configurações, Métricas e Bibliotecas	58
4.2	Experimentos	58

4.2.1	Experimento 1: Novas Arquiteturas	59
4.2.2	Experimento 2: Quantidade de pontos na etapa de segmentação	62
4.2.3	Experimento 3: Agregação de informações nos vértices de cada grafo	63
4.2.4	Experimento 4: Inversão de conjuntos de dados DS1 e DS2	66
4.2.5	Experimento 5: Paradigma <i>intra-patient</i>	68
4.2.6	Experimento 6: Comparação do método proposto	70
4.2.7	Decisões experimentais	71
5	CONSIDERAÇÕES FINAIS	73
5.1	Conclusões	73
5.2	Trabalhos Futuros	74
	REFERÊNCIAS	76

Lista de ilustrações

Figura 1 – Esquema simplificado dos principais componentes de um <i>hardware</i> para captura de sinais de ECG.	21
Figura 2 – Configuração de 10 eletrodos frequentemente utilizada na realização de eletrocardiograma.	21
Figura 3 – Diagrama de um sistema de classificação de arritmias automática. . . .	22
Figura 4 – Pontos fiduciais (onda P, onda do complexo QRS e onda T) e intervalos usuais de um batimento de sinal de ECG.	23
Figura 5 – Processo de segmentação de um sinal de ECG em batimentos a partir da detecção do pico R.	25
Figura 6 – Representação geral de uma rede neural artificial com vários neurônios.	33
Figura 7 – Representação de dois tipos de grafos: (a) grafo não direcionado e (b) grafo direcionado.	40
Figura 8 – Exemplo aplicação do método VG. (a) Visibilidade entre as pontos de uma série temporal univariada (sinal de ECG com uma derivação). (b) Grafo gerado pelo VG.	42
Figura 9 – Exemplo da aplicação do método VVG. (a) Séries temporais multivariadas como sendo dois sinais de ECG com derivações diferentes. (b) Visibilidade entre os vetores. (c) Grafo gerado pelo VVG.	44
Figura 10 – Operações de convoluções: (a) Convolução 2D em domínio euclidiano e (b) Convolução de grafos em domínio não euclidiano.	45
Figura 11 – Diagrama do sistema proposto para classificação de arritmias a partir de sinais de ECG.	50
Figura 12 – Exemplo do mapeamento dos batimentos de uma derivação correspondentes às classes N, S e V utilizando o método VG.	56
Figura 13 – Experimento 1: Arquitetura da CNN-2Conv utilizada nos experimentos.	60
Figura 14 – Experimento 1: Arquitetura da CNN-4Conv utilizada nos experimentos.	60
Figura 15 – Experimento 1: Arquitetura da CNN-6Conv utilizada nos experimentos.	61

Lista de tabelas

Tabela 1 – Trabalhos estado da arte de DL para classificação de arritmias.	36
Tabela 2 – Estudos de aplicações de GNN em diversos contextos além da classificação de arritmias.	37
Tabela 3 – Exemplos de publicações que utilizaram diferentes tipos de GNNs em suas pesquisas.	46
Tabela 4 – Agrupamento dos batimentos recomendado pela norma da AAMI.	52
Tabela 5 – Distribuição dos registros do MIT-BIH em dois conjuntos de dados.	52
Tabela 6 – Descrição da quantidade de batimentos nos conjuntos de treinamento e teste.	53
Tabela 7 – Descrição da amostragem antes e depois do balanceamento de dados.	55
Tabela 8 – Experimento 1: Novas arquiteturas de GCNs.	59
Tabela 9 – Experimento 1: Distribuição dos registros do MIT-BIH do conjunto de dados DS1 em treinamento (DS1.1) e validação (DS1.2).	62
Tabela 10 – Experimento 1: Resumo da performance das novas arquiteturas de GCNs e CNNs no conjunto de validação (DS1.2).	62
Tabela 11 – Experimento 2: Resumo da performance das arquiteturas de GCNs e CNN no conjunto de validação (DS1.2) em relação ao tamanho de pontos na segmentação.	63
Tabela 12 – Experimento 3: Resumo da performance das arquiteturas de GCNs no conjunto de teste (DS2) em relação a agregação de informações nos grafos utilizando o método VG.	66
Tabela 13 – Experimento 3: Resumo da performance das arquiteturas de GCNs no conjunto de teste (DS2) em relação a agregação de informações nos grafos utilizando o método VVG.	66
Tabela 14 – Experimento 4: Resumo da performance das arquiteturas de GCNs e CNN em relação a inversão de conjuntos de dados DS1 e DS2 utilizando o método VG.	68
Tabela 15 – Experimento 4: Resumo da performance das arquiteturas de GCNs em relação a inversão de conjuntos de dados DS1 e DS2 utilizando o método VVG.	68
Tabela 16 – Experimento 5: Resumo da performance das arquiteturas de GCNs e CNN em relação ao paradigma <i>intra-patient</i> utilizando o método VG.	69
Tabela 17 – Experimento 5: Resumo da performance das arquiteturas de GCNs em relação ao paradigma <i>intra-patient</i> utilizando o método VVG.	69
Tabela 18 – Experimento 6: Comparativo do método proposto com o trabalho de Garcia et al. (2017).	71

Tabela 19 – Resultados da repetição de experimentos. 72

Glossário

AAMI *Association for the Advancement of Medical Instrumentation.* 17

AI *Artificial Intelligence.* 32

ANN *Artificial Neural Networks.* 16

CNN *Convolutional Neural Networks.* 32

ConvGNN *Convolutional Graph Neural Networks.* 45

DL *Deep Learning.* 33

DNN *Deep Neural Networks.* 16

ECG *Eletrocardiograma.* 16

GAE *Graph AutoEncoder.* 45

GCN *Graph Convolutional Networks.* 45

KNN *K-Nearest Neighbor.* 27

LSTM *Long Short Term Memory.* 18

ML *Machine Learning.* 16

OMS *Organização Mundial da Saúde.* 8, 16

RecGNN *Recurrent Graph Neural Network.* 45

RNN *Recurrent Neural Networks.* 32

STGNN *Spatial-Temporal Graph Neural Networks.* 45

SVM *Support Vector Machine.* 27

VG *Visibility Graph.* 18, 41

VVG *Vector Visibility Graph.* 19, 41

WT *Wavelet Transform.* 22

1 Introdução

De acordo com a Organização Mundial da Saúde (OMS), doenças cardíacas são a principal causa de morte no planeta. Embora boa parte das doenças cardíacas possam ser diagnosticadas com antecedência, o número de casos continua a crescer. Estima-se que mais de 75% dos casos acontecem em países pobres e em desenvolvimento e 17,9 milhões de pessoas morreram de doenças cardíacas apenas em 2019, representando 32% das mortes globais (WHO, 2021).

É de fundamental importância a detecção precoce de doenças cardíacas para que medidas de prevenção e aconselhamento possam ser tomadas. Para isso, o principal exame para diagnóstico de doenças cardíacas é chamado de Eletrocardiograma (ECG). Segundo Cohen (1986), o ECG foi um dos primeiros sinais estudados pelas técnicas de processamento de sinais biomédicos. Até os dias atuais, o ECG proporciona diagnósticos não invasivos e de baixo custo, útil para monitorar a atividade elétrica do coração, e amplamente utilizado em diversas aplicações, como teste de repouso ou teste de estresse (SÖRNMO; LAGUNA, 2005). Um sinal de ECG consiste em uma série de batimentos cardíacos (ou ondas) que representam a atividade elétrica do coração ao longo do tempo (WANG et al., 2021).

As arritmias são um dos problemas cardíacos detectáveis pelo exame de ECG. Devido à arritmia, o ritmo cardíaco pode ser muito rápido ou muito lento ou irregular em relação ao ritmo regular do coração. Conseqüentemente, o coração não consegue enviar sangue suficiente para certas partes do corpo afetando o funcionamento do coração e do cérebro, por exemplo. A maioria das arritmias é prejudicial ao coração, podendo ser subdivididas em dois tipos: arritmias sem risco de vida e arritmias com risco de vida (PANDEY; JANGHEL, 2019). Portanto, o monitoramento contínuo da atividade cardíaca é indispensável e é muito importante identificar a arritmia para um atendimento médico adequado (CHENG; DONG, 2017).

O processo de identificação e classificação de arritmias pode ser exaustivo para um ser humano e ainda sujeito a erros, visto que seria necessário uma análise de batimento a batimento em horas ou até mesmo dias de registros de ECG capturados por um *holter* cardíaco (GARCIA et al., 2017). Há a necessidade de estudos por soluções que mitiguem esses erros. Uma alternativa ao processo exaustivo de identificação e classificação de arritmias baseia-se na utilização de métodos computacionais de inteligência artificial para classificação automática dos padrões de arritmias (LUZ et al., 2016). Atualmente, métodos baseados em aprendizagem de máquina, do inglês *Machine Learning* (ML), como as Redes Neurais Artificiais, do inglês *Artificial Neural Networks* (ANN) (ZAORÁLEK; PLATOŠ; SNÁŠEL, 2018) e as Redes Neurais Artificiais Profundas, do inglês *Deep Neural Networks*

(DNN) (HANNUN et al., 2019), tornaram-se bastante populares. Porém, ainda há espaço para melhorias, especialmente quando se considera uma avaliação mais justa e rigorosa, envolvendo o paradigma *inter-patient* (conjunto de treinamento e teste sem sobreposição de dados do mesmo paciente) (ANSI/AAMI, 2008; CHAZAL; O'DWYER; REILLY, 2004; LUZ et al., 2016).

Manter a conformidade com todas as normas e boas práticas é ainda um grande obstáculo para a introdução de novas técnicas na indústria. Chazal, O'Dwyer e Reilly (2004) discutem alguns requisitos para uma justa comparação entre trabalhos publicados e apontam que aqueles que não cumprem tais requisitos não apresentam grande valor prático, inclusive apresentando resultados enviesados (LUZ et al., 2016). Luz e Menotti (2011) realizaram experimentos considerando os paradigmas *intra-patient* (conjunto de treinamento e teste com sobreposição de dados de paciente) e *inter-patient* (conjuntos de treinamento e teste sem sobreposição), e observaram que os métodos que utilizam o paradigma *inter-patient* apresentam considerável redução na acurácia geral, em especial na precisão e sensibilidade das classes minoritárias (arrítmicas).

Para que soluções propostas possam ser utilizadas em equipamentos médicos, como monitores de sinais vitais, e uma normatização do processo de classificação de arritmias seja estabelecida, o projeto e a análise de experimentos devem obedecer a norma ANSI/AAMI EC57:1998/(R)2008 desenvolvida pela Associação para o Avanço da Instrumentação Médica - *Association for the Advancement of Medical Instrumentation* (AAMI) (ANSI/AAMI, 2008) que define boas condutas de avaliação e Chazal, O'Dwyer e Reilly (2004) que define um protocolo de avaliação para garantir que os experimentos sejam reprodutíveis e comparáveis.

Esta dissertação propôs investigar a aplicação de mapeamento de sinais de ECG em forma de grafos, em conjunto com a classificação através de redes neurais de grafos. A análise revelou que dentre os métodos avaliados para conversão de séries temporais em grafo, o método VG demonstrou maior eficiência em comparação com o método VVG nas arquiteturas de redes neurais de grafos exploradas. Isso é particularmente evidente quando se considera o uso de duas derivações simultâneas dos sinais de ECG, onde o método VVG apresentou complexidade computacional significativamente alta em termos de espaço e tempo. Adicionalmente, percebeu-se que a incorporação de informações agregadas nos grafos tem o potencial de aprimorar o desempenho das redes neurais de grafos analisadas, desde que essas informações sejam capazes de capturar de maneira mais precisa as características presentes na morfologia dos sinais de ECG.

1.1 Questões de pesquisa

O sinal ECG é comumente modelado como uma dimensão (série temporal), e uma ampla gama de métodos se concentra em técnicas de extração de características para sinais unidimensionais, utilizando classificadores como SVM, redes neurais artificiais e *Long Short Term Memory* (LSTM) (ALI; KAREEM; MOHAMMED, 2022; ÇINAR; TUNCER, 2021; VENKATESAN et al., 2018).

Recentemente, as técnicas de aprendizado profundo baseadas em redes de convolução têm sido empregadas para este problema, ainda tratando o sinal em uma dimensão (HANNUN et al., 2019), e alcançando resultados notáveis, superando até mesmo o desempenho humano. Aqui, uma hipótese foi proposta para a utilização de redes de grafos, em particular, para representar simultaneamente mais de uma derivação do sinal, levando em consideração aspectos ou relações da morfologia dos sinais de ECG.

Dessa forma, esta dissertação busca investigar a representação de um sinal de ECG em grafo, pautada pela hipótese de que através dessa nova representação, mais informações podem ser obtidas, aumentando a caracterização dos batimentos de ECG e a performance dos modelos de classificação. A investigação basea-se nas regras da AAMI juntamente com o protocolo *inter-patient*. Com isso, as seguintes questões de pesquisa foram levantadas:

- A técnica *Visibility Graph* (VG) é uma boa alternativa para mapeamento de séries temporais em grafos, podendo vir a auxiliar a representação do sinal de ECG em grafos nas redes de grafos?
- O emprego de mais de uma derivação do sinal (dois sinais ao mesmo tempo), como representação em grafo, poderia melhorar o desempenho de classificação das redes neurais de grafos?

1.2 Objetivos

Esta dissertação de Mestrado pode ser dividida em duas categorias de objetivos: primário e secundário. Temos como objetivos primários: i) classificar automaticamente arritmias em sinas de ECG por meio de um método baseado em Redes Neurais de Grafos; ii) investigar o mapeamento (conversão) de um batimento cardíaco em um grafo explorando a conversão dos sinais de ECG com uma e duas derivações. Por fim, tem-se o objetivo secundário como a avaliação do desempenho do método proposto diante de experimentos que analisam a performance em diversos cenários conforme a norma da AAMI e protocolo proposto em Chazal, O'Dwyer e Reilly (2004) no uso do paradigma *inter-patient*.

1.3 Principais Contribuições

Dois artigos foram apresentados no XXII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS) 2022¹², um dos principais fóruns de divulgação científica e de encontro de pesquisadores das áreas de computação e saúde no Brasil. O primeiro artigo intitulado *Explorando Redes Neurais de Grafos para Classificação de Arritmias* apresenta resultados iniciais da proposta do método de classificação de arritmias em sinais de ECG utilizando Redes Neurais de Grafos (OLIVEIRA et al., 2022b) e o segundo intitulado *Um Método Ensemble para Classificação de Arritmias: Uma Avaliação Em Mais de 10 Mil Registros de Sinais de ECG* apresenta a proposta de um método *ensemble* baseado em votação em um conjunto de dados com mais de 10 mil pacientes (OLIVEIRA et al., 2022a).

Além das publicações, disponibilizamos no github³ a implementação de um método eficiente e otimizado de conversão de séries temporais em grafos, o *Vector Visibility Graph* (VVG), representando uma significativa contribuição para a análise e compreensão de dados temporais. Ao otimizar o processo de mapeamento, que anteriormente demandava excessivo tempo e recursos, essa abordagem possibilita a transformação rápida e eficaz de séries temporais em estruturas de grafos, permitindo assim a exploração de dados temporais.

1.4 Organização

O restante desta dissertação é organizado da seguinte maneira: o Capítulo 2 apresenta a fundamentação teórica para compreensão do método proposto e os trabalhos relacionados; o Capítulo 3 descreve a metodologia proposta; a descrição dos resultados experimentais é apresentada no Capítulo 4; e por fim o Capítulo 5 apresenta as considerações finais e trabalhos futuros.

¹<https://sbcas2022.enucompi.com.br/>

²<https://sol.sbc.org.br/index.php/sbcas>

³github.com/raffoliveira

2 Fundamentação Teórica

Este capítulo descreve e discute tópicos relacionados aos métodos explorados nesta dissertação. Esses tópicos são descritos para familiarizar o leitor da dissertação com os principais conceitos relacionados para que o entendimento de vários termos possa ocorrer.

A Seção 2.1 apresenta os trabalhos relacionados à classificação de arritmias em sinais de ECG, bem como a descrição das etapas principais que compõem um sistema automático de arritmias. As etapas de pré-processamento e segmentação são descritas brevemente, uma vez que não são o foco dessa dissertação. A Seção 2.2 descreve os principais conceitos relacionados a redes complexas e grafos bem como as técnicas de conversão dos batimentos cardíacos em grafos. E por fim, a Seção 2.3 descreve os conceitos e tipos relacionados às GNNs.

2.1 Trabalhos Relacionados

Um único ciclo normal do sinal de ECG representa a sucessiva despolarização/repolarização atrial e ventricular que ocorre a cada batimento cardíaco (MCSHARRY et al., 2003). Essa atividade cardíaca inicia-se no nodo sinusal atrial e se propaga pelo resto do coração, resultando em correntes elétricas na superfície do corpo e provocando variações no potencial elétrico da superfície da pele. Esses sinais podem ser medidos por meio de eletrodos na superfície do corpo do paciente e então representados graficamente no registro de ECG (YANG; WEI, 2020).

A diferença de potencial elétrico entre os pontos marcados pelos eletrodos na pele, geralmente é potencializada com o auxílio de um amplificador de instrumentação com isolamento óptica, que tem a função de diminuir a interferência com outros campos elétricos e magnéticos. Em seguida, o sinal é submetido a um filtro banda passa-alta; a um segundo amplificador, a um filtro *antialiasing* passa-baixa e, por último, a um conversor analógico para digital (LUZ et al., 2016). A Figura 1 ilustra o esquema simplificado do processo de aquisição do sinal de ECG.

Utiliza-se três ou mais eletrodos para obtenção do sinal, sendo que um deles serve de referência para os demais. Normalmente, o eletrodo de referência é colocado próximo à perna direita. Deste modo, podem haver diferentes pontos de vista do sinal de ECG, a depender do par de eletrodos escolhido para construção do sinal. Esses diferentes pontos de vista recebem o nome de derivações (do inglês *leads*) (COHEN, 1986).

Uma configuração de eletrodos muito utilizada é composta por 5 eletrodos: um eletrodo no braço esquerdo, um no braço direito, um na perna esquerda, um na perna

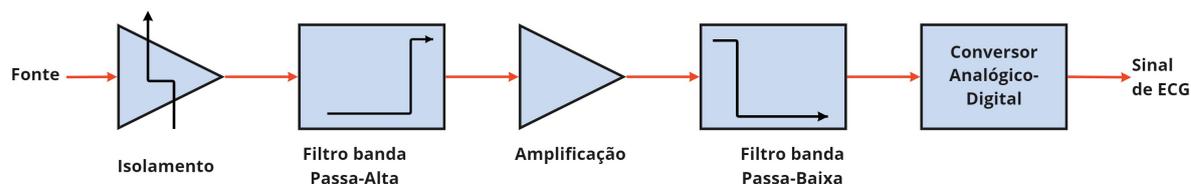


Figura 1 – Esquema simplificado dos principais componentes de um *hardware* para captura de sinais de ECG.

Fonte: Adaptada de Clifford et al. (2006).

direita e um no peito. Outra configuração muito aplicada é composta por 10 eletrodos (ver Figura 2), onde 6 eletrodos complementares (V1 a V6) são posicionados no tórax permitindo a formação de 12 derivações.

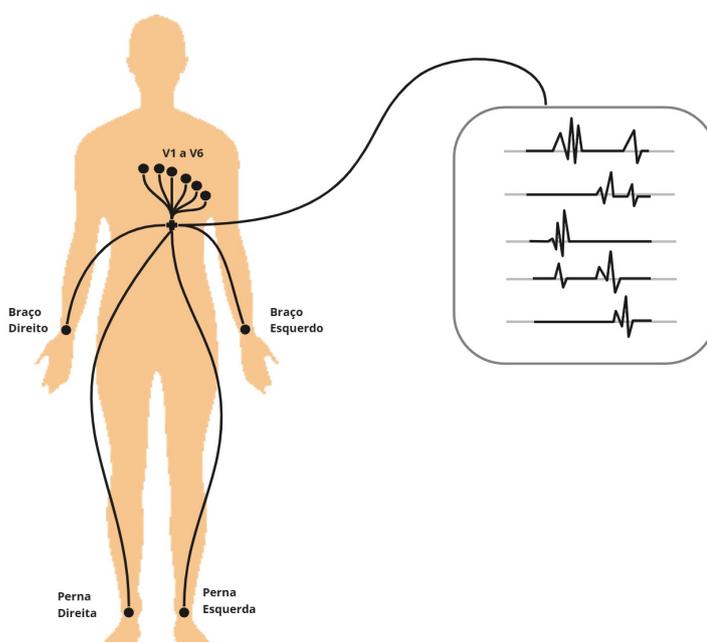


Figura 2 – Configuração de 10 eletrodos frequentemente utilizada na realização de eletrocardiograma.

Dentre as derivações, a derivação II (braço direito e perna esquerda) é a mais utilizada na detecção de doenças cardíacas, uma vez que ela evidencia vários segmentos dentro do batimento cardíaco, além de apresentar as três ondas mais importantes (pontos fiduciais), ondas P, QRS e T (LUZ et al., 2016), como ilustrado na Figura 4. Dentre os principais pontos apresentados, o segmento QRS é normalmente utilizado durante o processo de segmentação de um sinal de ECG.

A partir da obtenção dos sinais de ECG, pode-se construir um sistema de classificação automática (ver Figura 3), que pode ser dividido em quatro principais etapas: (1) pré-processamento, (2) segmentação, (3) extração de atributos e (4) classificação (LUZ et

al., 2016).

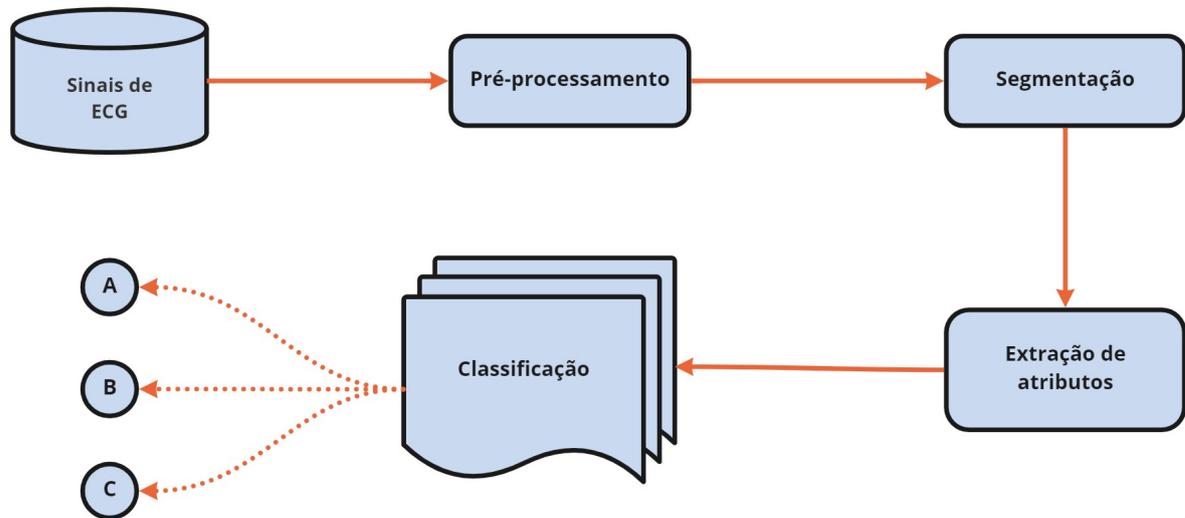


Figura 3 – Diagrama de um sistema de classificação de arritmias automática.

2.1.1 Pré-processamento

Na etapa de pré-processamento ocorre a remoção de ruídos do sinal de ECG. Os registros de sinais de ECG obtidos pela disposição de eletrodos no corpo do paciente, conforme a Figura 2, são inevitavelmente afetados por vários tipos diferentes de ruídos, uma vez que são sinais essencialmente fracos e não estacionários (sinais cujas componentes de frequência diferem ao longo do tempo (BERKAYA et al., 2018)). Dentre os ruídos existentes, têm-se como exemplos: o desvio da linha de base, interferência na linha de energia, sinais fisiológicos gerados por outros órgãos do corpo do paciente ou induzidos por contrações musculares relacionadas à respiração e ruídos aleatórios de alta frequência (WU et al., 2009). Portanto, o objetivo é distinguir o sinal de ECG válido dos ruídos indesejados de modo a apresentar um sinal que permita uma fácil interpretação visual (BLANCO-VELASCO; WENG; BARNER, 2008).

A eliminação dos ruídos dos sinais de ECG é uma tarefa desafiadora devido à sobreposição espectral de sinais e ruído, e uma ampla diversidade de métodos de tratamento de ruídos tem sido proposta na literatura (JIN et al., 2019). Dentre as propostas para a remoção de ruídos em sinais de ECG, as mais utilizadas são filtros adaptativos, filtros lineares, modo de decomposição empírica e transformada *Wavelet*, do inglês *Wavelet Transform* (WT). Ainda, segundo Luz et al. (2016), o uso excessivo de filtros, como por exemplo, filtros passa-altas e passa-baixas, pode distorcer a morfologia do sinal, tornando-o inutilizado para o diagnóstico de arritmias.

Os filtros utilizados para o propósito de remoção de ruídos podem ser fixos ou adaptativos. Filtros fixos são construídos baseados no conhecimento prévio tanto do sinal

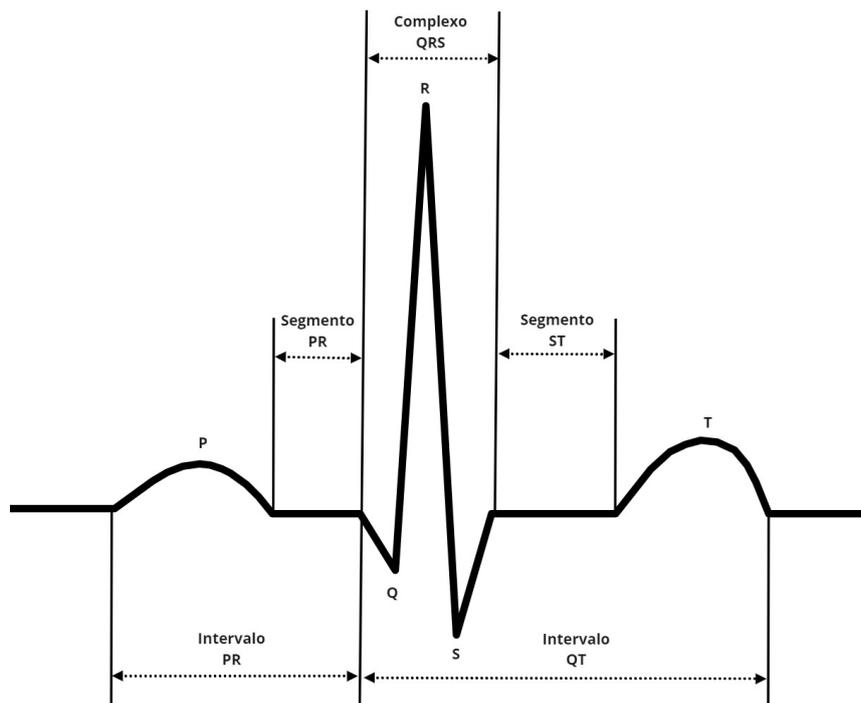


Figura 4 – Pontos fiduciais (onda P, onda do complexo QRS e onda T) e intervalos usuais de um batimento de sinal de ECG.

Fonte: Adaptada de Zheng et al. (2020).

quanto do ruído. Os filtros adaptativos, em contrapartida, têm a capacidade de ajustar seus próprios parâmetros automaticamente, não dependendo do conhecimento prévio dos atributos do sinal ou ruído.

Widrow et al. (1975) descrevem os principais conceitos de eliminação de ruídos em sinais de ECG por meio de filtros adaptativos. Anos mais tarde, Xue, Hu e Tompkins (1992) desenvolveram um filtro adaptativo baseado em redes neurais artificiais para uma melhor detecção do complexo QRS, apresentando um ganho de desempenho quando comparado com filtros adaptativos lineares.

Os métodos baseados em filtros lineares (SAYADI; SHAMSOLLAHI, 2008) possuem baixa complexidade computacional e velocidade de cálculo rápida e, portanto, têm sido amplamente utilizados em instrumentos de monitoramento embarcados ou portáteis (JIN et al., 2019). No entanto, os filtros lineares não conseguiram reduzir os componentes de ruído que se sobrepõem ao espectro do sinal de ECG. Para superar esse problema, métodos não lineares têm sido investigados (JAIN; BAJAJ; KUMAR, 2017). Já os métodos baseados em WT são simples do ponto de vista computacional e preservam o sinal evitando perda de informações importantes, a depender da função geradora *Wavelet* utilizada (SINGH; TIWARI, 2006). Em Wang et al. (2018), os autores propuseram um método de seleção *wavelet* com limiar adaptativo para redução de ruído em ECG baseado em funções *wavelet*. O limiar foi ajustado dinamicamente utilizando heurística e o número de camadas da

decomposição da função *wavelet*.

Outros métodos apresentaram resultados interessantes, como em Sameni et al. (2007), em que os autores propuseram o uso de filtros Bayesianos não lineares para a redução de ruídos em sinais de ECG. Uma metodologia utilizando a combinação de modo de decomposição empírica, do inglês *Empirical Mode Decomposition* (EMD) e filtro de média de comutação adaptável foi proposta por Rakshit e Das (2018), apresentando resultados significativos quando comparada com outras técnicas. Apesar da maioria das aplicações de ANN estar concentrada no reconhecimento de padrões e classificação de sinais de ECG, como em Rajpurkar et al. (2017) e Hannun et al. (2019), Pongpon Sri e Yu (2013) propuseram um filtro adaptativo baseado na combinação de WT e ANNs, permitindo que o limiar (do inglês *threshold*) de redução de ruídos utilizado na WT fosse calculado de forma adaptativa por meio do autoaprendizado da ANN.

2.1.2 Segmentação

Após o pré-processamento dos sinais de ECG, realiza-se a segmentação em batimentos delimitando a parte de maior interesse, o pico R ou o complexo QRS. Os atributos baseados no complexo QRS são os mais importantes para análise de sinais de ECG, dado que refletem a atividade elétrica no coração durante a contração ventricular (BERKAYA et al., 2018). A partir desta etapa de segmentação, diversas informações fisiológicas podem ser obtidas por meio de técnicas de extração de atributos, como por exemplo, frequência cardíaca, largura da onda R, amplitude, área do complexo QRS, *etc.*, que podem servir de base para uma classificação automática de arritmias.

Neste processo de segmentação, utiliza-se a localização do pico R a partir da detecção da onda por algum método ou a partir das anotações presentes no conjunto de dados utilizado, segmentando o sinal de ECG em batimentos e extraíndo-se n pontos antes e n pontos depois do pico R, conforme a Figura 5. Posteriormente, realiza-se o registro do tipo de batimento de acordo com as anotações do conjunto de dados. No final, cada batimento obtém um tamanho fixo de N pontos, sendo $N = n_{\text{antes}} + n_{\text{após}}$.

Na literatura, a quantidade de pontos ideal por batimento utilizada nos trabalhos não é um consenso. Por exemplo, Ye, Kumar e Coimbra (2012) utilizaram um janela fixa de 300 pontos (100 pontos antes da onda R e 200 pontos depois da onda R), enquanto Mondéjar-Guerra et al. (2019) e Ghongade et al. (2007) segmentaram utilizando uma janela fixa de 180 pontos centralizada na onda R. Além disso, baseados em suas experiências e estudos, Zaořálek, Platoř e Snářel (2018) utilizaram 70 pontos antes e 20 pontos depois da onda R no conjunto de dados do MIT-BIH enquanto que Peimankar e Puthusserypady (2021) segmentaram os sinais de ECG em partes de 1000 pontos equivalente a aproximadamente cinco batimentos, ou seja, cada batimento continha 200 pontos. Shoughi e Dowlatshahi (2021), após normalização dos sinais de ECG, utilizaram 280 pontos na

etapa de segmentação. Por fim, Mousavi e Afghah (2019) utilizaram uma janela fixa de 280 pontos obtendo resultados consideráveis na literatura, sendo o estado da arte nesta dissertação.

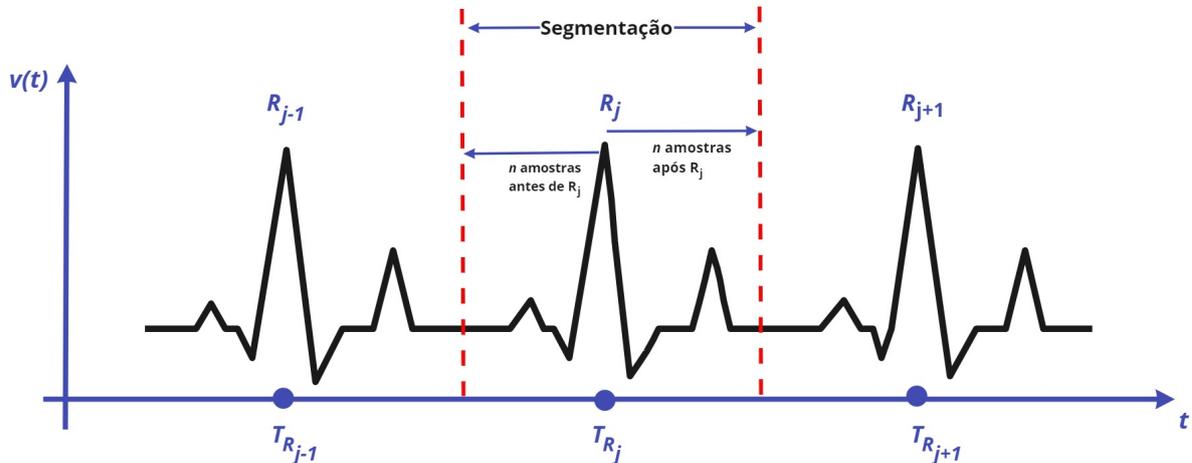


Figura 5 – Processo de segmentação de um sinal de ECG em batimentos a partir da detecção do pico R.

Fonte: Adaptada de Wang et al. (2021).

Com o avanço do poder de processamento dos computadores, os autores passaram a focar menos no tempo de processamento e mais na precisão da segmentação de batimentos. Para que uma comparação justa entre os métodos de segmentação propostos na literatura possa ser realizada, é necessário um banco de dados padrão (LUZ et al., 2016). O mais utilizado e recomendado pela AAMI para validação de equipamentos médicos (ANSI/AAMI, 2008) é o conjunto de dados MIT-BIH (MOODY; MARK, 1990; MOODY; MARK, 2001), embora outros conjuntos de dados sejam utilizados, como o conjunto de dados AHA (HERMES; GESELOWITZ; OLIVER, 1980) e CSE (BEMMEL; WILLEMS, 1990). Entretanto, segundo Kohler, Hennig e Orglmeister (2002), ainda é difícil uma comparação justa entre os métodos pois muitos deles não utilizam o banco de dados padrão.

Diversas abordagens têm sido propostas na literatura, como por exemplo, as abordagens baseadas em WT (ZIDELMAL et al., 2012), ANNs (ABIBULLAEV; SEO, 2011), filtros digitais e limiares de detecção adaptativos (PAN; TOMPKINS, 1985), algoritmos genéticos (POLI; CAGNONI; VALLI, 1995), modelos de Markov (HUGHES; TARASSENKO; ROBERTS, 2003), regressão linear (ASPURU et al., 2019), DNNs (MOSKALENKO; ZOLOTYKH; OSIPOV, 2019; CAI; HU, 2020), dentre outros. Ainda, Beraza e Romero (2017) propuseram um comparativo entre nove algoritmos de segmentação da literatura, a fim de avaliar suas performances. Os autores utilizaram o conjunto de dados *PhysioNet's QT* (LAGUNA et al., 1997) e desconsideraram a detecção do segmento QRS na avaliação. Algoritmos baseados em WT e métodos probabilísticos (modelos de Markov) apresentaram os melhores resultados.

Segundo Luz et al. (2016), a maioria das publicações utilizam banco de dados que fornecem previamente os rótulos dos pontos importantes do batimento, isto é, do complexo QRS, reduzindo a etapa de segmentação a uma simples busca. Porém, é importante ressaltar que a etapa de segmentação apresenta grande importância no processo de classificação de arritmias, podendo ter seus erros propagados ao longo de processo e representar um impacto direto em aplicações reais.

2.1.3 Extração de atributos

Como o ECG é uma representação da atividade elétrica do coração, uma representação apropriada do sinal de ECG desempenha um papel importante no processo de classificação de arritmias. Os atributos podem ser extraídos de diversas formas diretamente da morfologia do sinal de ECG no domínio do tempo e/ou no domínio da frequência ou do ritmo cardíaco (LUZ et al., 2016). Várias técnicas de extração de atributos têm sido propostas para mostrar as informações distintas dos sinais de ECG para diferentes propósitos, como análise e classificação. Segundo Berkaya et al. (2018), os atributos podem ser categorizados em cinco grupos: P-QRS-T, estatísticos, morfológicos, *wavelet* e outros atributos.

Ainda, segundo Luz et al. (2016), dois processos, extração de atributos e seleção de atributos, são comumente considerados semelhantes por alguns trabalhos, porém são diferentes. Enquanto a extração de atributos é a etapa responsável pela descrição do batimento, a seleção de atributos consiste na escolha de um subconjunto com os atributos mais representativos do batimento com o objetivo de melhorar a etapa de classificação.

2.1.3.1 Atributos P-QRS-T

Os atributos P-QRS-T basicamente correspondem às localizações, durações, amplitudes e formas das principais ondas do sinal de ECG. Normalmente, o sinal de ECG apresenta cinco ondas principais, as ondas P, Q, R, S e T. Além disto, certos intervalos do sinal de ECG trazem informações importantes e podem ser utilizadas como atributos, como os intervalos PP, PR, RR, ST e PT, como apresentado na Figura 4.

A onda P é uma pequena deflexão de baixa voltagem da linha de base do sinal de ECG, que é causada pela despolarização dos átrios antes da contração atrial. A onda Q é uma deflexão para baixo após a onda P. A onda R segue como uma deflexão para cima e a onda S como uma deflexão para baixo após a onda R. Por último, a onda T, após a onda S, é a repolarização atrial ventricular, pela qual o músculo cardíaco é preparado para o próximo ciclo do sinal de ECG (BERKAYA et al., 2018). As ondas Q, R e S juntas formam o complexo QRS, sendo o atributo mais importante e utilizado na literatura (YANG; WEI, 2020) juntamente com o intervalo RR (LUZ et al., 2016).

Yang e Wei (2020) combinaram atributos paramétricos da morfologia do sinal de ECG (amplitude, intervalo e duração) e padrão morfológico visual do complexo QRS para treinar três classificadores (ANN, *Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN)), obtendo resultados significativos quando comparado com outros trabalhos relacionados. Sob outra perspectiva, Dias et al. (2021) testaram um classificador discriminante linear com um grupo diferente de atributos composto por intervalos RR, valores morfológicos e valores estatísticos de alta ordem. Adicionalmente, os autores adicionaram um tremor (do inglês *jitter*) na posição da onda R a fim de mensurar a robustez do sistema proposto contra os erros de segmentação.

Segundo Berkaya et al. (2018), outros intervalos pertencentes ao sinal de ECG trazem informações significativas e também são utilizados como atributos, como por exemplo, o intervalo PR (NIELSEN et al., 2013), o intervalo QT (VALENTIN, 2010), o intervalo ST (TANG; HU; TANG, 2018) e o intervalo RR (RAJ; RAY, 2017). O intervalo RR pode variar de acordo com atributos dinâmicos do sinal de ECG e o intervalo do batimento. Na literatura, são amplamente utilizados dois intervalos (LUZ et al., 2016): o intervalo RR predecessor, que indica a distância entre o batimento atual e o batimento anterior, e intervalo RR sucessor, que indica a distância entre o batimento atual e o batimento posterior.

2.1.3.2 Atributos Estatísticos

Atributos estatísticos têm sido aplicados em sistemas de classificação de arritmias e são calculados utilizando valores do domínio do tempo dos sinais de ECG. Energia, entropia, média, desvio padrão, máximo, mínimo, curtose (*kurtosis*), variância e assimetria (*skewness*) são alguns exemplos desses atributos estatísticos. Esses atributos fornecem um meio para analisar o nível de complexidade, o tipo de distribuição, linearidade e não linearidade dos sinais de ECG, permitindo um melhor desempenho de classificação (BERKAYA et al., 2018).

O método proposto para classificação de arritmias em sinais de ECG por Yu e Chen (2009) aprimorou a sensibilidade do método para a maioria dos batimentos utilizando atributos estatísticos de alta ordem combinados com atributos relacionados ao intervalo RR, sendo ainda, um método tolerante a ambientes com ruídos. Outro modelo foi proposto por Pandey, Janghel e Vani (2020) baseado no conjunto de atributos referente aos intervalos RR, coeficientes *Wavelet*, estatísticos de alta ordem e morfológicos. Uma acurácia geral de 94,4% foi obtida por meio de um classificador *ensemble* de SVMs.

2.1.3.3 Atributos Morfológicos

Em relação aos atributos dos sinais de ECG empregados na classificação de arritmias, os intervalos RR, os atributos relacionados ao domínio do tempo, incluindo o intervalo

PP, duração da onda P, duração do complexo QRS, intervalo PR, duração da onda T e intervalo QT são os mais utilizados na literatura (ZHANG et al., 2014).

Além dos atributos mencionados anteriormente, outros atributos têm sido propostos. Zhang et al. (2014) utilizaram um conjunto de 46 atributos em um classificador SVM. Dentre o conjunto de atributos, os autores extraíram atributos relacionados à morfologia da amplitude e das áreas negativas e positivas da onda P, do complexo QRS, do intervalo ST e da onda T. Além disso, consideraram a distância morfológica proposta por Wiens e Guttag (2010), atributo capaz de medir a semelhança entre batimentos cardíacos. Essa distância baseia-se na distância de distorção de tempo dinâmico (DTW), do inglês *Dynamic time warping* (DTW), entre um determinado batimento e o batimento mediano de um eletrocardiograma.

Diversos trabalhos propuseram outras abordagens, como exemplo em Dias et al. (2021), onde os autores utilizaram o mínimo, o máximo, a variância e a raiz média quadrada dos valores de um segmento s de 256 pontos como atributos morfológicos. Segundo os autores, as arritmias podem mudar a morfologia do sinal de ECG. Além disso, Chen et al. (2017) escolheram uma matriz aleatória na qual cada coluna é normalizada e cada linha é transformada pela transformada discreta de cosseno, do inglês *discrete cosine transform* (DCT), como matriz de projeção para extrair atributos morfológicos dos batimentos cardíacos.

2.1.3.4 Atributos Wavelet

Atributos baseados em frequência são um dos mais populares utilizados para representar sinais de ECG (BERKAYA et al., 2018). De acordo com Luz et al. (2016), alguns pesquisadores argumentam que métodos baseados em WT apresentam alto desempenho em extração de atributos de sinais de ECG (KUTLU; KUNTALP, 2012; LIN; DU; CHEN, 2008).

Pelo fato dos sinais de ECG serem sinais não estacionários, essa propriedade torna a WT tão eficaz para extração de atributos baseados em frequência, uma vez que apresenta a propriedade de localização tempo-frequência (WANG et al., 2021).

A WT é uma transformação linear que decompõe um sinal de ECG em componentes em diferentes escalas (DAAMOUCHE et al., 2012). A localização temporal dos componentes espectrais pode ser obtida por uma análise *Wavelet*, a partir da representação tempo-frequência do sinal (BERKAYA et al., 2018). WT utilizam *wavelets* (versões dimensionadas e deslocadas de uma função *wavelet* mãe, do inglês *mother wavelet*) para decompor o sinal de ECG e representar a informação local no domínio do tempo e da frequência por meio de operações de escalonamento e deslocamento. Os ajustes das sub-bandas de alta e baixa frequência são realizados separadamente por meio do espaço do tempo e da frequência (MALLAT, 1999).

Ainda, a WT pode ser contínua (a decomposição é realizada por operações contínuas) denominada de transformada *wavelet* contínua, do inglês *Continuous Wavelet Transform* (CWT) e discreta (a decomposição é realizada por operações discretas) denominada de transformada *wavelet* discreta, do inglês *Discrete Wavelet Transform* (DWT).

De acordo com Wang et al. (2021), a escolha da função *Wavelet* mãe para extração de atributos é crucial para o desempenho do modelo de classificação. A escolha deve ser cuidadosamente analisada, a fim de não perder informações importantes do sinal de ECG.

Na literatura, diversos trabalhos têm utilizado atributos baseados em WT (SHARMA et al., 2019; LI et al., 2017). Outras abordagens têm sido propostas, tais como atributos baseados em CWT (WANG et al., 2021; BANERJEE; MITRA, 2013), *Dual Tree Complex Wavelet Transform* (DTCWT) (THOMAS; DAS; ARI, 2015), *Tunable-Q Wavelet Transform* (TQWT) (HASSAN; HAQUE, 2017; JHA; KOLEKAR, 2021), *Flexible Analytic Wavelet Transform* (FAWT) (KUMAR; PACHORI; ACHARYA, 2017) e *dyadic discrete WT* (DWT) (PADHY; DANDAPAT, 2017). Ainda, atributos estatísticos dos coeficientes da WT são propostos, como média, desvio padrão, energia (GÜLER; ÜBEYLI, 2005) e variância (YU; CHEN, 2007). Para Luz et al. (2016), estes atributos possuem grande vantagem, pois são imunes às variações da marcação dos pontos fiduciais.

2.1.3.5 Atributos baseados em grafos

Atributos baseados em grafos para redes neurais artificiais têm se mostrado uma abordagem promissora para lidar com problemas complexos de modelagem e análise de dados (LI et al., 2012). Esses atributos podem ser informações topológicas, como conectividade e proximidade, ou características específicas de cada vértice, como atributos numéricos, textuais ou categóricos (BACKES; CASANOVA; BRUNO, 2009). A utilização de atributos baseados em grafos permite que as redes neurais aprendam padrões globais e locais, facilitando a modelagem de problemas que envolvem estruturas não lineares e dependências contextuais (WU et al., 2020).

Baseado na possibilidade de utilizar a modelagem de grafos juntamente com redes neurais convolucionais de grafos, três trabalhos da literatura foram referências nesta dissertação. Estes trabalhos propuseram o uso de redes complexas para extração de informações a partir da conversão de novas representações dos sinais de ECG em grafos e utilizá-los em modelos de ML, como o SVM.

Queiroz et al. (2015) propuseram um novo método de detecção e classificação de arritmias utilizando a representação vetorcardiograma (VCG) dos sinais de ECG e redes complexas. Os autores exploraram a possibilidade de utilizar o VCG gerado pelas derivações do eletrocardiograma (ECG) para extrair informações relevantes dos batimentos cardíacos no banco de dados MIT-BIH. A metodologia proposta baseou-se na representação VCG de cada batimento cardíaco, empregando duas derivações dos sinais de ECG (MLII

e V1). Os autores empregaram a teoria de redes complexas para transformar o VCG em estruturas de grafo e, em seguida, extraíram características dessas estruturas. O método foi avaliado no conjunto de dados do MIT-BIH seguindo o padrão ANSI/AAMI EC 57:1998 e o protocolo *inter-patient* para classificar os batimentos em 5 classes (N, V, S, F e Q). O modelo Support Vector Machine (SVM) utilizado obteve uma acurácia global de 84,1%.

No trabalho de Garcia et al. (2016), os autores propuseram um método que utiliza uma representação tridimensional do ECG chamada vetorcardiograma temporal (VCG), uma variação da representação VCG acrescida da informação do tempo. Teoria de redes complexas foram empregadas na construção de estruturas de grafos a partir do VCG temporal e características foram extraídas através da análise do grau de conectividade de cada vértice do grafo gerado. Essas características foram utilizadas como entrada para um classificador SVM. Os resultados obtidos com o método proposto demonstraram melhorias significativas na classificação das classes N e S em comparação com o método VCG. Vale destacar que a norma da AAMI e o protocolo *inter-patient* foram utilizados.

Por fim, Garcia et al. (2017) utilizaram a mesma metodologia proposta por Garcia et al. (2016). A diferença consistiu na utilização de um algoritmo de seleção de características denominado otimização de enxame de partículas (do inglês *Particle Swarm Optimization* - PSO). Para realizar a classificação, foi utilizado um classificador SVM. O método foi avaliado sob o paradigma *inter-patient* seguindo a norma AAMI. As características extraídas dos grafos gerados pela teoria de redes complexas incluíram o grau médio de conectividade (*mean connectivity degree*), o grau máximo de conectividade (*maximum connectivity degree*), o grau de entropia (*joint degree entropy*), o grau de energia (*joint degree energy*) e o grau médio da junção dos nós (*mean joint degree*). Além disso, foram extraídas características relacionadas ao intervalo de batimento cardíaco, como a duração do complexo QRS, a duração da onda T e a presença ou ausência da onda P. Os resultados obtidos com o método proposto foram comparáveis ao estado da arte, conforme demonstrado na avaliação utilizando o banco de dados MIT-BIH.

2.1.3.6 Outros atributos

Além dos atributos mencionados anteriormente, Berkaya et al. (2018) menciona outras técnicas particulares de extrações de atributos para sinais de ECG presentes na literatura, tais como expoentes de Lyapunov (ÜBEYLI, 2009), atributos baseados em densidade espectral de potência (ERGIN et al., 2014), atributos baseados em análise de autocorrelação (AGRAFIOTI; HATZINAKOS, 2009), atributos baseados em complexidade de Kolmogorov (SHARMA; RAY, 2016) e algoritmos genéticos (VAFAIE; ATAIEI; KOOFIGAR, 2014).

2.1.3.7 Seleção de atributos

Atributos em um espaço de alta dimensionalidade requerem atenção durante a análise de sinais de ECG, principalmente quando se leva em consideração alguns fatores importantes, como tempo computacional e precisão de classificação. Seleção de atributos é a técnica para determinar um subconjunto de atributos mais representativos para a construção de um modelo de ML mais robusto por meio de remoção de atributos irrelevantes e redundantes.

O objetivo da seleção de atributos apresenta três pontos principais: aumentar a performance de classificação, prover um processo de aprendizado mais rápido e efetivo e prover uma melhor compreensão do processo de geração dos dados do modelo (KANTARDZIC, 2011). Portanto, a incorporação da seleção de atributos pode aumentar a generalização dos modelos de classificação (KAYA; PEHLIVAN; TENKECI, 2017).

De acordo com Berkaya et al. (2018), os métodos de seleção de atributos podem ser divididos em três categorias principais: filtragem, *wrapper* e *embedded*. Os métodos de filtragem avaliam a relevância dos recursos utilizando vários esquemas de pontuação como uma etapa de pré-processamento independentemente do modelo de classificação (GUYON; ELISSEEFF, 2003). São métodos escaláveis e computacionalmente simples e rápidos.

Em outra perspectiva, os métodos *wrappers* utilizam o interesse do ML como uma caixa preta para pontuar subconjuntos de atributos de acordo com o poder de classificação de um modelo específico (GUYON; ELISSEEFF, 2003). Esses métodos consideram as dependências de atributos e fornecem uma interação entre o subconjunto de atributos e o modelo de aprendizado escolhido (BERKAYA et al., 2018). No entanto, esses métodos são computacionalmente mais lentos em comparação com os métodos de filtragem.

Por último, os métodos *embedded* realizam uma busca por um subconjunto de atributos otimizado durante o treinamento do modelo. Segundo Guyon e Elisseff (2003), a incorporação desta categoria de seleção de atributos na etapa de treinamento pode ser mais eficiente sob algumas perspectivas: fazer um melhor uso dos dados disponíveis por não precisar dividir os dados de treinamento em um conjunto de treinamento e validação; alcançar uma solução mais rapidamente e evitar o retreinamento de um classificador do zero para cada subconjunto de atributos analisado.

Além das categorias apresentadas, outras técnicas de seleção de atributos têm sido aplicadas na literatura para aumentar o poder de generalização dos modelos de classificação e reduzir o custo computacional. Dentre as propostas, destacam-se algoritmos genéticos (DIKER et al., 2019), *Particle Swarm Optimization* (PSO) (GARCIA et al., 2017), *Principal Component Analysis* (PCA) (WOSIAK, 2019), *Linear Discriminant Analysis* (LDA) (VARATHARAJAN; MANOGARAN; PRIYAN, 2018), clusterização *Fuzzy C-mean* (FCM) (GACEK, 2013), regressão espectral (KHUSHABA et al., 2010) e

Independent Component Analysis (ICA) (RAMKUMAR et al., 2021).

2.1.4 Classificação

Após a extração do conjunto de atributos do sinais de ECG, modelos podem ser construídos através desses atributos utilizando algoritmos de *Artificial Intelligence* (AI) da área de ML para classificação de arritmias. De acordo com estudos recentes (LUZ et al., 2016; BERKAYA et al., 2018; SAI et al., 2020; BHIRUD; PACHGHARE, 2020), SVM, ANN e DNN são os métodos mais populares na literatura para classificação de arritmias.

SVM (VAPNIK, 1999) é um método amplamente utilizado em problemas de classificação binária devido a sua excelente performance de generalização (BERKAYA et al., 2018). O SVM têm como objetivo encontrar uma margem máxima entre os dados de treinamento e o limite de decisão. Amostras de treinamento mais próximas do limite de decisão, denominadas de vetores de suporte - do inglês *support vectors*, são utilizadas para maximizar a margem. O SVM utiliza funções, denominadas funções *kernels*, para realizar o mapeamento tanto de dados lineares quanto de dados não lineares. Diversos trabalhos (ELHAJ et al., 2016; VENKATESAN et al., 2018; TOMAR; AGARWAL, 2015; HAMMAD et al., 2018; JHA; KOLEKAR, 2020; PANDEY; JANGHEL; VANI, 2020; RAJESH; DHULI, 2017) têm utilizado o modelo SVM como classificador de arritmias.

Pode-se pensar em ANN como sendo um modelo matemático que é inspirado na rede neural biológica, contendo neurônios artificiais interligados (BERKAYA et al., 2018). Por sua vez, estes neurônios podem ser vistos como processadores simples, massivamente paralelizados e organizados, que podem ser generalizados para melhor atender às necessidades de um problema em específico, formando-se diversas arquiteturas de redes. Resumidamente, ANN consiste em neurônios distribuídos em camadas (entrada, oculta e saída) que convertem um vetor de entrada em um vetor de saída (ver Figura 6) (BHIRUD; PACHGHARE, 2020).

Recentemente, diversos modelos de DNNs têm sido propostos para aprimorar a precisão em diversos contextos, tais como *Feed-Forward Neural Network* (FFNN), *Radial Basis Function Neural Network* (RBFNN), *Recurrent Neural Networks* (RNN), *Modular Neural Network* (MNN), *Kohonen Self-Organizing Neural Network* (KSONN) e *Convolutional Neural Networks* (CNN) (BHIRUD; PACHGHARE, 2020; DAS; ROY, 2019).

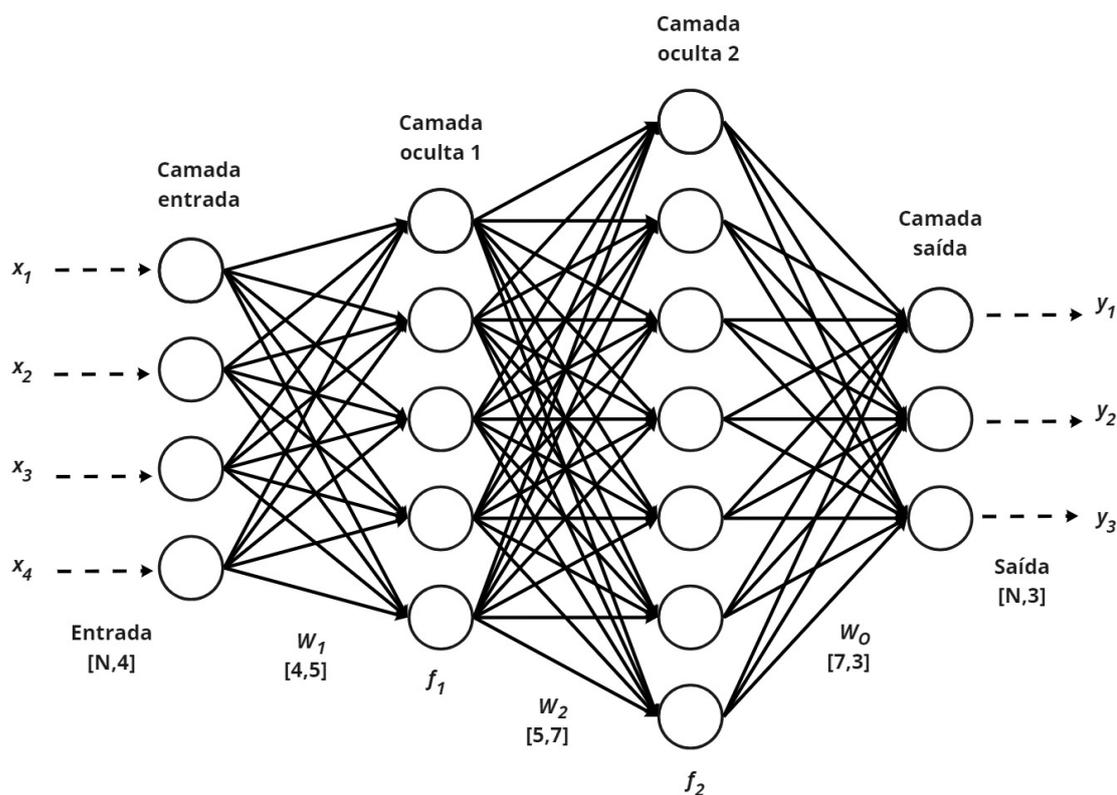


Figura 6 – Representação geral de uma rede neural artificial com vários neurônios.

Fonte: Adaptada de Mathur (2020)

As ANNs podem ser combinadas a fim de maximizar a eficiência da classificação. Há trabalhos que propuseram, por exemplo, uma rede híbrida neuro-fuzzy (ÖZBAY; CEYLAN; KARLIK, 2006) e redes neurais otimizadas evolutivas com *Particle Swarm Optimization* (PSO) (INCE; KIRANYAZ; GABBOUJ, 2009). Outras propostas têm sido apresentadas, como ANN e *Gradient Boosting* (ZAORÁLEK; PLATOŠ; SNÁŠEL, 2018), ANNs combinadas (GÜLER; ÜBEYLI, 2005) e ANN e LDA (WANG et al., 2011). Segundo Osowski, Markiewicz e Hoai (2008), combinações de classificadores não apenas reduz o erro geral das ANNs, mas também reduz a incidência de falsos negativos.

Por fim, tem-se *Deep Learning* (DL), uma extensão das ANNs. Estes métodos de aprendizado profundo baseiam-se nas redes neurais profundas ou DNN, redes neurais conectadas e compostas por várias camadas simulando as conexões do cérebro humano (DAS; ROY, 2019). DNN é um classificador não linear que “aprende” atributos complexos do conjunto de dados automaticamente, tornando-o muito atraente. O DL têm adquirido espaço na literatura devido à disponibilidade da computação baseada em GPU (*Graphical Processing Unit*). Possui uma ampla variedade de aplicações, como autenticação biométrica, detecção de objetos, classificação, compactação, classificação de imagens e outros campos

relacionados à visão computacional (WASIMUDDIN et al., 2020). Com isso, nota-se que métodos baseados em DL têm apresentado grande potencial em aplicações envolvendo classificação de arritmias, como por exemplo, no trabalho de Hannun et al. (2019), onde os autores relatam resultados melhores do que cardiologistas por meio de CNNs.

2.1.5 Trabalhos estado da arte

A literatura tem apresentado a emergência de uma série de estudos abordando metodologias no âmbito da classificação de arritmias em sinais de ECG. Nesse contexto, esta seção apresenta os trabalhos que apresentaram os melhores resultados nesse campo em constante progresso. Com isso, uma visão abrangente das tendências mais recentes será proporcionada, revelando como o uso de técnicas de ML tem redefinido os limites da detecção mais precisa em relação às arritmias.

A Tabela 1 resume alguns trabalhos entre os anos de 2018 e 2023 que utilizaram DL com o objetivo de aumentar a performance de métodos em classificação de arritmias. Os trabalhos foram selecionados considerando algumas regras, como o protocolo *inter-patient* proposto por Chazal, O'Dwyer e Reilly (2004) e as recomendações da AAMI, permitindo assim uma comparação justa entre os métodos propostos.

Observa-se que vários trabalhos propostos não se preocupam com a utilização das boas regras de construção e avaliação de modelos de classificação de arritmias ou as utilizam de forma incompleta. Com isso, ocorre uma inviabilização de comparação justa entre os métodos, podendo culminar em resultados enviesados no ponto de vista clínico em relação à performance dos modelos. Logo, métodos que se preocupam com a padronização no processo de construção e avaliação de modelos de classificação de arritmias são necessários para simulação de um cenário real.

Ao examinarmos os estudos detalhados na Tabela 1, torna-se evidente que o conjunto de dados MIT-BIH é predominantemente empregado, ressaltando assim sua relevância na literatura. Contudo, apesar dos resultados positivos apresentados, observa-se uma lacuna no emprego do paradigma *inter-paciente*, indicando que a simulação de cenário do mundo real ainda não se estabeleceu como uma prática de desenvolvimento. Tal observação enfatiza que os resultados obtidos podem estar suscetíveis às influências decorrentes da adoção desse paradigma.

A utilização de uma abordagem padronizada no desenvolvimento, como a AAMI, oferece a vantagem de possibilitar comparações significativas entre diferentes propostas, ao mesmo tempo em que viabiliza a replicabilidade dos resultados. Um exemplo disso pode ser observado no estudo conduzido por Hannun et al. (2019), no qual os autores demonstram que o modelo proposto alcançou uma sensibilidade na performance superior à de cardiologistas. No entanto, é importante notar que a avaliação dos resultados é

dificultada devido à falta de detalhes sobre a implementação bem como a utilização de um conjunto de dados público. A ausência dessas informações essenciais impede uma análise mais aprofundada, ressaltando que números elevados de métricas, por si só, não contribuem de maneira efetiva para o avanço das técnicas de aprendizado de máquina aplicadas à classificação de arritmias.

Por outro lado, estudos como os conduzidos por Essa e Xie (2021) e Mousavi e Afghah (2019) demonstraram um desempenho considerável ao aderir aos padrões da AAMI e ao paradigma *inter-patient*. Ambos projetos empregaram CNNs como modelos de ML, porém com abordagens distintas. Enquanto Essa e Xie (2021) propuseram uma arquitetura híbrida, combinando CNN-LSTM e LSTM, e utilizando segmentos de batimentos, Mousavi e Afghah (2019) propuseram uma estrutura de RNN, composta por um codificador e um decodificador, em conjunto com uma CNN, aplicando-a a sequências de batimentos cardíacos.

Analisando os trabalhos apresentados na Tabela 1, percebe-se que em sua maioria o conjunto de dados MIT-BIH é utilizado, mostrando sua importância dentro da literatura. Em contraponto aos bons resultados apresentados, nota-se que ainda o paradigma *inter-patient* não é amplamente utilizado, o que evidencia que a simulação do cenário do mundo real ainda não tornou-se uma prática de desenvolvimento, onde os resultados podem ser influenciados pelo uso do paradigma.

Com base na proposta desta dissertação, que visa avaliar a utilização de GNNs para a classificação de arritmias através do mapeamento de sinais de ECG em grafos, a Tabela 2 apresenta um resumo de alguns estudos relacionados na literatura que empregaram GNNs em diversas aplicações. É possível observar que a aplicação de GNNs tem se mostrado versátil, abrangendo contextos que incluem a previsão de doenças arteriais, classificação dos estágios do sono, detecção de COVID-19, entre outros. No entanto, ao analisar os trabalhos relacionados à classificação de arritmias, nota-se que a problemática mencionada anteriormente em estudos de DNNs (Tabela 1) também se repete nos estudos referentes à Tabela 2. Em outras palavras, os autores não têm demonstrado uma preocupação consistente na aplicação de boas práticas na construção e avaliação dos modelos propostos.

Portanto, esta dissertação desempenha um papel fundamental na elaboração de um modelo que combina as diretrizes da AAMI com o protocolo *inter-patient*. O objetivo é facilitar uma avaliação justa em comparação com outros modelos. Além disso, o estudo se concentra na investigação da representação de sinais de ECG em formato de grafo. A hipótese é que essa representação pode resultar em uma versão mais suavizada do sinal, permitindo a inclusão de dados adicionais nos vértices do grafo. A pesquisa também explora a viabilidade de criar grafos que abrangem mais de uma derivação, com a intenção de melhorar o desempenho na classificação.

Tabela 1 – Trabalhos estado da arte de DL para classificação de arritmias.

Referência	Conjunto de Dados	Atributos	# classes	Classificador	Performance (%)*	AAMI	Inter-patient
Cao et al. (2023)	MIT-BIH	Espectrograma 2D de tempo-frequência	4	ResNet18 pré-treinada	$Acc \Rightarrow 90, 8, Pr_N \Rightarrow 95, 3, Re_N \Rightarrow 95, 1$ $Pr_S \Rightarrow 13, 0, Res \Rightarrow 9, 0, Pr_V \Rightarrow 68, 2,$ $Re_V \Rightarrow 88, 4, Pr_F \Rightarrow 1, 3, Re_F \Rightarrow 0, 3$	\pm	\checkmark
Shobanaidevi e Veeramakali (2023)	MIT-BIH	-	5	CNN	$Acc \Rightarrow 99, 01, Pr \Rightarrow 99, 03$ $Re \Rightarrow 99, 01, F1 \Rightarrow 99, 02$	\pm	X
Li, Huang e Wu (2023)	MIT-BIH	ECG Imagens	5	Tagnchi-CNN	$Acc \Rightarrow 96, 79, Pr \Rightarrow 96, 12$ $Re \Rightarrow 93, 19, F1 \Rightarrow 94, 52$	\pm	X
Ozpolat e Karabataki (2023)	CUSPH	Qubit formado por 11 características	4	QSVM	$Acc \Rightarrow 84, 64, Se \Rightarrow 81, 13$ $Sp \Rightarrow 95, 0, F1 \Rightarrow 81, 15$	X	X
Choi et al. (2023)	GE Health-care Asan Medical Center	-	8	Inception-V3 CNN	$Acc \Rightarrow 96, 0, Pr \Rightarrow 96, 0$ $Re \Rightarrow 96, 0, F1 \Rightarrow 96, 0$	X	X
Madan et al. (2022)	MIT-BIH, BIDMC	Escalogramas 2D	3	CNN-LSTM	$Acc \Rightarrow 98, 9, Pr \Rightarrow 98, Se \Rightarrow 97,$ $Sp \Rightarrow 98, 7, Re \Rightarrow 98, F1 \Rightarrow 97, 4$	X	X
Bhatia et al. (2022)	MIT-BIH	-	5	CNN-BLSTM	$Pr \Rightarrow 89, 4, Re \Rightarrow 94, 24$ $F1 \Rightarrow 91, 67, Acc \Rightarrow 98, 36$	\pm	X
Gai (2022)	MIT-BIH	Imagens WVD (Wigner-Villee distribution)	5	ImageNet pre-treinada	$Pr \Rightarrow 98, 62, Re \Rightarrow 98, 65,$ $F1 \Rightarrow 98, 62, Acc \Rightarrow 98, 65$	\pm	\checkmark
Aseeri (2021)	MIT-BIH	-	5	Gated RNN	$Pr \Rightarrow 99, 39, Re \Rightarrow 99, 39$ $F1 \Rightarrow 99, 39, AUC \Rightarrow 99, 55$	\checkmark	X
Essa e Xia (2021)	MIT-BIH	Intervalo RR, HOS, Espaço-temporal	4	CNN-LSTM RR-HOS-LSTM	$Acc \Rightarrow 95, 81, Sp \Rightarrow 94, 56, Se \Rightarrow 69, 20,$ $F1 \Rightarrow 71, 06, +P \Rightarrow 74, 97, \kappa \Rightarrow 0, 79$	\checkmark	\checkmark
Sharma, Dinkar e Gupta (2021)	MIT-BIH	QRS, morfológicos	5	SVM-FBPNN	$Acc \Rightarrow 99, 15, Pr \Rightarrow 99, 78$ $Re \Rightarrow 99, 78, F1 \Rightarrow 99, 78$	X	X
Zhang et al. (2021)	MIT-BIH	-	5	CNN	$Acc \Rightarrow 99, 76, Se \Rightarrow 94, 45$ $Sp \Rightarrow 99, 54, +P \Rightarrow 97, 40$	\pm	\checkmark
Nurmaini et al. (2020)	MIT-BIH	-	5	Deep Autoencoder Learning	$Acc \Rightarrow 99, 34, Se \Rightarrow 93, 83, Sp \Rightarrow 99, 57,$ $Pr \Rightarrow 89, 81, F1 \Rightarrow 91, 44$	X	X
Plawiak e Acharya (2020)	MIT-BIH	densidade espectral de potência	17	Deep Genetic Ensemble of Classifiers (DGEC)	$Acc \Rightarrow 99, 37, Se \Rightarrow 94, 62$ $Sp \Rightarrow 99, 66$	\checkmark	X
Hannun et al. (2019)	Criado pelos autores	-	12	DNN	$AUC \Rightarrow 97, Sp \Rightarrow 75, 2$ $F1 \Rightarrow 83, 7$	X	\checkmark
Mousavi e Aghabab (2019)	MIT-BIH	-	4	Sequence-to-sequence CNN	$Acc \Rightarrow 99, 53, Se \Rightarrow 96, 18$ $+P \Rightarrow 97, 2, Sp \Rightarrow 98, 58$	\checkmark	\checkmark
(IZCI et al., 2019)	MIT-BIH	Imagens 2D	5	CNN	$Acc \Rightarrow 97, 4$	\checkmark	X
Sannino e Pietro (2018)	MIT-BIH	Intervalo RR	5	DNN	$Acc \Rightarrow 99, 09, Se \Rightarrow 98, 55$ $Sp \Rightarrow 99, 52$	\pm	\checkmark
Mathews, Kambhampati e Barner (2018)	MIT-BIH	intervalos RR, morfológicos, amplitude de segmentos, intervalos de batimentos	2	Restricted Boltzmann Machines (RBM) Deep Belief Network (DBN)	$Acc \Rightarrow 95, 2, Se \Rightarrow 80, 5$ $+P \Rightarrow 47, 97, FPR \Rightarrow 4, 65$	\checkmark	\checkmark

* $Acc \Rightarrow$ Acurácia \Rightarrow Acc , Sensibilidade \Rightarrow Se , Especificidade \Rightarrow Sp , Predição Positiva \Rightarrow $+P$, Taxa de Falso Positivo \Rightarrow FPR , Precisão \Rightarrow Pr , Recall \Rightarrow Re , F1-score \Rightarrow $F1$, Área Sob a Curva \Rightarrow AUC , $Kappa \Rightarrow \kappa$, Cumpriu em partes a norma da AAMI $\Rightarrow \pm$.

Tabela 2 – Estudos de aplicações de GNN em diversos contextos além da classificação de arritmias.

Referência	Conjunto de Dados	Atributos	# classes	Classificador	Performance*	AAMI	Inter-patient	Aplicação
He et al. (2023)	MIT-BIH, INCARTDB, MIT-BIH SVDB, MIT-BIH LTDB	Espaciais e temporais (ASPP-R) estruturas dos grafos (GCN)	4	MLUDAF (ASPP-R + GCN)	$Se \Rightarrow 71,2$, $+P \Rightarrow 80,3$, $F1 \Rightarrow 74,8$ $Acc \Rightarrow 96,8$	✓	✓	Classificação de arritmias
Ma e Xia (2023)	MIT-BIH AFDB e Physionet Challenge 2017	-	1	AF-GCN	$Se \Rightarrow 99,65$, $Sp \Rightarrow 99,70$	-	-	Classificação de arritmias
Huang et al. (2022)	Exames de fundoscopia e angiogramografia de 145 pacientes do Hospital de Hong Kong	Biomarcadores quantitativos da microvasculatura retiniana	2	GraphSAGE Network	$Acc \Rightarrow 70,0$, $Se \Rightarrow 71,0$, $Sp \Rightarrow 68,0$, $+P \Rightarrow 71,0$, $F1 \Rightarrow 71,0$, $AUC \Rightarrow 73,0$	-	-	Predição da doença arterial coronariana
Li, Chen e Cheng (2022)	ISRUC-SLEEP sleep-EDF	Espaciais e temporais de EEG	5	ST-GCN ²	$Acc \Rightarrow 87,0$, $Se \Rightarrow 86,0$, $+P \Rightarrow 86,0$, $F1 \Rightarrow 86,0$, $k \Rightarrow 84,0$ (ISRUC-SLEEP) $Acc \Rightarrow 91,0$, $Se \Rightarrow 90,0$, $+P \Rightarrow 87,0$, $F1 \Rightarrow 89,0$, $k \Rightarrow 88,0$ (sleep-EDF)	-	-	Classificação dos estágios do sono
Mueller et al. (2022) ¹	CPSC	-	2	GCN	$Acc \Rightarrow 79,0$, $Se \Rightarrow 77,0$, $Sp \Rightarrow 93,0$, $F1 \Rightarrow 79,0$, $AUC \Rightarrow 86,0$	X	X	Classificação de arritmias
Andayeshgar et al. (2022)	CUSPH	12 derivações de cada sinal	7	GCN-MI	$Acc \Rightarrow 99,71$, $Se \Rightarrow 98,45$, $Pr \Rightarrow 97,80$ $Sp \Rightarrow 99,85$	-	-	Classificação de arritmias
Yu et al. (2021)	Fourth People's Hospital of Hua'an City	-	2	ResGNet-C	$Acc \Rightarrow 96,0$, $Se \Rightarrow 97,0$, $Sp \Rightarrow 95,0$ $+P \Rightarrow 96,0$, $F1 \Rightarrow 96,0$	-	-	Deteção de Covid-19
Cao et al. (2020) ¹	ECG5000	-	5	StemGNN ²	$MAE \Rightarrow 0,05$, $RMSE \Rightarrow 0,07$ $MAPE \Rightarrow 10,58$	X	X	Classificação de arritmias
Wang et al. (2020)	HFECCG	-	34	MLWGAT ²	$f1_{micro} \Rightarrow 91,0$, $f1_{macro} \Rightarrow 44,0$	X	✓	Classificação de arritmias
Wu et al. (2020)	TwitterSH Twitter 1KS-10KN	Bag-of-words	2	GCNwithMRF ²	$Acc \Rightarrow 83,0$, $PRAUC \Rightarrow 89,0$ (TwitterSH) $Acc \Rightarrow 83,0$, $PRAUC \Rightarrow 86,0$ (1KS-10KN)	-	-	Deteção de spam em redes sociais
Mathur e Chaakka (2020)	Instituto de Biometria Médica da Universidade de Bonn	Densidade espectral de potência	2	GDFT ²	$Acc \Rightarrow 100$, $Se \Rightarrow 100$, $Sp \Rightarrow 100$	-	-	Classificação de epilepsia em EEG
Guo et al. (2019)	PeMSD4 PeMSD8	03 segmentos temporais (recente, diário e semanal)	-	ASTGCN ²	$RMSE \Rightarrow 32,82$, $MAE \Rightarrow 21,80$ (PeMSD4) $RMSE \Rightarrow 25,27$, $MAE \Rightarrow 16,63$ (PeMSD8)	-	-	Previsão de fluxos de tráfego
Guo et al. (2018)	CAD-120 PiGraphs	Anotações das localizações dos objetos	10	NGM ²	Aprendizado $\Rightarrow 91,0$ (CAD-120) Aprendizado $\Rightarrow 88,0$ (PiGraphs)	-	-	Reconhecimento de cenas 3D

* $Acúrcia \Rightarrow Acc$, $Sensibilidade \Rightarrow Se$, $Especificidade \Rightarrow Sp$, $Predição Positiva \Rightarrow +P$, $F1-score \Rightarrow F1$, $Kappa \Rightarrow \kappa$, $\text{Área Sob a Curva} \Rightarrow AUC$, $\text{Erro absoluto médio} \Rightarrow MAE$, $\text{Erro percentual absoluto médio} \Rightarrow MAPE$, $\text{Erro quadrático médio} \Rightarrow RMSE$, $\text{Área Sob a Curva Precisão-Recall} \Rightarrow PRAUC$.

¹ Os autores realizaram testes com outros conjuntos de dados (não exclusivamente a ECGs).

² SpatioTemporal Graph Convolutional Network (ST-GCN), Spectral Temporal GNN (StemGNN), Multi-Label Weighted Graph Attention Network (MLWGAT), Graph Convolution Network with Markov Random Field (GCNwithMRF), Graph Discrete Fourier Transform (GDFT), Attention Spatial-Temporal Graph Convolution Network (ASTGCN), Neural Graph Matching Networks (NGM)

2.2 Redes Complexas e Teoria de Grafos

Redes complexas corresponde a um grafo com uma estrutura topológica não trivial composto por vértices ou nós conectados por arestas/*links* (BARABÁSI et al., 2003). Essa forma de conexão pode ser utilizada para representar relações, onde os vértices representam entidades e as arestas representam a interação entre essas entidades e, a partir desta relação, seus dados e significados podem ser analisados por meio da teoria de grafos.

Do mesmo modo, uma rede complexa é um grafo que representa um sistema complexo, como a Internet, redes sociais, redes de mobilidade, redes neuronais, infectados de uma epidemia, relação entre livros e artigos, rede molecular, entre outras. Essa área ganhou grande atenção a partir dos anos noventa, quando diversos mapas de redes foram criados e percebeu-se que, apesar de representarem dados em domínios distintos, muitas características eram universais, como distribuição de métricas de centralidade e mecanismos de crescimento das redes (BARABÁSI, 2013).

A criação da área de teoria dos grafos é comumente atribuída ao matemático do século XVIII, Leonhard Euler, que em 1735 a usou para resolver o problema das Sete Pontes de Königsberg¹. Alguns trabalhos foram fundamentais para o surgimento e crescimento da área, como a criação de modelos de geração de redes aleatórias de Paul Erdős e Alfred Rényi (ERDŐS; RÉNYI et al., 1960) e a importância de ligações fracas em redes complexas de Mark Granovetter (GRANOVETTER, 1973).

Na literatura, diversas soluções têm sido propostas baseadas em redes complexas. Garcia et al. (2017) propuseram um método de classificação automática de arritmias baseado em uma nova representação do sinal de ECG, denominado de vetorcardiograma temporal com seleção de atributos por meio de redes complexas e classificador SVM. Utilizando o paradigma *inter-patient*, o método proposto obteve resultados comparáveis com outros métodos da literatura com acurácia global de 92,4%.

Ainda, Freitas, Lacerda e Macau (2019) utilizaram redes complexas não direcionadas construídas a partir de séries temporais para caracterização dinâmica de sistemas não lineares. Backes, Casanova e Bruno (2009) apresentaram uma nova metodologia de caracterização de contorno de forma em imagens modelada por redes complexas de “pequeno mundo”, do inglês *small world*. Para isso, medidas de graus em redes de evolução dinâmica foram utilizadas para compor o conjunto de descritores de forma.

Portanto, percebe-se um grande interesse na literatura pela teoria de redes complexas sendo aplicada em diversos campos do conhecimento (PAGANI; AIELLO, 2013), como biologia (JEONG et al., 2000), química (DOYE, 2002), ciências sociais (TRAVERS; MILGRAM, 1977), padrões de chamadas telefônicas (AIELLO; CHUNG; LU, 2000), redes de computadores (FALOUTSOS; FALOUTSOS; FALOUTSOS, 1999), web (ALBERT;

¹<https://www.blogs.unicamp.br/zero/1398/>

JEONG; BARABASI,), propagação do vírus (COLIZZA et al., 2007; FREITAS et al., 2020; FREITAS; MOREIRA; SANTOS, 2020; BALCAN et al., 2010), logística (GUIMERA; AMARAL, 2004) e sistemas interbancários (BOSS et al., 2004).

Ainda, de acordo com Newman (2003), diversos livros buscam expandir o conhecimento relacionado à redes complexas e sendo que três livros populares merecem menção: *Linked: The new science of networks* (BARABÁSI, 2003) de Albert-László Barabási, que apresenta a ciência das redes e seu desenvolvimento ao público por meio dos principais modelos, propriedades e aplicações em áreas da vida real; *Six degrees: The science of a connected age* (WATTS, 2004) de Duncan J. Watts, que apresenta uma visão de um sociólogo, cobrindo a aplicação da teoria das redes à sociologia; e por último, *Nexus: Small Worlds and the Groundbreaking Science of Networks* (MARK, 2002) de Mark Buchanan, que oferece uma visão divertida do ponto de vista de um jornalista científico.

Por fim, alguns conceitos principais da teoria de grafos (WU et al., 2020) são definidos a seguir para uma melhor compreensão desta dissertação. Considerando um grafo como $G(V, E)$, tem-se que:

- G é um conjunto de vértices conectados a partir de algum tipo de relação por meio de arestas;
- V é o conjunto de vértices;
- E é o conjunto de arestas;
- $v_i \in V$ é o vértice i ;
- $e_{i,j} \in E$ é uma aresta de v_j para v_i ;
- $n = |V|$ é o número de vértices do grafo;
- $N(v) = \{u \in V | (v, u) \in E\}$ é a vizinhança do vértice v ;
- Matriz de adjacência $\mathbf{A}^{n \times n}$ com:
 - $A_{i,j} = 1$ se $e_{i,j} \in E$,
 - $A_{i,j} = 0$ se $e_{i,j} \notin E$;
- Matriz de atributos dos vértices $\mathbf{X} \in \mathcal{R}^{n \times d}$. O vetor de atributos de um vértice v é $\mathbf{x}_v \in \mathcal{R}^d$;
- Matriz de atributos das arestas $\mathbf{X}^e \in \mathcal{R}^{m \times c}$, sendo $m = |E|$. O vetor de atributos de uma aresta (v, u) é $\mathbf{x}_{v,u}^e \in \mathcal{R}^c$;

- Grafo G não direcionado: grafo onde as relações entre os vértices não possuem direcionalidade. Um grafo é não direcionado se, e somente se, a sua matriz de adjacência é simétrica² (ver Figura 7a);
- Grafo G direcionado: grafo onde todas as suas arestas são direcionadas, ou seja, as arestas possuem uma origem e destino (ver Figura 7b);
- Grafos homogêneos: grafo que contém vértices e arestas do mesmo tipo;
- Grafos heterogêneos: grafo que contém vértices e arestas de diferentes tipos;
- Grau: número de arestas conectadas a um vértice;

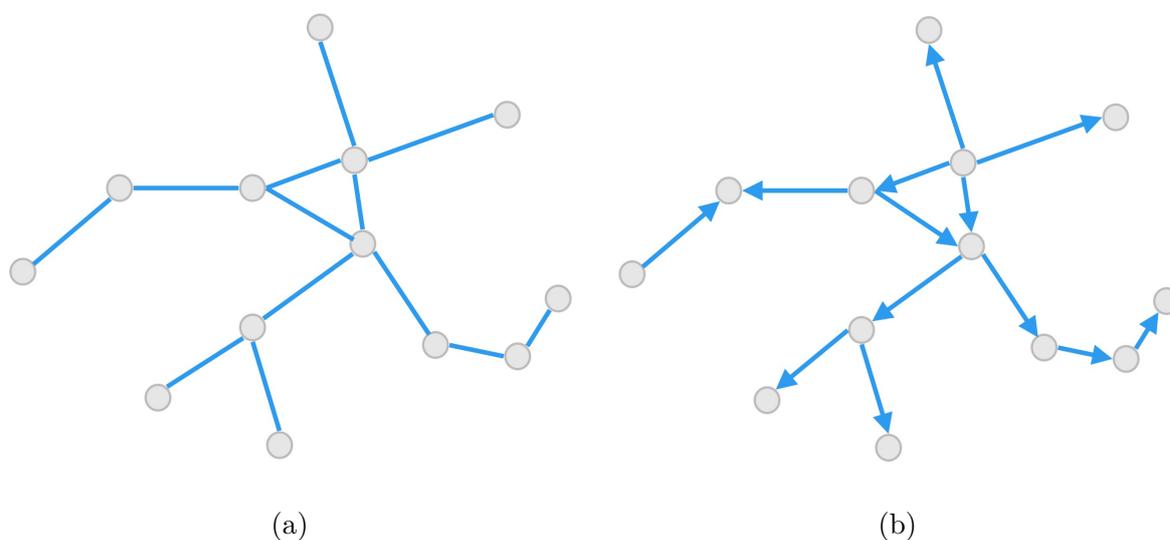


Figura 7 – Representação de dois tipos de grafos: (a) grafo não direcionado e (b) grafo direcionado.

2.2.1 Conversão de séries temporais em grafos

Diante das possibilidades na área do conhecimento, redes complexas têm sido úteis na obtenção de informações importantes contidas em séries temporais, possibilitando assim a caracterização do comportamento dinâmico não linear em diversos contextos. Para determinar a conectividade espacial das séries temporais através de redes complexas diversas abordagens têm sido propostas. De acordo com Ren e Jin (2019), três principais abordagens destacam-se na literatura:

1. Mapeamento de séries temporais pseudoperiódicas em redes complexas, onde os vértices da rede correspondem a cada ciclo da série temporal e a conectividade entre os vértices é baseada na similaridade ou correlação temporal entre os ciclos (ZHANG; SMALL, 2006; SUN et al., 2014);

²https://www.ufrgs.br/reamat/AlgebraLinear/livro/s1e1-matrizes_simx00e9tricas.html

2. Rede recorrente que considera o vetor de espaço de fase como vértice e determina a conectividade entre os vértices pela distância do vetor correspondente (DONNER et al., 2010; DONGES et al., 2011);
3. Dados da série temporal são definidos diretamente como vértices da rede e a conectividade entre os vértices é determinada pela visibilidade entre os dados correspondentes (LACASA et al., 2008; LUQUE et al., 2009; GOTODA et al., 2017).

Dentre as abordagens comumente utilizadas na literatura, esta dissertação baseia-se no mapeamento dos sinais de ECG em grafos por meio de dois métodos, sendo: o método VG proposto por Lacasa et al. (2008) para séries temporais univariadas (sinais de ECG com uma derivação) e o método VVG proposto por Ren e Jin (2019) para séries temporais multivariadas (sinais de ECG com duas derivações).

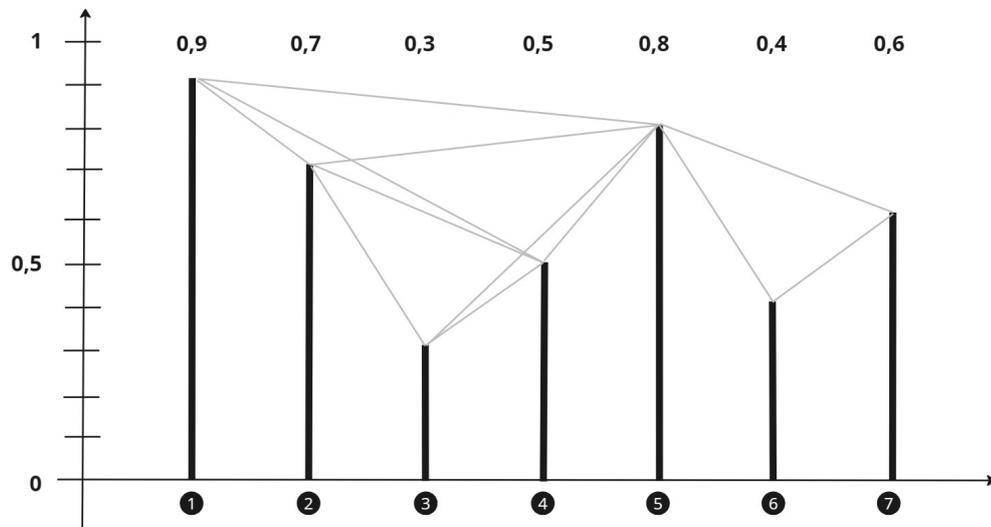
2.2.1.1 Visibility Graph (VG)

As pontos de uma derivação do sinal de ECG no tempo podem ser vistas como uma série temporal de uma dimensão e esta série temporal é, então, transformada em grafo. A Figura 8 exemplifica a representação do mapeamento dos sinais de ECG pelo método VG. Cada ponto da série origina um vértice do grafo e dois vértices são conectados se satisfazem um critério de visibilidade.

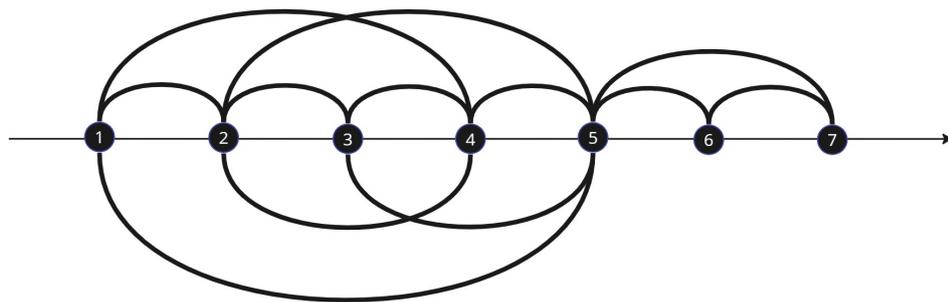
Considere dois pontos (t_a, y_a) e (t_b, y_b) , representados pelos vértices a e b , onde t_a e t_b representam o tempo e y_a e y_b os valores associados. Eles serão conectados se

$$y_c < y_b + \left(y_a - y_b \right) \frac{t_b - t_c}{t_b - t_a} \quad (2.1)$$

para quaisquer pontos (t_c, y_c) . Em outras palavras, se cada ponto da série fosse uma barra vertical, em um gráfico de barras, duas barras a e b se conectam se não existe nenhuma barra c entre elas, cuja altura impossibilite que uma linha reta seja traçada entre os picos de a e b , como representado pela Figura 8.



(a)



(b)

Figura 8 – Exemplo aplicação do método VG. (a) Visibilidade entre as pontos de uma série temporal univariada (sinal de ECG com uma derivação). (b) Grafo gerado pelo VG.

Fonte: Adaptada de Lacasa et al. (2008).

Segundo Lacasa et al. (2008), o grafo extraído pelo VG sempre apresenta as seguintes características:

- Grafo conectado: cada vértice apresenta visibilidade pelo menos para seus vizinhos mais próximos, tanto pela esquerda quanto pela direita;
- Grafo não direcionado: pela forma que o algoritmo é construído, não há direção nas arestas;
- Invariante sob transformações dos dados da série: o critério de visibilidade é invariante

sob reescalonamento dos eixos horizontal e vertical e translações horizontais e verticais.

2.2.1.2 Vector Visibility Graph (VVG)

Baseado no método VG para séries temporais univariadas, Ren e Jin (2019) propuseram o método VVG para mapeamento de séries temporais multivariadas em uma rede complexa direcionada. O vetor de dados multidimensional é definido como um vértice e a conectividade entre eles é dada pela visibilidade entre o vetor de dados correspondente de acordo com um critério de visibilidade.

Seja $X_t = \{x_t^i\}_{i=1}^m$ uma série temporal multivariada m -dimensional³, onde N é o tamanho em cada dimensão e $\{\vec{X}_t\}$ um vetor que representa o espaço da série temporal multivariada, dado por $\vec{X}_t = [x_t^1, x_t^2, \dots, x_t^m]$. Considerando dois vetores quaisquer \vec{X}_a e \vec{X}_b do vetor de espaço $\{\vec{X}_t\}$, a projeção de \vec{X}_a em \vec{X}_b pode ser definida como:

$$\|\vec{X}_b^a\| = \frac{\sum_{i=1}^m x_a^i x_b^i}{\sqrt{\sum_{i=1}^m x_a^i x_a^i}}. \quad (2.2)$$

Considerando que cada vetor na sequência vetorial seja representado como um vértice na rede, o critério de visibilidade entre os vetores é definido como

$$\|\vec{X}_c^a\| < \|\vec{X}_b^a\| + \left(\|\vec{X}_a\| - \|\vec{X}_b\| \right) \frac{t_b - t_c}{t_b - t_a}, \quad (2.3)$$

onde $t_a < t_c < t_b$, $\|\vec{X}_b^a\|$ a projeção de \vec{X}_a em \vec{X}_b e $\|\vec{X}_c^a\|$ a projeção de \vec{X}_a em \vec{X}_c . Consequentemente, se o critério (2.3) for satisfeito, haverá uma conexão do vértice representado por \vec{X}_a ao vértice representado por \vec{X}_b na rede complexa gerada. Com $m = 1$, o método VVG é equivalente ao método VG. A Figura 9 ilustra um exemplo da aplicação do método VVG.

³Representação de uma série temporal multivariada m -dimensional:
 $X_t = [\{x_t^1, x_{t+1}^1, x_{t+2}^1, \dots, x_{t+n}^1\}, \{x_t^2, x_{t+1}^2, x_{t+2}^2, \dots, x_{t+n}^2\}, \dots, \{x_t^m, x_{t+1}^m, x_{t+2}^m, \dots, x_{t+n}^m\}]$

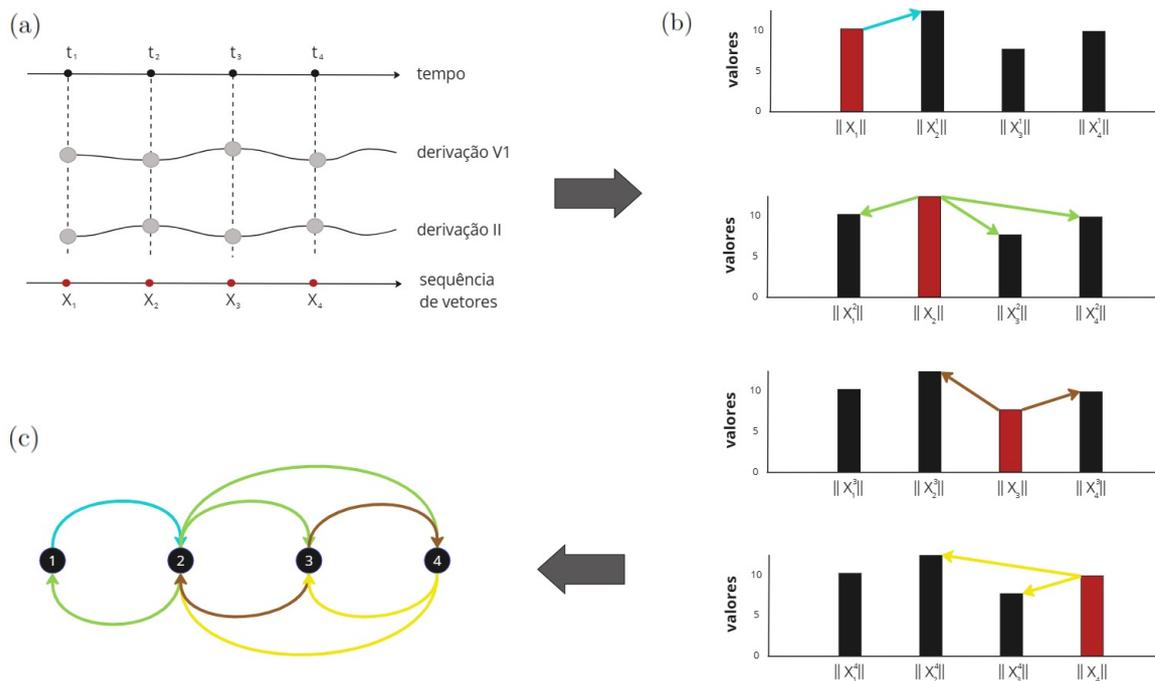


Figura 9 – Exemplo da aplicação do método VVG. (a) Séries temporais multivariadas como sendo dois sinais de ECG com derivações diferentes. (b) Visibilidade entre os vetores. (c) Grafo gerado pelo VVG.

Fonte: Adaptada de Ren e Jin (2019).

2.3 Graph Neural Network (GNN)

O recente progresso da inteligência artificial e *deep learning* tem aumentado o potencial das análises na área biomédica, permitindo a descoberta de representações morfológicas, texturais e temporais em imagens e sinais biológicos por meio de seus dados (AHMEDT-ARISTIZABAL et al., 2021). Esse crescimento significativo da popularidade de DL deve-se ao fato do sucesso na modelagem de dados relacionais não estruturados e estruturados, como sinais cerebrais (fMRI e EEG) e detecção e segmentação de órgãos (cérebro, pulmão, fígado, por exemplo).

A notoriedade das GNNs está presente em diversos domínios da literatura (WU et al., 2020), como na química (DO; TRAN; VENKATESH, 2019), em estudos sociais (WANG et al., 2018), na biologia (FOUT, 2017), em classificação de texto (YAO; MAO; LUO, 2019), em sistemas de recomendação (WU et al., 2019), dentre outros.

Diferente da vasta maioria das aplicações, onde os dados pertencem ao domínio euclidiano (imagens, textos e vídeos, por exemplo), o interesse nas GNNs é justificado pelo número crescente de aplicações onde os dados não podem ser mapeados no domínio euclidiano (WU et al., 2020). Para isso, pode-se utilizar a representação em forma de grafos.

O campo do DL que visa construir redes neurais para dados pertencentes ao domínio não euclidiano é denominado de *Geometric Deep Learning* (WU et al., 2020).

Como ilustrada na Figura 10a, a convolução em um domínio euclidiano, em uma imagem por exemplo, é análogo a um grafo, considerando cada pixel como um vértice e seus vizinhos são determinados pelo tamanho do filtro da operação de convolução. Para o vértice em destaque (em vermelho), a convolução 2D considera os valores dos pesos ao longo da sua vizinhança, que é ordenada e de tamanho fixo. Na Figura 10b, a convolução gera uma representação do vértice em destaque (em vermelho) também considerando os atributos da sua vizinhança. Porém, diferente do domínio euclidiano, no domínio não euclidiano a vizinhança é desordenada e de tamanho variável.

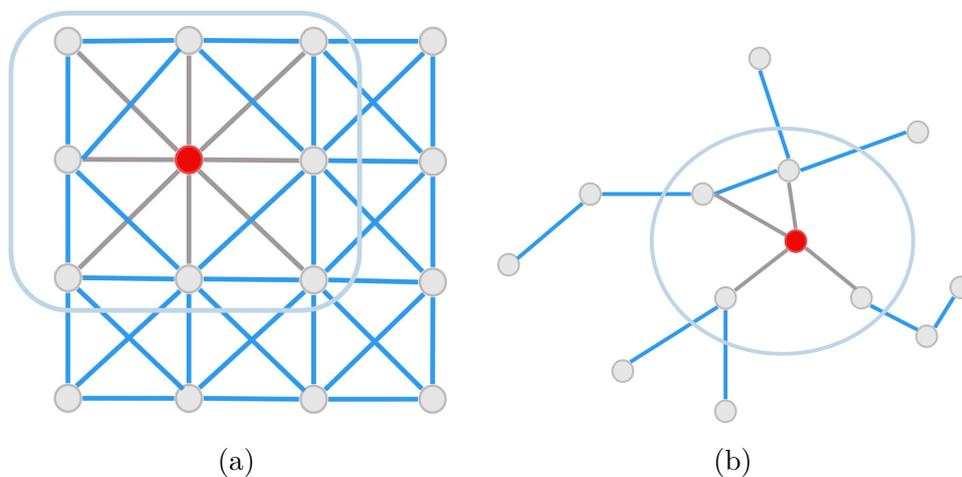


Figura 10 – Operações de convoluções: (a) Convolução 2D em domínio euclidiano e (b) Convolução de grafos em domínio não euclidiano.

Fonte: Adaptada de Wu et al. (2020)

O surgimento das GNNs deu-se nos anos 90 (ZHOU et al., 2020) com as redes neurais recursivas (SPERDUTI; STARITA, 1997) utilizadas em grafos direcionados acíclicos. Posteriormente, RNNs (SCARSELLI et al., 2008) e FFNNs (MICHELI, 2009) foram introduzidas para grafos cíclicos. Até esse momento, as redes eram construídas baseadas em sistemas de transição de estado em grafos e iteragiam até a convergência, o que restringia a capacidade de extensão e representação. Com o avanço das DNNs, em especial pelas CNNs (LECUN et al., 1998), as GNNs foram aprimoradas.

De acordo com Wu et al. (2020), GNNs podem ser categorizadas em quatro principais tipos: *Recurrent Graph Neural Network* (RecGNN), *Graph AutoEncoder* (GAE), *Spatial-Temporal Graph Neural Networks* (STGNN) e *Convolutional Graph Neural Networks* (ConvGNN) ou *Graph Convolutional Networks* (GCN). As ConvGNNs foram escolhidas como proposta de classificação automática de arritmias por meio do mapeamento dos sinais de ECG em grafos nesta dissertação. Os outros modelos serão tratados brevemente pois eles não são o foco nesta dissertação.

A Tabela 3 resume algumas publicações na literatura que utilizaram os quatro principais tipos GNNs em suas pesquisas. As publicações foram categorizadas de acordo com o tipo de GNN utilizada.

Tabela 3 – Exemplos de publicações que utilizaram diferentes tipos de GNNs em suas pesquisas.

Modelos		Publicações
RecGNNs		Scarselli et al. (2008), Gallicchio e Micheli (2010), Li et al. (2015), Dai et al. (2018)
GAEs	<i>Network embeddings</i>	Cao, Lu e Xu (2016), Wang, Cui e Zhu (2016), Kipf e Welling (2016b), Pan et al. (2018)
	Geração de grafos	Simonovsky e Komodakis (2018), Cao e Kipf (2018), Ma, Chen e Xiao (2018), Bojchevski et al. (2018)
STGNNs		Jain et al. (2016), Yu, Yin e Zhu (2017), Yan, Xiong e Lin (2018), Wu et al. (2019)
ConvGNNs	Espectral	Bruna et al. (2013), Henaff, Bruna e LeCun (2015), Defferrard, Bresson e Vandergheynst (2016), Kipf e Welling (2016a)
	Espacial	Liu et al. (2019), Velickovic et al. (2019), Xu et al. (2018), Chiang et al. (2019)

As RecGNNs são os primeiros modelos de GNN, visando aprender as representações dos vértices com arquiteturas de redes neurais recorrentes. Essas redes assumem que um vértice do grafo compartilha informações com seus vértices vizinhos até que um equilíbrio estável seja alcançado. Conceitualmente, RecGNNs são importantes e serviram de inspiração para pesquisas com ConvGNNs em relação à ideia de transmissão de mensagem por vértices (WU et al., 2020).

As GAEs são utilizadas para aprender *network embeddings* (transformações em um espaço de baixa dimensão, preservando o máximo de informações possível) e gerar distribuições de grafos. Para *network embeddings*, as GAEs aprendem representações dos vértices por meio da reconstrução de informações estruturais do grafo, como a matriz de adjacência. Para isso, utiliza camadas convolucionais para cada vértice. Para a geração de grafos, alguns métodos geram vértices e arestas passo a passo enquanto outros métodos geram um grafo de uma só vez (WU et al., 2020).

As STGNNs visam aprender os padrões de grafos espaço-temporais, que se tornaram cada vez mais populares em diversas aplicações, como previsão de velocidade em fluxo de tráfego (LI et al., 2017), antecipação de manobras de motoristas (JAIN et al., 2016) e reconhecimento de ação humana (YAN; XIONG; LIN, 2018). A base das STGNNs é considerar a dependência espacial e temporal ao mesmo tempo. Algumas abordagens

integram convoluções de grafos para capturar a dependência espacial com RNNs ou CNNs para modelar a dependência temporal (WU et al., 2020).

As ConvGNNs generalizam a operação de convolução de dados do domínio euclidiano em formato de grade para dados em formato de grafo. A ideia principal é gerar uma representação de um vértice v por meio de agregação de seus próprios atributos \mathbf{x}_v e os atributos dos seus vizinhos \mathbf{x}_u , onde $u \in N(v)$.

Diferente das RecGNNs, as ConvGNNs utilizam múltiplas camadas convolucionais para extrair representações de alto-nível dos vértices. Isso implica que uma camada convolucional agrega informações da primeira vizinhança do vértice, duas camadas convolucionais agregam informações de duas vizinhanças do vértice, e assim por diante. Portanto, quanto mais camadas convolucionais forem utilizadas mais informações serão agregadas. Por isso, as ConvGNNs desempenham um papel central na construção de diversos outros modelos complexos de GNNs (WU et al., 2020).

As ConvGNNs apresentam duas categorias de metodologia segundo Wu et al. (2020):

1. Espectral (*Spectral-based*): define as convoluções de grafos introduzindo filtros a partir da perspectiva do processamento de sinais de grafos (SHUMAN et al., 2013), onde a convolução de grafos é interpretada como remoção de ruídos de sinais de grafos.
2. Espacial (*Spatial-based*): herdaram a ideia de propagação da RecGNNs para definir convoluções de grafos por meio da propagação de informações pela vizinhança. Essa metodologia desenvolveu-se rapidamente devido a sua eficiência, flexibilidade e generalidade (KIPF; WELLING, 2016a).

Nesta dissertação, adotou-se a metodologia espacial como base para desenvolver o método proposto de classificação automática de sinais de ECG. Essa escolha foi influenciada pela disponibilidade da biblioteca DGL, pela simplicidade na implementação das arquiteturas propostas e também pela ampla presença dessa abordagem nas referências da literatura.

Formalmente, as GCNs podem ser definidas da seguinte maneira: considere um grafo como $G(V, E)$, onde V ($|V| = n$) é o conjunto de vértices e E o conjunto de arestas. Cada vértice é conectado consigo mesmo (*loop*), isto é, $(v, v) \in E$, fazendo com que o atributo do próprio vértice seja agregado aos atributos dos vizinhos. Assumindo $X \in \mathcal{R}^{n \times d}$ como a matriz contendo todos os n vértices com seus respectivos vetores de atributos, onde d é a dimensão deste vetor, cada linha $x_v \in \mathcal{R}^d$ é o vetor de atributos para v .

Considere ainda a matriz de adjacência A de G e a matriz diagonal de graus D , onde $D_{ii} = \sum_j A_{ij}$. Para adicionar os *loops* na matriz de adjacência, adicionamos na

matriz A a matriz identidade, $\tilde{A} = A + \lambda I_n$. Com apenas uma camada, a GCN captura informações apenas dos vizinhos imediatos. Com múltiplas camadas, agrega-se informações de uma vizinhança de maior alcance. Uma GCN de várias camadas segue a seguinte regra de propagação em camadas (KIPF; WELLING, 2016a):

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}), \quad (2.4)$$

sendo \tilde{A} a matriz de adjacência do grafo com *loops*, $\tilde{D} = \sum_j \tilde{A}_{ij}$ a matrix de graus com *loops*, $W^{(l)}$ a matriz de pesos e σ a função de ativação, por exemplo, a ReLU, $H^{(l)} \in \mathcal{R}^{n \times d}$ a representação dos atributos dos vértices da l -ésima camada com $H^{(0)} = X$.

O termo $\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}$ indica uma ponderação na matriz de adjacência pela matrix de graus. Essa ponderação realizada pelos graus, na etapa de convolução, dá mais importância aos vértices com baixos graus do que aos vértices com altos graus. A intuição dessa ponderação é que assume-se que os vértices de baixo grau têm impactos maiores em seus vizinhos, enquanto os vértices de alto grau geram impactos menores à medida que espalham sua influência em muitos vizinhos. O expoente $(-\frac{1}{2})$ da matriz \tilde{D} aparece tanto à esquerda e à direita de \tilde{A} porque é preciso ponderar \tilde{A} duas vezes, uma pela linhas e outra pelas colunas. Para outras explicações de como as GCNs funcionam, estes artigos ^{4 5} podem auxiliar.

Como o número de vizinhos de um vértice pode variar de um a milhares, é ineficiente em alguns casos considerar o tamanho total a vizinhança. Para contornar esse problema, existe um modelo denominado GraphSAGE (SAmple and aggreGatE) (HAMILTON; YING; LESKOVEC, 2017) que propõe obter um número fixo de vizinhos para cada vértice adotando uma escolha por amostragem. A operação de convolução é dada por (WU et al., 2020; HAMILTON; YING; LESKOVEC, 2017)

$$h_v^{(l)} = \sigma(W^{(l)} \cdot f_l(h_v^{(l-1)}, \{h_u^{(l-1)}, \forall u \in S_{N(v)}\})), \quad (2.5)$$

sendo f uma função de agregação, σ a função de ativação, $S_{N(v)}$ a amostragem dos vizinhos do vértice v , $W^{(l)}$ a matriz de pesos, $h_v^{(l)} \in \mathcal{R}^d$ o vetor de atributos do vértice v da l -ésima camada com $h_v^{(0)} = X_v$. A função de agregação deve ser invariável às permutações da ordem dos vértices, como uma função de média, soma ou máxima.

Para que informações possam ser agregadas a um vértice a partir da sua vizinhança local, um conjunto de funções agregadoras é utilizado. O alcance de uma vizinhança mais distante no grafo pode ser obtido repetindo o processo de agregação. A operação de agregação do GraphSAGE é definida por

⁴<https://towardsdatascience.com/what-makes-graph-convolutional-networks-work-53badade0ce9>

⁵<https://www.topbots.com/graph-convolutional-networks/>

$$h_{\mathcal{N}(v)}^k \leftarrow \text{aggregate}_k(\{h_u^{k-1}, \forall u \in \mathcal{N}(v)\}), \quad (2.6)$$

$$h_v^k \leftarrow \sigma(W^k \cdot \text{concat}(h_v^{k-1}, h_{\mathcal{N}(v)}^k)), \quad (2.7)$$

$$h_v^k \leftarrow \text{norm}(h_v^k, \forall v \in V). \quad (2.8)$$

A intuição do GraphSAGE é que a informação agregada dos vizinhos locais de cada vértice é incrementada cada vez mais, tornando o processo de classificação mais robusto a cada iteração. A cada iteração k , cada vértice $v \in V$ agrega informação dos vizinhos imediatos amostrados $h_u^{k-1}, \forall u \in \mathcal{N}(v)$ em um único vetor $h_{\mathcal{N}(v)}^{k-1}$, como em (2.6). Percebe-se que a agregação depende das representações geradas na iteração anterior ($k-1$) e o caso base ($k=0$) que representa vetor de atributos de entrada. Após a agregação, o GraphSAGE concatena a representação atual do vértice h_v^{k-1} com as dos vizinhos $h_{\mathcal{N}(v)}^{k-1}$ aplicada a uma função de ativação σ (2.7), onde as transformações são utilizadas na próxima iteração por meio de $h_v^k, \forall v \in V$, a representação atual do vértice na iteração k . Por fim, as informações são normalizadas (2.8) para a próxima iteração.

Com a estrutura do grafo definida e as informações agregadas a essa estrutura, as GNNs podem analisar diferentes níveis de tarefas no grafo. Comumente há três tipos diferentes de mecanismos de aprendizado (ZHOU et al., 2020):

- Nível de vértice (*node-level*): tarefas relacionadas aos vértices. Pode ser classificação, que realiza uma categorização dos vértices em classes distintas; regressão, que prediz um valor contínuo para cada vértice; e clusterização, que particiona vértices em diversos grupos, agrupando vértices similares no mesmo grupo.
- Nível de aresta (*edge-level*): tarefas relacionadas às arestas. O modelo pode classificar as arestas em diferentes tipos ou predizer se uma aresta existe entre dois vértices analisados.
- Nível de grafo (*graph-level*): tarefas relacionadas ao grafo. Incluem também classificação, regressão e equivalência (*matching*) de grafos. Para isso, o modelo precisa aprender uma representação de alto nível para o grafo extraindo informações de todos os vértices. Neste dissertação, os batimentos foram mapeados em grafos e utilizou-se o mecanismo de aprendizado nível grafo para classificá-los, ou seja, o modelo classifica cada batimento considerando o grafo como um todo.

3 Metodologia

Este capítulo descreve a metodologia proposta para a classificação automática de arritmias utilizando mapeamento de sinais de ECG em Grafos e GCNs. A metodologia proposta foi utilizada nos experimentos iniciais, tendo os resultados apresentados e publicados no XXII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2022)¹ (OLIVEIRA et al., 2022b; OLIVEIRA et al., 2022a). A Seção 3.1 apresenta o conjunto de dados utilizado nos experimentos. Ainda é apresentado o protocolo de avaliação para os métodos propostos na literatura desenvolvido pela AAMI. Por fim, a Seção 3.2 descreve algumas configurações utilizadas no desenvolvimento dos modelos GCNs e seus respectivos experimentos.

O sistema de classificação automática de sinais de ECG utilizado nos experimentos é ilustrado na Figura 11. As etapas do sistema consistem na obtenção do conjunto de dados, na segmentação dos sinais de ECG em batimentos de tamanho fixo, no balanceamento dos dados, na divisão dos dados em conjunto de treinamento e teste, no mapeamento dos batimentos em grafos e na classificação dos batimentos por meio dos modelos de GNNs, em especial os modelos de redes convolucionais de grafos (GCNs).

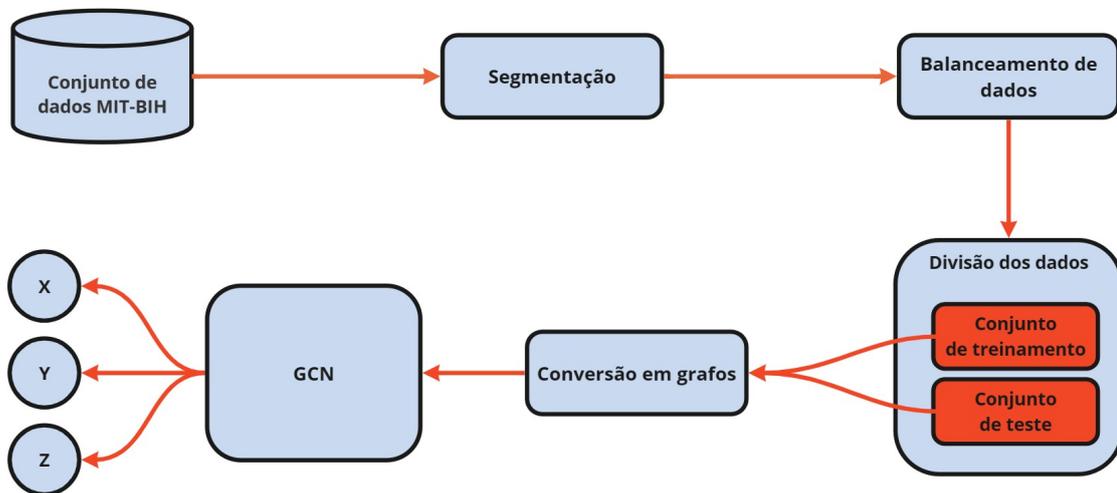


Figura 11 – Diagrama do sistema proposto para classificação de arritmias a partir de sinais de ECG.

¹<https://sol.sbc.org.br/index.php/sbcas>

3.1 Conjunto de Dados e o Protocolo AAMI

Para avaliar os métodos propostos na literatura relacionados à classificação automática de arritmias é necessário o uso de um conjunto de dados que contenha batimentos cardíacos agrupados em registros de pacientes. Para isso, a AAMI desenvolveu um protocolo de desenvolvimento com o objetivo de padronizar as avaliações desses métodos propostos na literatura tornando-os reproduzíveis e comparáveis (LUZ et al., 2016). O protocolo é especificado pela norma ANSI/AAMI EC57:1998/(R)2008 (ANSI/AAMI, 2008).

Quanto ao conjunto de dados, a norma recomenda o uso de algum desses cinco conjunto de dados:

- MIT-BIH: *The Massachusetts Institute of Technology - Beth Israel Hospital Arrhythmia Database* → (48 registros de 30 minutos cada);
- CU: *The Creighton University Sustained Ventricular Arrhythmia Database* → (35 registros de 8 minutos cada);
- AHA: *The American Heart Association Database for Evaluation of Ventricular Arrhythmia Detectors* → (80 registros de 35 minutos cada);
- ESC: *The European Society of Cardiology ST-T Database* → (90 registros de 2 horas cada);
- NST: *The Noise Stress Test Database* → (12 registros de 30 minutos cada, mais 3 registros com excesso de ruídos).

O conjunto de dados mais representativo é o MIT-BIH² (MOODY; MARK, 1990; MOODY; MARK, 2001) em relação aos tipos de arritmias, por isso ele é utilizado na maioria dos trabalhos da literatura (LUZ et al., 2016). Este conjunto de dados também foi utilizado nesta dissertação. Este conjunto de dados é composto por 48 registros de sinais de ECG de 30 minutos, de 47 pacientes diferentes, amostrados à frequência de 360 Hz. A diferença entre o número de registros e pacientes trata-se pelos registros 201 e 202 serem diferentes, porém do mesmo paciente. Os pacientes são 25 homens de 32 a 89 anos e 22 mulheres de 23 a 89 anos. Cada sinal contém duas derivações: derivação V1 (podendo ser V2, V4 e V5 a depender do paciente) e derivação II (MLII), sendo a derivação II a mais utilizada na literatura.

A norma da AAMI também especifica como devem ser realizadas as anotações sobre cada batimento nos conjuntos de dados. Importante ressaltar que a norma recomenda que os registros de pacientes com marca-passos, segmentos de dados que contém *ventricular flutter* ou *fibrillation* (VF) e dados artificiais devem ser excluídos dos experimentos.

²<https://physionet.org/content/mitdb/1.0.0/>

Tabela 4 – Agrupamento dos batimentos recomendado pela norma da AAMI.

Grupo AAMI	Batimentos
<i>Normal</i> (N)	N, e, j, L, R
<i>Supraventricular ectopic beat</i> (S)	A, a, J, S
<i>Ventricular ectopic beat</i> (V)	V, E
<i>Fusion beat</i> (F)	F
<i>Unknown beat</i> (Q)	P ou /, f, U

Dentre os 15 tipos de classes de batimentos, a norma também recomenda o agrupamento dos batimentos em cinco classes principais: *Normal* (N), *Supraventricular ectopic beat* (S), *Ventricular ectopic beat* (V), *Fusion beat* (F) e *Unknown beat* (Q). A Tabela 4 resume o agrupamento dos batimentos dos dados do MIT-BIH após a exclusão dos registros recomendados pela AAMI.

A norma da AAMI não especifica quais dados devem ser utilizados durante as etapas de treinamento e teste do modelo de classificação. De acordo com Chazal, O’Dwyer e Reilly (2004), quando dados do mesmo paciente são utilizados no treinamento e no teste, isso ocasiona uma avaliação enviesada, uma vez que o modelo tende a “aprender” particularidades dos batimentos do paciente durante o treinamento, obtendo resultados expressivos durante a etapa de teste (LUZ; MENOTTI, 2011). Deste modo, o protocolo de divisão dos batimentos pode ser dividido em dois principais paradigmas (SRAITIH; JABRANE; ATLAS, 2021): *intra-patient* e *inter-patient*. No paradigma *intra-patient*, o conjunto de treinamento e teste contém dados de sinais de ECG de um mesmo paciente, enquanto que no paradigma *inter-patient*, o conjunto de treinamento e teste são obtidos por dados de sinais de ECG de pacientes diferentes, sem sobreposição de dados.

Nesse sentido, Chazal, O’Dwyer e Reilly (2004) propuseram uma divisão de batimentos do conjunto de dados MIT-BIH em dois conjuntos a fim de tornar os testes mais adequados à realidade, visto que os modelos terão que “aprender” batimentos de pacientes nunca vistos. A Tabela 5 descreve os registros de pacientes de cada conjunto, denominados de DS1 e DS2. Observa-se que nenhum registro está contido nos dois conjuntos simultaneamente.

Tabela 5 – Distribuição dos registros do MIT-BIH em dois conjuntos de dados.

DS1	DS2
101, 106, 108, 109, 112, 114, 115, 116	100, 103, 105, 111, 113, 117, 121, 123
118, 119, 122, 124, 201, 203, 205	200, 202, 210, 212, 213, 214, 219
207, 208, 209, 215, 220, 223, 230	221, 222, 228, 231, 232, 233, 234

Por meio do paradigma *inter-patient* e da divisão proposta por Chazal, O’Dwyer e Reilly (2004), a Tabela 6 resume a quantidade de batimentos de cada classe juntamente

Tabela 6 – Descrição da quantidade de batimentos nos conjuntos de treinamento e teste.

Classe	% do total	# Treinamento (DS1)	# Teste (DS2)	# Batimentos total
N	89,47	45844	44238	90082
S	2,76	944	1837	2781
V	6,96	3788	3220	7008
F	0,80	414	388	802
Q	0,01	8	7	15
Total	100	50998	49690	100688

com o percentual de presença no conjunto de dados do MIT-BIH. Ainda, a Tabela 6 resume a quantidade de batimentos após a segmentação por conjunto de treinamento (DS1) e conjunto de teste (DS2). Os percentuais de batimentos nos conjuntos de treinamento e teste em relação ao conjunto total foram de 50,65% e 49,35%, respectivamente. Observa-se que as classes F e Q apresentam poucos batimentos, somando menos de 1% de presença em relação ao conjunto de dados total. Por isso, as classes F e Q são removidas do conjunto de dados durante os experimentos.

Quanto às métricas para avaliação dos métodos, as recomendadas pela norma são *Sensibility* ou *Recall* (Se), *Positive Predictivity* ou *Precision* (+P), *False Positive Rate* (FPR) e *Accuracy* (Acc). Apesar da métrica *F1-score* (F_s) não ser recomendada pela norma, essa métrica é amplamente utilizada na literatura. A métrica Acc é fortemente enviesada pela classe majoritária, logo as três primeiras métricas são as mais relevantes no comparativo entre métodos (LUZ et al., 2016), uma vez que as classes no conjunto de dado utilizado durante os experimentos são extremamente desbalanceadas.

O cálculo das métricas é baseado na matriz de confusão por meio dos valores verdadeiros positivos (TP), falsos negativos (FN), verdadeiros negativos (TN) e falsos positivos (FP). As Fórmulas 3.1, 3.2, 3.3, 3.4 e 3.5 correspondem às métricas Se, +P, FPR, F_s e Acc, respectivamente³:

$$Se = \frac{TP}{TP + FN}, \quad (3.1)$$

$$+P = \frac{TN}{TN + FP}, \quad (3.2)$$

$$FPR = \frac{FP}{FP + TN}, \quad (3.3)$$

$$F_s = 2 * \frac{Se * (+P)}{Se + (+P)}, \quad (3.4)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}. \quad (3.5)$$

³Para obter os valores em percentual, basta multiplicar os resultados por 100.

Uma alta Se indica que o modelo é melhor em detectar casos verdadeiramente positivos, ou seja, capacidade do modelo de identificar corretamente os pacientes com arritmias. Por outro lado, uma alta $+P$ indica que o modelo é melhor em detectar casos verdadeiramente negativos, ou seja, capacidade do modelo de identificar corretamente os pacientes saudáveis. A FPR é o percentual de casos negativos nos dados que foram erroneamente relatados como positivos. Logo, o modelo prediz erroneamente que pacientes saudáveis apresentam alguma arritmia. Em um modelo ideal, procura-se obter altas taxas de Se e $+P$. Por serem métricas inversamente proporcionais, F_s foi desenvolvida para conjuntos de dados desbalanceados, sendo a união das métricas Se e $+P$ em uma média harmônica. Por isso, F_s é comumente utilizada como principal métrica de avaliação de modelos de ML (LIPTON; ELKAN; NARAYANASWAMY, 2014). Por fim, tem-se a Acc , como sendo a métrica que mede o número de predições corretas como percentual do número total de predições realizadas. Por exemplo, se 90% das predições estiverem corretas, a Acc será de 90%. Porém, Acc é uma métrica útil apenas em conjuntos de dados balanceados (distribuição uniforme das classes). Como a maioria dos conjuntos de dados na literatura são desbalanceados, a Acc pode não ser a melhor métrica de avaliação, uma vez que sofre influência das classes majoritárias gerando assim resultados enviesados.

3.2 Construção da metodologia

Para que o sistema apresentado na Figura 11 fosse desenvolvido, algumas configurações iniciais foram implementadas durante as etapas de desenvolvimento e as mesmas são apresentadas a seguir. Vale ressaltar que nesta dissertação não utilizou-se nenhum tipo de filtro redutor de ruídos nos sinais de ECG, sendo os mesmos utilizados em sua forma original. A não utilização de filtros redutores de ruídos é uma das motivações para a investigação do uso dos métodos VG e VVG, em que a conversão em grafos funciona com uma espécie de suavização do sinal, uma vez que há perdas, isto é, insere degenerescências (não sendo possível o mapeamento inverso) no sinal de ECG.

Segmentação: a partir da localização da onda R presente no conjunto de dados do MIT-BIH, foi realizada a segmentação dos sinais de ECG em batimentos sendo n pontos obtidas antes da onda R e n pontos obtidas após a onda R, totalizando batimentos de N pontos, sendo $N = n_{\text{antes}} + n_{\text{após}}$. Posteriormente, cada batimento é rotulado com a classe de acordo com as anotações presentes no conjunto de dados. Há experimentos que foram realizados para determinar o valor de n mais ideal para esta etapa. Os resultados são apresentados na Seção 4. Ainda, em alguns experimentos realizados, antes desta etapa de segmentação, os sinais de ECG são normalizados para que ambos sinais fiquem na mesma faixa de amplitude.

Balanceamento de dados: o grande número de batimentos da classe N, conforme

apresentado na Tabela 6, ocasiona um grande tempo de processamento devido ao alto número de grafos gerados, somado ao problema de desbalanceamento entre as classes. Por esse motivo, os batimentos da classe N foram subamostrados, tanto no conjunto de treinamento (DS1) quanto no conjunto de teste (DS2). Utilizou-se amostragem de 10%, onde em uma sequência de 10 batimentos, apenas o último (décimo) é escolhido. A Tabela 7 resume o conjunto de dados antes e após o balanceamento juntamente com a remoção das classes minoritárias F e Q.

Tabela 7 – Descrição da amostragem antes e depois do balanceamento de dados.

Batimentos	Treinamento (DS1)		Teste (DS2)	
	Antes	Depois	Antes	Depois
N	45844	4584	44238	4423
S	944	944	1837	1837
V	3788	3788	3220	3220
Total	50576	7732	49295	8057

Divisão do conjunto de dados: os batimentos gerados na etapa de segmentação foram divididos em conjunto de treinamento (DS1) e conjunto de teste (DS2), conforme apresentado na Tabela 6, respeitando o paradigma *inter-patient*, possibilitando a simulação de um cenário de mundo real (CHAZAL; O'DWYER; REILLY, 2004). Ainda, após o balanceamento de dados apresentado na Tabela 7, é possível perceber que tanto a quantidade de batimentos total quanto da classe S presente no DS2 é maior que a do DS1. Logo, dois experimentos foram adicionados a fim de analisar como os modelos de GCNs comportam-se na inversão entre os conjuntos DS1 e DS2 e na divisão do conjunto de dados pelo paradigma *intra-patient*.

Conversão em grafos: nesta etapa, os batimentos foram convertidos em grafos por meio dos métodos VG e VVG. A Figura 12 exemplifica a conversão dos batimentos correspondentes às classes N, S e V utilizando uma derivação do sinal de ECG pelo método VG. O processo realiza a conversão de um batimento P em um grafo $G(V, E)$, em que V corresponde ao conjunto de vértices e E corresponde ao conjunto de arestas do grafo G .

Nesta dissertação, utilizou-se a abordagem de nível de grafo (*graph-level*) em que a classificação ocorre considerando o grafo como um todo, similar ao trabalho de Kojima et al. (2020), em que foi realizado a predição de proteínas por meio das estruturas moleculares utilizando GCN. Ainda, o uso de GNNs permite que informações adicionais sejam inseridas nos vértices ou arestas. Um experimento proposto avalia diferentes grupos de informações inseridas nos vértices em relação ao comportamento das GCNs na classificação de arritmias dos sinais de ECG. Os mesmos são detalhados na Seção 4.

Classificação: para a classificação dos batimentos, diferentes arquiteturas de GCNs juntamente com diferentes arquiteturas de CNNs são avaliadas durante os experimentos.

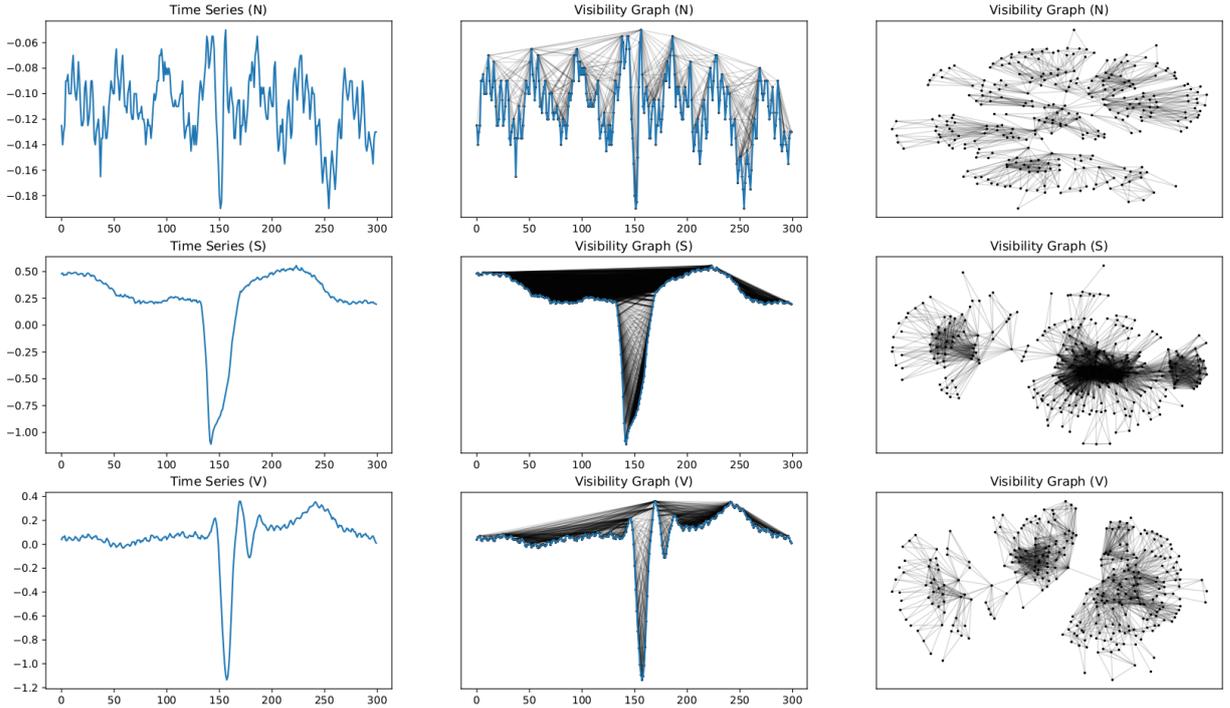


Figura 12 – Exemplo do mapeamento dos batimentos de uma derivação correspondentes às classes N, S e V utilizando o método VG.

Apesar do foco desta dissertação não ser as CNNs, elas servem como base comparativa entre as GCNs em relação ao desempenho de classificação de arritmias. Mais detalhes das arquiteturas utilizadas são detalhadas na Seção 4.

Nas arquiteturas das GCNs, a camada de entrada tem como argumento o tamanho do vetor de atributos (d) de cada vértice ($\mathbf{x}_v \in \mathcal{R}^d$), ou seja, a quantidade de informações agregadas em cada vértice. A camada de saída possui três neurônios correspondentes às três classes alvos (N, S, V). Para classificação a nível de grafos, a camada *readout* é utilizada para agregar atributos de todos os vértices na última iteração da etapa de processamento tanto no treinamento quanto no teste, como segue:

$$h_G = \text{readout}(\{h_v^{(l)} | v \in G\}), \quad (3.6)$$

sendo $h_v^{(l)}$ a representação do vetor de atributos do vértice v na l -ésima iteração/camada com $h_v^{(0)} = X$. A função *readout* pode ser uma operação invariante simples, como soma, média ou uma função mais sofisticada de agrupamento em nível de grafo. Aqui, utilizou-se a média para tal operação. Logo, a função desta camada é obter uma representação de alto-nível de todo grafo (h_G) (XU et al., 2018).

Após a descrição de todas as etapas da metodologia proposta, os experimentos foram construídos visando investigar e responder a questão principal desta dissertação: representações em grafos dos sinais de ECG por meio dos métodos VG e VVG podem melhorar o desempenho de classificação de arritmias utilizando redes convolucionais de

grafos? Os experimentos são enumerados a seguir:

- **Experimento 1:** investigar novas arquiteturas de GCNs utilizando o método VG juntamente com diferentes arquiteturas de CNNs;
- **Experimento 2:** investigar diferentes tamanhos de janela de pontos para segmentação de sinais de ECG nas melhores arquiteturas de GCNs utilizando o método VG e na melhor arquitetura de CNN;
- **Experimento 3:** investigar a agregação de informações nos vértices de cada grafo nas melhores arquiteturas de GCNs utilizando os métodos VG e VVG;
- **Experimento 4:** investigar a inversão dos conjuntos de dados DS1 e DS2 nas melhores arquiteturas de GCNs utilizando os métodos VG e VVG e na melhor arquitetura de CNN;
- **Experimento 5:** investigar o paradigma *intra-patient* nas melhores arquiteturas de GCNs utilizando os métodos VG e VVG e na melhor arquitetura de CNN;
- **Experimento 6:** comparar a metodologia proposta com o trabalho de Garcia et al. (2017).

4 Resultados e Discussões

A avaliação da metodologia proposta e os experimentos realizados são apresentados neste capítulo. Para isso, foram consideradas as recomendações da AAMI, o banco de dados MIT-BIH e os esquemas de divisão de batimentos *intra-patient* e *inter-patient* detalhados na Seção 3.1. As configurações de máquina, métricas e bibliotecas utilizadas nos experimentos são detalhadas na Seção 4.1. Na Seção 4.2 são apresentados os resultados dos experimentos e suas discussões.

4.1 Configurações, Métricas e Bibliotecas

Os experimentos foram conduzidos no sistema operacional Linux Mint 20.1 com ambiente virtual Python 3.8.10 com processador AMD Ryzen Threadripper@3960X 24-Core de 3.8GHz (4.5GHz turbo), 128GB de DDR4 RAM e GPU GeForce RTX 3090 de 24GB de RAM.

As arquiteturas ou modelos de classificação propostos foram avaliados por meio das três métricas recomendadas na norma da AAMI: predição positiva ($+P^k$), sensibilidade (Se^k), taxa de falsos positivos (FPR^k). A avaliação foi complementada pela métrica F1-score (F_s^k) amplamente utilizada na literatura. $k \in \{N, S, V\}$ indica a classe correspondente a cada métrica.

As principais bibliotecas utilizadas na implementação das redes GCN foram *Deep Graph Library* - DGL¹ versão 0.8.2 (WANG et al., 2019), *NetworkX*² versão 2.8.3 (HAGBERG; SCHULT; SWART, 2008) e *PyTorch*³ versão 1.11.0 (PASZKE et al., 2019). Para a conversão dos batimentos em grafos, utilizou-se a biblioteca *ts2vg*⁴ versão 1.0.0 para o método VG e implementação manual para o método VVG baseado no artigo de Ren e Jin (2019). Os códigos das implementações dos métodos VG e VVG quanto das redes convolucionais de grafos estão disponíveis no repositório do github ⁵.

4.2 Experimentos

Nesta seção são reportados os experimentos realizados de acordo com as atividades construídas após a apresentação dos artigos no SBCAS 2022. Os experimentos permeiam

¹<https://www.dgl.ai/>

²<https://networkx.org/>

³<https://pytorch.org/>

⁴<https://github.com/CarlosBergillos/ts2vg>

⁵https://github.com/raffoliveira/visibility_graph_implementation

tanto a utilização dos métodos VG e VVG quanto os paradigmas *inter-patient* e *intra-patient* e inversão de conjunto de dados, visando analisar se ambas representações em grafos podem melhorar o desempenho de classificação de arritmias em sinais de ECG por meio das redes convolucionais de grafos.

4.2.1 Experimento 1: Novas Arquiteturas

Nesta etapa foram realizados experimentos com diferentes arquiteturas de GCNs e CNNs. O uso das CNNs desempenha uma base comparativa de desempenho de classificação de arritmias entre as arquiteturas. O objetivo é analisar o desempenho das arquiteturas propostas de GCNs diante as CNNs, uma vez que as CNNs são arquiteturas amplamente utilizadas na literatura. As variações das arquiteturas de GCNs permeiam os tipos de camadas (convolucionais de grafos tradicionais (GraphConv) e especiais (SAGEConv)) e a quantidade de neurônios das camadas ocultas enquanto que as variações das arquiteturas de CNNs permeiam a quantidade de camadas de convolucionais.

A Tabela 8 detalha as arquiteturas de GCNs propostas neste experimento. Vale ressaltar que a camada *readout* é utilizada para agregar atributos dos vértices na última iteração do processamento para obter uma representação de alto-nível de cada grafo inteiro, sendo utilizado aqui a operação de média. As Figuras 13, 14 e 15 detalham as arquiteturas das CNNs propostas neste experimento, sendo denominadas de CNN-2Conv, CNN-4Conv e CNN-6Conv, respectivamente, devido ao número de camadas convolucionais em cada arquitetura. Na modelagem das CNNs, utilizou-se camadas convolucionais 1D. As arquiteturas de CNNs foram baseadas no exemplo do uso de CNN na classificação de sinais de eletroencefalograma presente no site da biblioteca Keras⁶.

Tabela 8 – Experimento 1: Novas arquiteturas de GCNs.

GCN7			GCN2			GCN60			GCN120			GCN240		
No	Camada	Formato	No	Camada	Formato	No	Camada	Formato	No	Camada	Formato	No	Camada	Formato
1	SAGEConv	$d \times 20$	1	GraphConv	$d \times 20$	1	SAGEConv	$d \times 60$	1	SAGEConv	$d \times 120$	1	SAGEConv	$d \times 240$
2	GraphConv	50×40	2	GraphConv	20×3	2	SAGEConv	60×50	2	SAGEConv	120×40	2	SAGEConv	240×140
3	SAGEConv	40×30	4	Readout	-	3	SAGEConv	50×35	3	SAGEConv	40×20	3	SAGEConv	140×40
4	SAGEConv	30×20	5	Softmax	-	4	SAGEConv	35×3	4	SAGEConv	20×3	4	SAGEConv	40×3
5	SAGEConv	20×10				5	Readout	-	5	Readout	-	5	Readout	-
6	GraphConv	10×5				6	Softmax	-	6	Softmax	-	6	Softmax	-
7	GraphConv	5×3												
8	Readout	-												
9	Softmax	-												

d indica o tamanho do vetor de atributos/informações de cada vértice.

Para os experimentos das GCNs, foram agregadas as seguintes informações em cada vértice: valores dos pontos da derivação V1, valores dos pontos da derivação II e o tempo de cada ponto. Utilizou-se um menor número de informações agregadas neste experimento devido a análise de outros grupos de informações ser realizada no experimento 4.2.3. Ambas informações agregadas foram normalizadas entre $[0, 1]$ pela técnica de normalização

⁶https://keras.io/examples/timeseries/eeg_signal_classification/

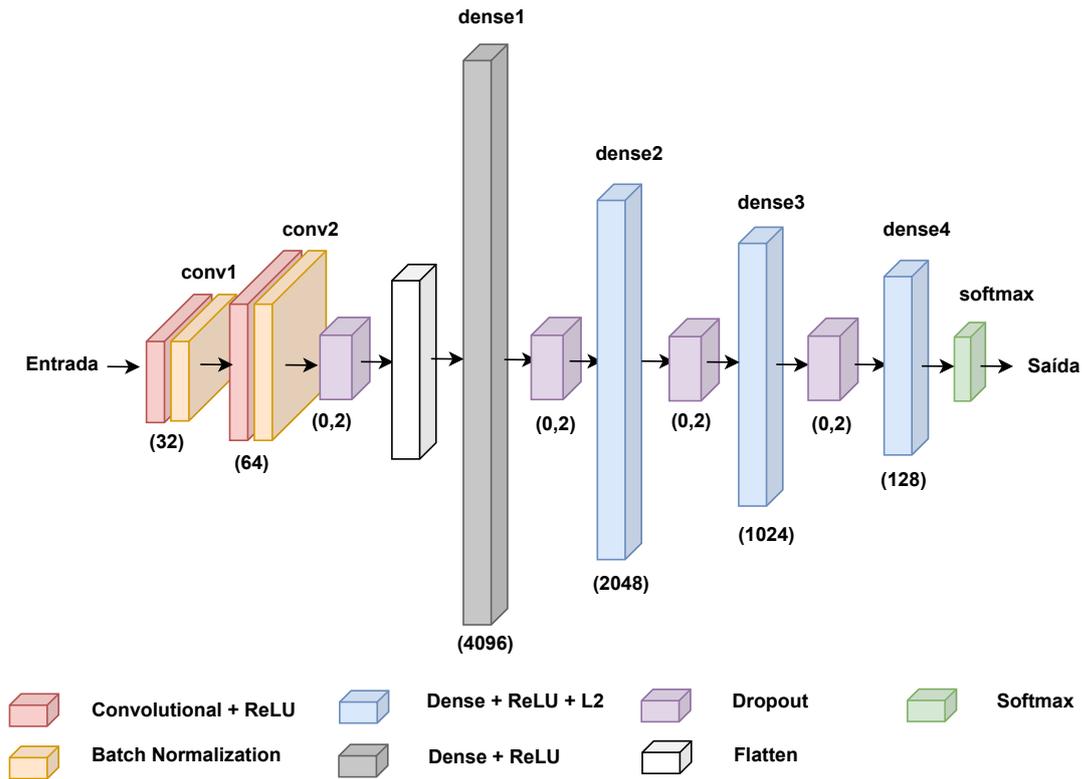


Figura 13 – Experimento 1: Arquitetura da CNN-2Conv utilizada nos experimentos.

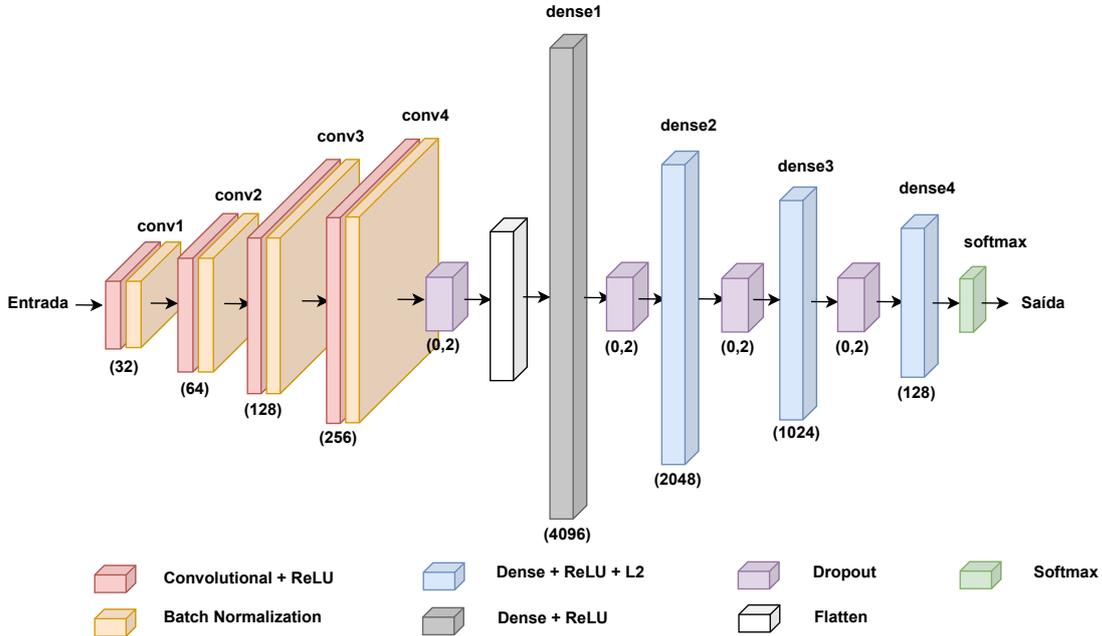


Figura 14 – Experimento 1: Arquitetura da CNN-4Conv utilizada nos experimentos.

min-max⁷. Essa técnica foi escolhida de forma que as arquiteturas analisadas não sofram influência por informações com valores extremos, uma vez que essa técnica preserva as relações de ordem entre os dados. Nos experimentos das CNNs, não foram adicionadas

$${}^7 X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

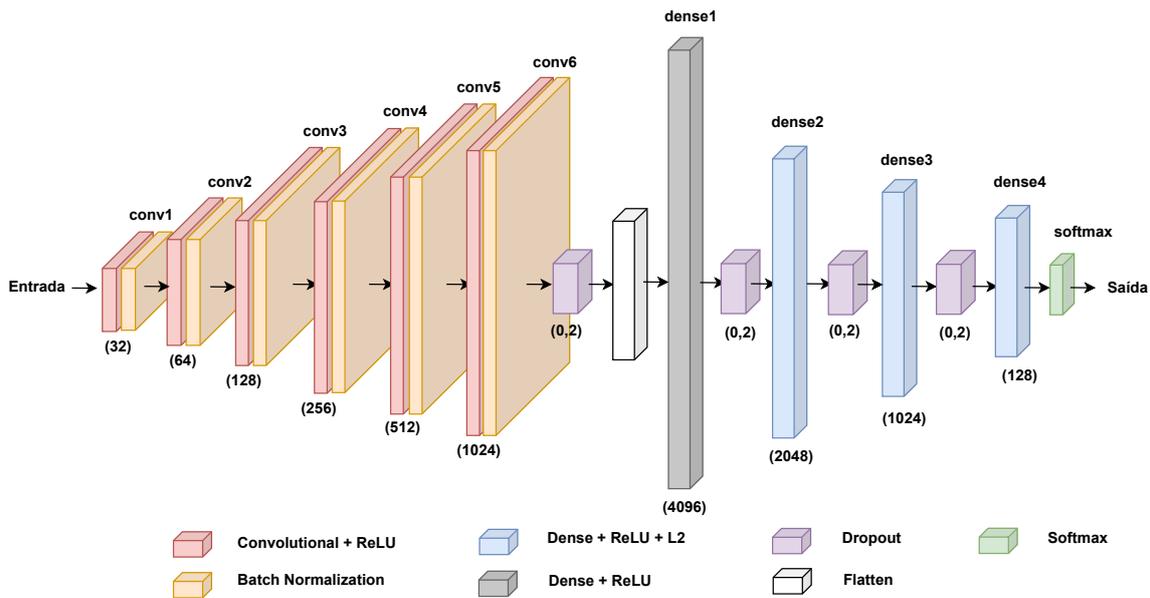


Figura 15 – Experimento 1: Arquitetura da CNN-6Conv utilizada nos experimentos.

informações, ficando a responsabilidade das CNNs em “aprender” sobre os sinais de ECG. Tanto no treinamento das CNNs quanto na conversão dos sinais de ECG em grafos pelo método VG para treinamento das GNNs, utilizou-se a derivação II. Ainda, foi realizada uma amostragem de 10% na classe N, onde em uma sequência de 10 batimentos, apenas o último (décimo) é escolhido.

Por se tratar de um experimento de ajustes de parâmetros, foi utilizado apenas o conjunto de treinamento DS1 dividido na proporção de 80% para treinamento (DS1.1) e 20% para validação (DS1.2). Para que não ocorra uma sobreposição de dados entre os conjuntos de treinamento e validação, utilizou-se o paradigma *inter-patient*, tendo a distribuição dos registros do MIT-BIH de acordo com a Tabela 9. Na etapa de segmentação dos sinais de ECG, utilizou-se uma janela fixa de 280 pontos (100 pontos antes e 180 pontos após o pico R), tendo como base o trabalho de Mousavi e Afghah (2019), considerado o estado da arte.

Em ambos treinamentos, GCNs e CNNs, utilizou-se 150 épocas com o otimizador Adam⁸ a uma taxa de aprendizado de 0,001. No treinamento das CNNs, utilizou-se a função *Categorical Cross Entropy*⁹ como função de perda. Dessa forma, as arquiteturas CNNs têm seus pesos continuamente ajustados no processo de minimização da perda, o que culmina na obtenção de melhores resultados. A expressão matemática que define a função de perda é dada como:

$$L(y_i, \hat{y}_i) = - \sum_{i=1}^N y_i * \log(\hat{y}_i), \quad (4.1)$$

⁸<https://pytorch.org/docs/stable/generated/torch.optim.Adam.html>

⁹https://www.tensorflow.org/api_docs/python/tf/keras/losses/CategoricalCrossentropy

sendo y_i o rótulo real durante o treinamento, \hat{y}_i o rótulo predito e N o número de rótulos de classe.

Tabela 9 – Experimento 1: Distribuição dos registros do MIT-BIH do conjunto de dados DS1 em treinamento (DS1.1) e validação (DS1.2).

Treinamento (DS1.1)	Validação (DS1.2)
101, 106, 108, 112, 115, 116, 118 119, 122, 124, 201, 203, 205, 208 209, 215, 220 e 230	109, 114, 207 e 223

Diante dos experimentos com as variações de arquiteturas, as duas melhores arquiteturas de GCNs e a melhor arquitetura de CNN foram escolhidas para serem analisadas nos experimentos posteriores. A Tabela 10 resume a performance das variações de arquiteturas, tendo as arquiteturas GCN2 e GCN7 os melhores resultados para as GCNs e a CNN-2Conv o melhor resultado para as CNNs.

Enquanto que as arquiteturas GCN2 e GCN7 apresentaram um F_S médio de 41% e 54%, respectivamente, a arquitetura CNN-2Conv apresentou um F_S médio de 63%. Nota-se um baixo desempenho na class S em ambas arquiteturas. Como as arquiteturas apresentaram de forma geral um baixo desempenho, os experimentos posteriores irão analisar outros parâmetros e configurações com o objetivo de melhorar a atual performance.

Tabela 10 – Experimento 1: Resumo da performance das novas arquiteturas de GCNs e CNNs no conjunto de validação (DS1.2).

Arquiteturas	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	
GCN2	47,0	62,0	58,26	53,0	-	-	-	-	40,0	36,0	43,02	38,0	39,0	44,0	45,18	41,0	44,0
GCN7	67,0	46,0	18,31	55,0	33,0	1,0	0,26	2,0	55,0	86,0	55,25	67,0	58,0	59,0	32,5	54,0	59,0
GCN60	35,0	43,0	64,29	39,0	1,0	1,0	6,52	1,0	32,0	28,0	46,28	30,0	30,0	32,0	50,05	31,0	32,0
GCN120	37,0	47,0	64,64	42,0	1,0	1,0	5,02	1,0	35,0	31,0	44,75	33,0	33,0	35,0	49,37	33,0	35,0
GCN240	36,0	43,0	62,24	39,0	4,0	3,0	8,18	3,0	32,0	29,0	46,99	31,0	31,0	32,0	49,62	31,0	32,0
CNN-2Conv	82,0	50,0	8,89	62,0	43,0	16,0	2,64	23,0	60,0	94,0	48,83	73,0	70,0	65,0	25,69	63,0	65,0
CNN-4Conv	77,0	49,0	11,82	60,0	67,0	14,0	0,84	23,0	57,0	90,0	52,6	70,0	67,0	63,0	28,47	60,0	63,0
CNN-6Conv	81,0	43,0	8,16	56,0	79,0	16,0	0,52	26,0	55,0	93,0	58,61	70,0	68,0	62,0	29,41	59,0	62,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Nota: valores em negrito indicam a melhor performance.

4.2.2 Experimento 2: Quantidade de pontos na etapa de segmentação

Este experimento avalia o impacto da quantidade de pontos utilizada na etapa de segmentação, visando analisar se a quantidade de pontos por batimento interfere no desempenho das arquiteturas no cenário de classificação automática de arritmias. Vale ressaltar que a depender da quantidade de pontos utilizadas na segmentação, pode ser que ocorra perda de informações dos sinais de ECG.

Neste experimento, utilizou-se três tamanhos de segmentação: 230, 280 e 300 pontos por batimento. Estes tamanhos foram escolhidos por serem mais usuais nos trabalhos da literatura. As configurações do conjunto de dados (DS1.1 e DS1.2) e de treinamento são as mesmas utilizadas no experimento 4.2.1.

Os resultados apresentados na Tabela 11 mostram que os melhores resultados encontram-se na janela de 280 pontos. Nas arquiteturas de GCNs, a GCN7 apresentou o melhor resultado com 54% de F_S médio enquanto que a CNN-2Conv apresentou F_S médio de 63%. Observa-se um baixo desempenho das arquiteturas na classe S, sendo ainda um desafio de classificação para as arquiteturas analisadas. Em relação à quantidade de pontos, a GCN7 apresentou um aumento de desempenho de 20% e 1,87% no F_S médio quando comparado com a mesma arquitetura nas janelas de 230 e 300 pontos, respectivamente. A CNN-2Conv, por sua vez, apresentou um aumento de desempenho de 23,53% e 16,67% no F_S médio quando comparado com a mesma arquitetura nas janelas de 230 e 300 pontos, respectivamente. Portanto, a janela de 280 pontos é a melhor escolha para ser utilizada na etapa de segmentação.

Tabela 11 – Experimento 2: Resumo da performance das arquiteturas de GCNs e CNN no conjunto de validação (DS1.2) em relação ao tamanho de pontos na segmentação.

Arquiteturas	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	
230 pontos																	
GCN2	43,0	53,0	57,53	47,0	-	-	-	-	37,0	37,0	50,25	37,0	36,0	40,0	48,01	38,0	40,0
GCN7	49,0	45,0	33,63	47,0	5,0	3,0	14,07	4,0	48,0	59,0	48,62	53,0	44,0	46,0	38,04	45,0	46,0
CNN-2Conv	59,0	43,0	24,9	50,0	40,0	15,0	2,7	21,0	50,0	72,0	56,07	59,0	53,0	52,0	36,1	51,0	52,0
280 pontos																	
GCN2	47,0	62,0	58,26	53,0	-	-	-	-	40,0	36,0	43,02	38,0	39,0	44,0	45,08	41,0	44,0
GCN7	67,0	46,0	18,31	55,0	33,0	1,0	0,26	2,0	55,0	86,0	55,25	67,0	58,0	59,0	32,3	54,0	59,0
CNN-2Conv	82,0	50,0	8,89	62,0	43,0	16,0	2,64	23,0	60,0	94,0	48,83	73,0	70,0	65,0	25,69	63,0	65,0
300 pontos																	
GCN2	47,0	59,0	56,17	52,0	-	-	-	-	40,0	39,0	44,95	40,0	38,0	43,0	45,18	40,0	44,0
GCN7	72,0	40,0	12,76	52,0	-	-	0,19	-	54,0	92,0	60,75	68,0	56,0	58,0	32,4	53,0	59,0
CNN-2Conv	61,0	54,0	28,97	57,0	40,0	12,0	2,32	19,0	54,0	69,0	46,48	60,0	55,0	56,0	33,7	54,0	56,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Nota: valores em negrito indicam a melhor performance.

4.2.3 Experimento 3: Agregação de informações nos vértices de cada grafo

A possibilidade de agregação de informações nos grafos tanto pelos vértices quanto pelas arestas permite que sejam inseridas informações complementares e extrínsecas ao grafo, o que conseqüentemente, podem contribuir no aumento do desempenho das GCNs. O objetivo desta etapa é avaliar o desempenho das arquiteturas de GCNs diante a agregação de informações, focando principalmente nas informações extrínsecas ao grafo, visto que o objetivo das GCNs é extrair e aprender com as próprias estruturas dos grafos utilizadas durante o treinamento. A arquitetura de CNN não foi testada neste experimento.

Em vista disso, as informações agregadas em cada vértice foram agrupadas para um melhor entendimento dos experimentos e resultados que serão apresentados posteriormente, sendo eles:

- **II_V1**: valores dos pontos da derivação II, valores dos pontos da derivação V1 e o tempo de cada ponto (03 informações);
- **RR**: valores dos pontos da derivação II, valores dos pontos da derivação V1, intervalo RR predecessor, intervalo RR sucessor e o tempo de cada ponto (05 informações);
- **DifII**: valores dos pontos da derivação II, valores dos pontos da derivação V1, intervalo RR predecessor, intervalo RR sucessor, diferença dos valores dos pontos da derivação V1 pela derivação II e o tempo de cada ponto (06 informações);
- **AvgII**: valores dos pontos da derivação II, valores dos pontos da derivação V1, intervalo RR predecessor, intervalo RR sucessor, diferença dos valores dos pontos da derivação V1 pela derivação II, divisão dos valores dos pontos da derivação V1 pela média da derivação II e o tempo de cada ponto (07 informações);
- **StdII**: valores dos pontos da derivação II, valores dos pontos da derivação V1, intervalo RR predecessor, intervalo RR sucessor, diferença dos valores dos pontos da derivação V1 pela derivação II, divisão dos valores dos pontos da derivação V1 pela média da derivação II, divisão dos valores dos pontos da derivação V1 pelo desvio padrão da derivação II e o tempo de cada ponto (08 informações);
- **Stats**: valores dos pontos da derivação II, valores dos pontos da derivação V1, intervalo RR predecessor, intervalo RR sucessor, diferença dos valores dos pontos da derivação V1 pela derivação II, divisão dos valores dos pontos da derivação V1 pela média da derivação II, divisão dos valores dos pontos da derivação V1 pelo desvio padrão da derivação II, informações estatísticas (entropia, variância, desvio padrão, média, mediana, 5-percentil, 25-percentil, 75-percentil, 95-percentil, RMS¹⁰, *kurtosis*¹¹, *skewness*¹², *zero_crossings*¹³, *mean_crossings*¹⁴) dos valores dos pontos da derivação II e o tempo de cada ponto (22 informações).

As configurações do conjunto de dados e de treinamento são as mesmas utilizadas no experimento 4.2.1. A diferença é que nesta etapa, o conjunto de dados foi dividido em treinamento (DS1) e teste (DS2) pelo paradigma *inter-patient* apresentado na Tabela 5

¹⁰Raiz quadrada média

¹¹Mede a concentração ou dispersão de um conjunto de valores em relação às medidas de tendência central em uma distribuição Normal.

¹²Mede a assimetria de um conjunto de valores (distribuição)

¹³Mede o número de vezes que o sinal cruzou o eixo $y = 0$

¹⁴Mede o número de vezes que o sinal cruzou o eixo $y = \text{média}(y)$

da Seção 3.1. Utilizou-se a quantidade de 280 pontos na etapa de segmentação conforme resultados apresentados no experimento 4.2.2.

Antes da segmentação, vale ressaltar que os sinais de ECG passaram por uma etapa de normalização, utilizando a técnica conhecida como *z-score*. A normalização de um sinal é uma abordagem que busca equalizar seus níveis, conferindo-lhes uniformidade. No contexto desse procedimento, os parâmetros estatísticos média (μ) e desvio padrão (σ) foram empregados para o cálculo do *z-score*, como parte do processo¹⁵. A escolha estratégica dessa técnica *z-score* foi motivada pela sua capacidade de preservar a distribuição dos pontos nos próprios sinais de ECG, uma característica que inclui a manutenção dos pontos fiduciais. Considerando que os sinais de ECG podem abranger uma variedade de picos com magnitudes diversas, a aplicação de métodos baseados em distância ou em redes neurais pode ser desafiadora, principalmente devido a problemas associados à exploração de gradientes (SHOBANADEVI; VEERAMAKALI, 2023).

A Tabela 12 resume a performance das arquiteturas GCN2 e GCN7 de acordo com cada grupo de informações agregadas por meio do método VG. Para a arquitetura GCN2, os dois grupos de informações que apresentaram os melhores resultados foram o grupo RR e Stats com F_S médio de 68% e 73%, respectivamente. Para a arquitetura GCN7, os dois melhores grupos de informações foram o grupo AvgII e Stats com F_S médio de 77%.

A Tabela 13, por sua vez, resume a performance das arquiteturas GCN2 e GCN7 de acordo com cada grupo de informações agregadas por meio do método VVG. Para a arquitetura GCN2, os dois grupos de informações que apresentaram os melhores resultados foram o grupo RR e Stats com F_S médio de 68% e 74%, respectivamente. Nesta arquitetura, os resultados são similares nos dois métodos VG e VVG. Para a arquitetura GCN7, os dois melhores grupos de informações foram o grupo StdII e Stats com F_S médio de 68% e 74%, respectivamente.

O grupo com maior número de informações agregadas, o grupo Stats formado principalmente com informações estatísticas dos sinais de ECG que totaliza 22 informações, apresentou o melhor desempenho nas duas arquiteturas enquanto que no grupo menor de informações houve uma variação nas duas arquiteturas analisadas. O grupo RR totaliza cinco informações enquanto que o grupo AvgII totaliza sete informações. Portanto, tanto uma quantidade maior quanto uma quantidade menor de informações contribuíram de forma semelhante no aumento de desempenho das arquiteturas analisadas.

O desempenho diferencial das GCNs com os grupos de informações pode ser resultado de uma combinação de fatores, como a relevância das informações, a habilidade de capturar as características dos grupos, a complexidade das arquiteturas e as características específicas das arritmias sendo classificadas. Outro aspecto observado foi que nos grupos

¹⁵ $z = \frac{x - \mu}{\sigma}$, onde μ é a média e σ o desvio padrão dos pontos dos sinais de ECG.

Tabela 12 – Experimento 3: Resumo da performance das arquiteturas de GCNs no conjunto de teste (DS2) em relação a agregação de informações nos grafos utilizando o método VG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	
GCN2																	
II_V1	59,0	85,0	50,92	70,0	-	-	-	-	68,0	66,0	16,15	67,0	51,0	62,0	29,24	55,0	62,0
RR	74,0	94,0	28,63	83,0	52,0	2,0	0,52	5,0	77,0	91,0	14,25	83,0	71,0	75,0	18,3	68,0	75,0
DiffI	73,0	94,0	31,07	82,0	41,0	2,0	0,79	4,0	77,0	87,0	13,63	81,0	68,0	74,0	19,28	67,0	74,0
AvgII	73,0	93,0	30,65	82,0	37,0	2,0	0,77	4,0	75,0	87,0	14,55	81,0	67,0	73,0	19,39	66,0	73,0
StdII	73,0	92,0	29,9	81,0	48,0	1,0	0,38	3,0	74,0	88,0	16,2	80,0	68,0	73,0	19,53	66,0	73,0
Stats	75,0	94,0	27,61	84,0	50,0	12,0	2,85	19,0	85,0	92,0	8,32	88,0	74,0	77,0	16,26	73,0	77,0
GCN7																	
II_V1	62,0	85,0	46,31	72,0	31,0	5,0	2,89	9,0	82,0	78,0	8,51	80,0	63,0	67,0	25,06	62,0	67,0
RR	75,0	90,0	26,72	81,0	62,0	30,0	4,44	41,0	88,0	89,0	6,31	88,0	77,0	78,0	15,47	76,0	78,0
DiffI	76,0	88,0	24,07	82,0	60,0	29,0	4,68	39,0	86,0	93,0	7,73	89,0	76,0	78,0	14,76	76,0	78,0
AvgII	74,0	92,0	27,9	82,0	58,0	32,0	5,7	41,0	94,0	86,0	2,89	90,0	78,0	79,0	14,68	77,0	79,0
StdII	76,0	89,0	25,05	82,0	58,0	30,0	5,39	40,0	89,0	91,0	5,75	90,0	77,0	78,0	15,1	76,0	78,0
Stats	75,0	92,0	26,2	83,0	62,0	27,0	4,02	38,0	92,0	93,0	4,42	92,0	78,0	80,0	14,5	77,0	80,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Nota: valores em negrito indicam a melhor performance.

Tabela 13 – Experimento 3: Resumo da performance das arquiteturas de GCNs no conjunto de teste (DS2) em relação a agregação de informações nos grafos utilizando o método VVG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	
GCN2																	
II_V1	63,0	83,0	42,97	72,0	-	-	-	-	57,0	64,0	24,97	60,0	49,0	61,0	28,53	54,0	61,0
RR	75,0	92,0	26,91	82,0	52,0	2,0	0,39	3,0	74,0	92,0	16,33	82,0	70,0	75,0	18,18	68,0	75,0
DiffI	75,0	92,0	26,83	82,0	42,0	3,0	1,07	6,0	74,0	91,0	16,07	82,0	68,0	74,0	18,19	67,0	74,0
AvgII	74,0	92,0	27,53	82,0	29,0	1,0	0,8	3,0	74,0	91,0	16,37	81,0	66,0	74,0	18,56	67,0	74,0
StdII	75,0	91,0	27,17	82,0	27,0	3,0	1,94	5,0	74,0	89,0	16,17	81,0	65,0	73,0	18,54	67,0	73,0
Stats	76,0	93,0	25,98	84,0	48,0	18,0	4,63	26,0	86,0	90,0	7,51	88,0	74,0	77,0	15,57	74,0	77,0
GCN7																	
II_V1	71,0	85,0	30,59	77,0	29,0	2,0	1,27	4,0	65,0	82,0	22,51	73,0	61,0	68,0	22,16	61,0	68,0
RR	75,0	91,0	25,92	82,0	18,0	8,0	9,17	11,0	76,0	77,0	12,86	76,0	64,0	70,0	18,24	67,0	70,0
DiffI	76,0	90,0	25,41	82,0	21,0	12,0	11,49	15,0	76,0	73,0	11,79	75,0	65,0	69,0	18,09	67,0	69,0
AvgII	74,0	93,0	28,32	83,0	21,0	8,0	7,76	12,0	78,0	77,0	11,37	77,0	65,0	70,0	18,58	67,0	71,0
StdII	76,0	92,0	25,69	83,0	21,0	12,0	11,12	16,0	79,0	74,0	10,19	77,0	66,0	71,0	17,6	68,0	71,0
Stats	76,0	87,0	24,52	81,0	53,0	27,0	5,81	36,0	85,0	91,0	8,43	88,0	74,0	77,0	15,43	74,0	77,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Nota: valores em negrito indicam a melhor performance.

com melhor desempenho, as matrizes de confusão evidenciaram que as arquiteturas analisadas apresentavam uma tendência a classificar menos os batimentos arrítmicos como normais em comparação com os demais grupos.

4.2.4 Experimento 4: Inversão de conjuntos de dados DS1 e DS2

Após a divisão do conjunto de dados do MIT-BIH em conjunto de treinamento (DS1) e teste (DS2) pelo paradigma *inter-patient* (ver Tabela 7), observa-se que o conjunto DS2 apresenta mais batimentos da classe S em relação ao conjunto DS1. Por ser uma classe que apresenta baixo desempenho nas arquiteturas analisadas, este experimento analisa se

a inversão dos conjuntos de dados DS2 em treinamento e DS1 em teste pode melhorar o desempenho das arquiteturas GCNs e CNN na classe S.

As configurações de conjunto de dados e treinamento são as mesmas utilizadas no experimento 4.2.3. Apenas no treinamento da CNN que utilizou-se um conjunto de validação de 10% em relação ao conjunto DS2. Em relação às GCNs, utilizou-se apenas os conjuntos de treinamento (DS2) e teste (DS1). Nas arquiteturas de GCNs, utilizou-se os dois grupos de informações que apresentaram os melhores resultados no experimento 4.2.3 em cada arquitetura nos métodos de conversão VG e VVG.

A Tabela 14 resume a performance das arquiteturas em relação a inversão de conjuntos de dados DS1 e DS2 por meio do método VG. Nota-se que a inversão dos conjuntos de dados aumentou a performance na classe S em ambas arquiteturas. O aumento foi mais considerável nas métricas de Se e F_S das arquiteturas de GCNs, principalmente na arquitetura GCN7. Consequentemente, essa melhoria no desempenho da classe S influenciou na performance geral das arquiteturas, contribuindo para que o F_S médio geral aumentasse, variando de 75% a 84%.

A arquitetura GCN7 com o grupo de informações AvgII apresentou a melhor performance geral de 84% em relação a métrica F_S . Quando se compara o resultado desta arquitetura com o resultado da Tabela 12, a inversão do conjunto de dados contribuiu em um aumento de performance de 9,09%. Comparando os resultados da CNN-2Conv, percebe-se que também houve um aumento na performance da classe S e no desempenho geral. A Se e F_S da classe S aumentaram 153,33% e 193,75%, respectivamente, enquanto que o desempenho geral aumentou 20,31% na métrica F_S .

Analisando a performance das arquiteturas de GCNs em relação a inversão de conjuntos de dados DS1 e DS2 por meio do método VVG, os resultados da Tabela 15 mostram que apesar de não ter apresentado um aumento na performance da classe S, os desempenhos gerais na métrica F_S aumentaram em relação aos resultados da Tabela 13. Enquanto que na arquitetura GCN2, os grupos de informações RR e Stats apresentaram aumento de 11,76% e 5,4%, respectivamente, na arquitetura GCN7, os grupos de informações StdII e Stats apresentaram aumento de 5,88% e 8,10%, respectivamente. Quando compara-se a performance dos dois métodos VG e VVG nas Tabelas 14 e 15, o método VG performou melhor do que o método VVG. Portanto, a utilização de duas derivações na conversão dos sinais de ECG em grafos não contribuiu tanto quanto a utilização de uma derivação para o aumento de performance das arquiteturas analisadas no cenário de inversão de conjunto de dados.

Tabela 14 – Experimento 4: Resumo da performance das arquiteturas de GCNs e CNN em relação a inversão de conjuntos de dados DS1 e DS2 utilizando o método VG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	
GCN2																	
RR	82,0	85,0	18,66	83,0	27,0	27,0	8,33	27,0	79,0	74,0	13,57	77,0	75,0	75,0	15,54	75,0	75,0
Stats	89,0	84,0	10,38	86,0	39,0	50,0	8,72	44,0	90,0	90,0	7,18	90,0	84,0	83,0	8,91	83,0	83,0
GCN7																	
AvgII	86,0	90,0	14,22	88,0	63,0	57,0	3,74	60,0	85,0	83,0	9,64	84,0	83,0	84,0	11,3	84,0	84,0
Stats	86,0	84,0	12,7	85,0	55,0	51,0	4,68	53,0	83,0	88,0	12,52	85,0	82,0	82,0	11,81	82,0	82,0
CNN-2Conv																	
Sem inversão	64,0	67,0	33,28	65,0	18,0	15,0	16,54	16,0	88,0	90,0	6,44	89,0	63,0	65,0	20,92	64,0	65,0
Com inversão	86,0	73,0	11,45	79,0	62,0	38,0	2,57	47,0	74,0	95,0	23,3	83,0	79,0	78,0	15,37	77,0	78,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Tabela 15 – Experimento 4: Resumo da performance das arquiteturas de GCNs em relação a inversão de conjuntos de dados DS1 e DS2 utilizando o método VVG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	+P	Se	FPR	F _s	
GCN2																	
RR	87,0	91,0	13,1	89,0	9,0	2,0	2,71	4,0	74,0	84,0	19,92	79,0	74,0	84,0	14,82	76,0	79,0
Stats	82,0	81,0	16,76	82,0	20,0	21,0	9,35	20,0	88,0	89,0	7,96	89,0	79,0	78,0	12,43	78,0	78,0
GCN7																	
StdII	81,0	77,0	17,1	79,0	14,0	17,0	12,51	15,0	77,0	77,0	15,54	77,0	73,0	71,0	16,0	72,0	71,0
Stats	81,0	88,0	19,55	84,0	36,0	35,0	7,1	35,0	90,0	82,0	6,51	85,0	80,0	80,0	12,99	80,0	80,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

4.2.5 Experimento 5: Paradigma *intra-patient*

Em oposição ao paradigma *inter-patient*, o método *intra-patient* é analisado neste experimento. Enquanto que no paradigma *inter-patient* não há sobreposição de dados do mesmo paciente entre os conjuntos de treinamento e teste, no paradigma *intra-patient* os conjuntos de treinamento e teste podem apresentar dados de batimentos cardíacos do mesmo paciente nos dois conjuntos. Portanto, este experimento desempenha um papel comparativo entre o desempenho das arquiteturas nos dois paradigmas.

As configurações do conjunto de dados e de treinamento são as mesmas utilizadas no experimento 4.2.3 com a diferença de que o conjunto de treinamento e teste foram obtidos randomicamente. Logo, dados de um mesmo paciente pode estar tanto no conjunto de treinamento quanto no conjunto de teste.

Analisando os resultados da Tabela 16 em relação às GCNs e o método VG na arquitetura GCN2, enquanto que o grupo de informações RR apresentou uma queda de desempenho de 7,35% em relação ao desempenho do paradigma *inter-patient* apresentado na Tabela 12 na métrica F_s, o grupo de informações Stats apresentou um aumento de desempenho de 2,74%. Enquanto isso na arquitetura GCN7, os grupos de informações AvgII e Stats apresentaram aumento de 2,6% e 12,98% na métrica F_s. Comparando os dois paradigmas na arquitetura CNN-2Conv, nota-se que houve um aumento considerável

de desempenho tanto na classe S quanto no desempenho geral. No desempenho geral, o aumento na métrica F_S da CNN-2Conv foi de 50%.

Em relação o método VVG da Tabela 17, na arquitetura GCN2 os grupos de informações RR e Stats apresentaram queda de desempenho geral de 2,94% e 1,35%, respectivamente, em relação aos resultados da Tabela 13. Na arquitetura GCN7, em oposição à arquitetura GCN2, os grupos de informações StdII e Stats apresentaram aumento de 2,94% e 16,21% na métrica F_S , respectivamente.

Tabela 16 – Experimento 5: Resumo da performance das arquiteturas de GCNs e CNN em relação ao paradigma *intra-patient* utilizando o método VG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	
GCN2																	
RR	76,0	87,0	24,64	81,0	40,0	-	0,08	-	63,0	85,0	25,8	73,0	64,0	70,0	20,27	63,0	70,0
Stats	77,0	91,0	23,75	83,0	65,0	21,0	2,7	32,0	82,0	93,0	10,61	87,0	76,0	78,0	15,21	75,0	78,0
GCN7																	
AvgII	77,0	94,0	24,3	85,0	93,0	31,0	0,56	46,0	86,0	94,0	7,62	90,0	83,0	82,0	14,03	79,0	82,0
Stats	85,0	93,0	13,88	89,0	87,0	60,0	2,15	71,0	90,0	95,0	5,54	92,0	87,0	87,0	8,77	87,0	87,0
CNN-2Conv																	
Inter-patient	62,0	72,0	38,07	67,0	21,0	14,0	12,57	17,0	88,0	86,0	6,1	87,0	63,0	66,0	22,27	64,0	66,0
Intra-patient	95,0	97,0	4,11	96,0	94,0	90,0	1,4	92,0	99,0	98,0	0,69	98,0	96,0	96,0	2,42	96,0	96,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

Tabela 17 – Experimento 5: Resumo da performance das arquiteturas de GCNs em relação ao paradigma *intra-patient* utilizando o método VVG.

Informações	N				S				V				Média Ponderada				Acc
	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	
GCN2																	
RR	75,0	86,0	24,48	80,0	96,0	8,0	0,09	15,0	67,0	89,0	22,65	76,0	76,0	72,0	19,13	66,0	72,0
Stats	76,0	93,0	25,11	84,0	68,0	14,0	1,6	23,0	81,0	94,0	11,25	87,0	76,0	78,0	15,85	73,0	78,0
GCN7																	
StdII	75,0	87,0	25,45	81,0	81,0	18,0	1,06	30,0	70,0	85,0	18,75	77,0	74,0	73,0	18,45	70,0	73,0
Stats	87,0	91,0	11,67	89,0	80,0	62,0	3,81	69,0	88,0	94,0	6,61	91,0	86,0	86,0	8,43	86,0	86,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

De modo geral, os resultados enfatizam que o paradigma *intra-patient* apresenta melhores resultados em relação ao paradigma *inter-patient* no desempenho das arquiteturas analisadas, mesmo por não representar um cenário mais parecido ao mundo real, onde dados de um novo paciente não são utilizados durante o treinamento do modelo proposto.

Durante os experimentos, constatou-se que o método VVG apresenta uma alta complexidade computacional em termos de tempo e espaço, devido ao uso de duas derivações para mapear os sinais de ECG. Para resolver a complexidade de tempo, foram utilizadas estruturas de dados (organização dos códigos de programação) mais eficientes, o que permitiu mapear os batimentos de 280 pontos em aproximadamente 0,3 segundos. No entanto, a complexidade de espaço continua sendo um desafio tanto no mapeamento dos sinais de ECG quanto no processamento dos grafos gerados durante o treinamento e

teste. Embora tenha sido aplicado um balanceamento de dados para mitigar esse problema inicialmente, é necessário analisar outras soluções que permitam explorar todo o potencial das redes convolucionais de grafos.

4.2.6 Experimento 6: Comparação do método proposto

Neste último experimento, foi conduzida uma comparação entre o método proposto nesta dissertação e o estudo de Garcia et al. (2017) que utilizou um modelo SVM. A seleção desse estudo foi motivada pelo fato dele ser uma referência nesta dissertação, além de apresentar uma metodologia similar à proposta aqui. Para efetuar a comparação, o estudo realizado por Garcia et al. (2017) passou por algumas adaptações a fim de torná-lo comparável com a abordagem apresentada nesta dissertação. Uma das modificações envolveu a subamostragem de 10% da classe N, ou seja, de cada sequência de 10 batimentos, apenas o décimo foi selecionado. Além disso, utilizaram-se os mesmos conjuntos de dados DS1.1 e DS1.2, conforme detalhado na Tabela 9, para ajustar os parâmetros do modelo SVM. A comparação permeou três cenários:

- Garcia et al. (2017):
 - **Cenário 1:** características extraídas da rede de grafo baseada em redes complexas;
 - **Cenário 2:** características extraídas da rede de grafo baseada em redes complexas juntamente com características do intervalo RR;
 - **Cenário 3:** características extraídas da rede de grafo baseada em redes complexas, características do intervalo RR e características estatísticas da rede de grafos;
- **Método proposto:**
 - **Cenário 1:** experimento 3 da arquitetura GCN7 com as informações do grupo II_V1 e o método VG;
 - **Cenário 2:** experimento 3 da arquitetura GCN7 com as informações do grupo RR e o método VG;
 - **Cenário 3:** experimento 3 da arquitetura GCN7 com as informações do grupo Stats e o método VG;

Ao analisar os resultados apresentados na Tabela 18, nota-se que o método introduzido nesta dissertação exibiu um bom desempenho em comparação com o estudo realizado por Garcia et al. (2017). Tanto no cenário 1 como no cenário 2, observa-se que o método proposto supera em grande parte as expectativas, com exceção da classe N,

Tabela 18 – Experimento 6: Comparativo do método proposto com o trabalho de Garcia et al. (2017).

Cenários	Trabalho	N				S				V				Acc
		+P	Se	FPR	F_s	+P	Se	FPR	F_s	+P	Se	FPR	F_s	
Cenário 1	Garcia et al. (2017)	79,60	74,2	60,83	76,80	0,40	0,20	7,90	0,30	39,40	71,9	15,13	50,90	65,20
	Método proposto	62,0	85,0	46,31	71,47	31,0	5,0	2,89	8,61	82,0	78,0	8,51	79,95	67,0
Cenário 2	Garcia et al. (2017)	86,60	87,40	43,36	87,0	21,10	2,80	1,38	4,90	46,80	83,90	13,05	60,10	77,0
	Método proposto	75,0	90,0	26,72	81,81	62,0	30,0	4,44	40,43	88,0	89,0	6,31	88,50	78,0
Cenário 3	Garcia et al. (2017)	90,20	95,30	48,90	92,70	55,30	17,70	1,37	26,80	68,20	78,40	3,48	72,90	87,0
	Método proposto	78,0	92,0	26,20	84,82	62,0	27,0	4,02	37,62	92,0	93,0	4,42	92,49	80,0

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Acurácia \Rightarrow Acc e F1-score \Rightarrow F_s .

onde apresentou desempenho ligeiramente inferior nas métricas +P e F_s . No cenário 3, uma tendência semelhante é observada, com a classe N mostrando uma diminuição no desempenho em relação às métricas +P, Se e F_s . No entanto, é importante notar que no cenário 3, as características estatísticas da rede de grafos utilizadas pelo Garcia et al. (2017) são diferentes em relação às informações do método proposto. Mesmo considerando essa diferença, o comparativo foi realizado, permitindo assim uma avaliação aproximada do cenário proposto. Em relação às classes arrítmicas S e V, apenas a métrica FPR revelou um desempenho inferior para o método proposto em comparação com ao método de Garcia et al. (2017).

Uma observação relevante é que o método proposto apresentou um desempenho superior nas classes arrítmicas em comparação à classe normal (N). Isso ressalta a capacidade do método proposto de se destacar nas classes arrítmicas, um aspecto crucial no desenvolvimento de um método com aplicação clínica. Isso demonstra sua eficácia na diferenciação entre os batimentos cardíacos normais e arrítmicos, o que é fundamental para evitar o aumento de predições falsas. Este último é um desafio significativo quando se trata de aplicação clínica, pois diminui a confiabilidade do método. É importante notar que ainda existem espaços de aprimoramento, particularmente na classe S, onde o desempenho está abaixo das expectativas.

4.2.7 Decisões experimentais

Devido à resultados consistentes e com pouca variação entre as execuções iniciais, tanto em termos do desvio padrão quanto da média calculada das métricas de avaliação, os experimentos foram conduzidos uma única vez, abrangendo as etapas de treinamento e teste das arquiteturas exploradas. Essa conclusão foi alcançada por meio da realização de dois experimentos descritos na Tabela 19.

O experimento 1 relacionou-se à arquitetura GCN2 com o conjunto de informações Stats e o experimento 2 relacionou-se à arquitetura GCN7 com o conjunto de informações Stats, ambos apresentados na Subseção 4.2.3 com o método VG. Notou-se que o desvio padrão e a variância entre as métricas avaliadas não apresentaram valores significativamente

elevados. Cada experimento foi repetido dez vezes, com a semente (do inglês *seed*) sendo variada a cada execução durante a etapa de treinamento.¹⁶

Tabela 19 – Resultados da repetição de experimentos.

# Execução	Acc	+P	Se	FPR	F _s	Tempo (s)
Experimento 1: GCN2_Stats						
#1	77,56	74,62	77,56	16,33	72,17	5408
#2	77,33	73,41	77,33	16,07	72,78	5435
#3	78,05	75,50	78,04	16,21	72,84	5528
#4	77,40	73,84	77,40	16,41	72,56	5521
#5	77,70	74,29	77,70	16,04	72,96	5528
#6	77,80	74,41	77,80	15,98	73,05	5555
#7	77,37	73,64	77,37	16,23	72,32	5567
#8	77,48	73,50	77,48	15,95	72,90	5578
#9	76,88	72,77	76,88	16,20	72,75	5598
#10	77,48	73,71	77,48	16,22	72,48	5617
Média	77,50	73,97	77,51	16,16	72,68	5533
Desvio Padrão	0,003	0,007	0,003	0,14	0,003	63,53
Variância	8.8×10^{-6}	5.23×10^{-5}	8.8×10^{-6}	2×10^{-2}	7.5×10^{-6}	4.04×10^3
Experimento 2: GCN7_Stats						
#1	78,15	76,33	78,15	15,17	75,52	8124
#2	79,42	78,32	79,42	15,16	76,95	8174
#3	79,56	78,20	79,58	14,30	77,74	8290
#4	80,06	79,66	80,06	15,0	77,26	8337
#5	78,86	77,21	78,86	14,50	76,83	8390
#6	79,75	78,21	79,75	14,09	77,56	8370
#7	79,04	77,66	79,04	15,17	76,37	8378
#8	78,62	77,00	78,62	15,19	75,08	8395
#9	78,37	77,33	78,37	15,25	77,76	8462
#10	79,64	78,49	79,64	14,65	77,56	8437
Média	79,15	77,84	79,15	14,84	76,66	8335
Desvio Padrão	0,006	0,009	0,006	0,405	0,009	104,26
Variância	3.66×10^{-5}	7.90×10^{-5}	3.66×10^{-5}	1.6×10^{-1}	8×10^{-5}	1.09×10^4

Predição Positiva \Rightarrow +P, Sensibilidade \Rightarrow Se, Taxa de Falsos Positivos \Rightarrow FPR, F1-score \Rightarrow F_s e Acurácia \Rightarrow Acc.

A abordagem escolhida de uma execução por experimento foi adotada com base na observação de que múltiplas execuções não acrescentariam significativamente informações adicionais, dada a estabilidade dos resultados obtidos. Além disso, levou-se em consideração o substancial custo computacional envolvido em termos de espaço e tempo. Cada ciclo de execução demandava em média de duas a três horas, o que somado ao número de iterações necessárias para uma análise estatisticamente válida, tornaria o processo excessivamente oneroso em termos de recursos. Portanto, optou-se por uma única execução dos experimentos, embasada na confiabilidade das execuções preliminares e na necessidade de otimização dos recursos disponíveis.

¹⁶Para isso, utilizou-se o comando `TORCH.MANUAL_SEED(RANDOM.RANDINT(1,100000))` da biblioteca *torch*. A biblioteca *random* permitiu que a cada execução fosse gerado um número aleatório entre 1 e 100000.

5 Considerações finais

Neste capítulo serão apresentadas as conclusões obtidas nesta dissertação e, simultaneamente, serão apresentados os possíveis rumos a serem pesquisados sobre este campo de investigação. Ao longo desta dissertação, exploramos as representações dos sinais de ECG em grafos por meio dos métodos VG e VVG, com o intuito de avaliar se essa representação contribuiria no desempenho de classificação de arritmias por meio das redes convolucionais de grafos. Além disso, serão identificadas propostas de trabalho nos desafios que ainda subsistem, sinalizando direções promissoras para investigações futuras.

5.1 Conclusões

Esta dissertação propôs um método de classificação de arritmias em sinais de ECG, utilizando o mapeamento desses sinais em grafos e a classificação em nível de grafo com Redes Neurais Convolucionais de Grafos (GCNs), incorporando o paradigma *inter-patient* e as normas da AAMI. A pesquisa centralizou-se na seguinte questão: as representações em grafos dos sinais de ECG, por meio dos métodos VG e VVG, podem melhorar o desempenho da classificação de arritmias utilizando redes convolucionais de grafos? Para responder a essa pergunta, diversos experimentos foram conduzidos no conjunto de dados do MIT-BIH, envolvendo a construção de arquiteturas GCNs, análise de parâmetros de pré-processamento e a utilização dos paradigmas *inter-patient* e *intra-patient* na divisão dos dados.

A metodologia proposta consistiu em cinco etapas fundamentais: segmentação dos sinais de ECG em batimentos de tamanho fixo, balanceamento dos dados, divisão dos dados em conjuntos de treinamento e teste, conversão dos batimentos em grafos e classificação dos batimentos por meio das GCNs. Os experimentos realizados investigaram diferentes configurações em algumas dessas etapas, analisando o impacto no desempenho das arquiteturas propostas.

Os experimentos revelaram que arquiteturas mais simples de GCNs obtiveram melhores resultados em comparação com arquiteturas mais complexas. Isto sugere que a simplicidade das arquiteturas de GCNs permite uma melhor captura das características essenciais dos dados, evitando a incorporação de ruídos desnecessários. Além disso, arquiteturas mais simples tendem a ser computacionalmente mais eficientes, o que pode ser uma consideração crucial em cenários de recursos limitados.

A inclusão de informações extrínsecas nos grafos provou ser eficaz para melhorar o desempenho dos métodos VG e VVG, desde que sejam selecionadas informações que

capturem de forma mais precisa a morfologia dos sinais de ECG. Embora tanto o VG quanto o VVG tenham apresentado resultados promissores, o método VG se mostrou mais eficiente para as arquiteturas de GCNs exploradas.

O desafio de classificação na classe S ainda persiste nas arquiteturas analisadas, especialmente no paradigma *inter-patient*, mesmo quando a inversão dos conjuntos de dados DS1 e DS2 é aplicada. Por outro lado, o paradigma *intra-patient* alcançou melhores resultados, embora não reflita totalmente o cenário do mundo real. Em resumo, os resultados indicam que é possível classificar arritmias em sinais de ECG utilizando redes neurais convolucionais de grafos com os métodos VG e VVG para o mapeamento de sinais em grafos. O benefício percebido na metodologia proposta foi que as arquiteturas não necessitaram de pré-processamento e eliminação de ruído dos sinais ECG. No entanto, ainda há espaço para melhorias e pesquisas adicionais visando explorar todo o potencial das redes neurais de grafos.

Durante o desenvolvimento do método proposto, uma das limitações encontradas relaciona-se à complexidade computacional do método VVG no mapeamento dos sinais de ECG e no treinamento das redes convolucionais de grafos. Essa complexidade está relacionada tanto ao tempo de processamento quanto ao espaço exigido, exigindo estratégias para lidar com esse problema. Inicialmente, foram utilizadas estruturas de dados mais eficientes para reduzir o tempo de mapeamento dos sinais de ECG. Em relação ao espaço, o balanceamento de dados foi aplicado para diminuir a quantidade de grafos gerados, permitindo que os experimentos fossem realizados em um subconjunto dos dados. No entanto, outras alternativas ainda podem ser exploradas para lidar com esse desafio.

5.2 Trabalhos Futuros

Considerando a complexidade computacional do método VVG, investigações podem ser conduzidas no uso de tecnologias de processamento, como a aceleração de hardware por meio de GPUs. O desempenho das arquiteturas e dos métodos VG e VVG podem ser avaliados em outros conjuntos de dados recomendados pela AAMI. Pode-se ainda verificar o desempenho das arquiteturas e métodos VG e VVG utilizando o conjunto de dados MIT-BIH na etapa de treinamento e avaliá-los em outro conjunto de dados.

Ainda relacionado à complexidade do uso de grafos em classificação de arritmias, é válido um estudo da viabilidade da abordagem de grafos em infraestrutura computacional limitada. Isso envolveria a análise do tempo de processamento e os recursos necessários para criar, armazenar e manipular os grafos em comparação com os métodos tradicionais. A pesquisa também pode abordar a questão da eficiência da inferência, ponderando o tempo gasto para obter previsões utilizando representações de grafos em relação aos benefícios de desempenho obtidos.

Pode-se ainda, investigar a aplicação de estratégias de pré-processamento destinadas a lidar com conjuntos de dados altamente desequilibrados, através da adoção de técnicas de balanceamento bem como aplicação de filtros de ruído em sinais biológicos. Considerando que esta dissertação se concentrou em batimentos cardíacos únicos ao treinar as arquiteturas investigadas, uma direção alternativa seria a exploração de padrões de batimentos sequenciais, combinados com abordagens de seleção de atributos.

Dentre outras oportunidades, há possibilidades que incluem exploração de métodos alternativos para transformar séries temporais em estruturas de grafo, utilização de diferentes bibliotecas na construção das GCNs, utilização *fine-tuning* a partir de redes neurais pré-treinadas e a avaliação de métricas adaptadas que capturem de maneira mais eficaz o desequilíbrio presente nos conjuntos de dados. Por fim, um estudo que investigue uma abordagem híbrida entre GCNs e CNNs. A abordagem consideraria a aplicação das GCNs para capturar informações contextuais e topológicas contidas nos ECGs. Simultaneamente, as CNNs seriam empregadas para extrair informações dos padrões espaciais e temporais intrínsecos nos ECGs. As informações provenientes de ambas as fontes seriam integradas em um vetor unificado de características, que alimentará um classificador, tal como uma rede artificial profunda.

Referências

- ABIBULLAEV, B.; SEO, H. D. A new qrs detection method using wavelets and artificial neural networks. *Journal of medical systems*, Springer, v. 35, n. 4, p. 683–691, 2011. Citado na página 25.
- AGRAFIOTI, F.; HATZINAKOS, D. Ecg biometric analysis in cardiac irregularity conditions. *Signal, Image and Video Processing*, Springer, v. 3, n. 4, p. 329–343, 2009. Citado na página 30.
- AHMEDT-ARISTIZABAL, D. et al. Graph-based deep learning for medical diagnosis and analysis: past, present and future. *Sensors*, MDPI, v. 21, n. 14, p. 4758, 2021. Citado na página 44.
- AIELLO, W.; CHUNG, F.; LU, L. A random graph model for massive graphs. In: *Proceedings of the thirty-second annual ACM symposium on Theory of computing*. [S.l.: s.n.], 2000. p. 171–180. Citado na página 38.
- ALBERT, R.; JEONG, H.; BARABASI, A. L.(1999). diameter of the world-wide web. *Nature*, v. 401, n. 6,749, p. 130–131. Citado na página 39.
- ALI, O. M. A.; KAREEM, S. W.; MOHAMMED, A. S. Evaluation of electrocardiogram signals classification using cnn, svm, and lstm algorithm: A review. In: *IEEE. 2022 8th International Engineering Conference on Sustainable Technology and Development (IEC)*. [S.l.], 2022. p. 185–191. Citado na página 18.
- ANDAYESHGAR, B. et al. Developing graph convolutional networks and mutual information for arrhythmic diagnosis based on multichannel ecg signals. *International Journal of Environmental Research and Public Health*, MDPI, v. 19, n. 17, p. 10707, 2022. Citado na página 37.
- ANSI/AAMI. *Testing and Reporting Performance Results of Cardiac Rhythm and ST Segment Measurement Algorithms*. 2008. American National Standards Institute, Inc. (ANSI), Association for the Advancement of Medical Instrumentation (AAMI). ANSI/AAMI/ISO EC57, 1998-(R)2008. Citado 3 vezes nas páginas 17, 25 e 51.
- ASEERI, A. O. Uncertainty-aware deep learning-based cardiac arrhythmias classification model of electrocardiogram signals. *Computers*, MDPI, v. 10, n. 6, p. 82, 2021. Citado na página 36.
- ASPURU, J. et al. Segmentation of the ecg signal by means of a linear regression algorithm. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 4, p. 775, 2019. Citado na página 25.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, Elsevier, v. 42, n. 1, p. 54–67, 2009. Citado 2 vezes nas páginas 29 e 38.
- BALCAN, D. et al. Modeling the spatial spread of infectious diseases: The global epidemic and mobility computational model. *Journal of Computational Science*, v. 1, n. 3, p. 132–145, 2010. ISSN 1877-7503. Citado na página 39.

- BANERJEE, S.; MITRA, M. Application of cross wavelet transform for ecg pattern analysis and classification. *IEEE transactions on instrumentation and measurement*, IEEE, v. 63, n. 2, p. 326–333, 2013. Citado na página 29.
- BARABÁSI, A.-L. *Linked: The new science of networks*. 1st. ed. [S.l.]: American Association of Physics Teachers, 2003. Citado na página 39.
- BARABÁSI, A.-L. Network science. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society Publishing, v. 371, n. 1987, p. 20120375, 2013. Citado na página 38.
- BARABÁSI, A.-L. et al. *Linked: how everything is connected to everything else and what it means for business. Science, and Everyday Life*. Plume Books, v. 2, n. 6.3, p. 1, 2003. Citado na página 38.
- BEMMEL, J. V.; WILLEMS, J. Standardization and validation of medical decision-support systems: the cse project. *Methods of Information in Medicine*, Schattauer GmbH, v. 29, n. 04, p. 261–262, 1990. Citado na página 25.
- BERAZA, I.; ROMERO, I. Comparative study of algorithms for ecg segmentation. *Biomedical Signal Processing and Control*, Elsevier, v. 34, p. 166–173, 2017. Citado na página 25.
- BERKAYA, S. K. et al. A survey on ecg analysis. *Biomedical Signal Processing and Control*, Elsevier, v. 43, p. 216–235, 2018. Citado 8 vezes nas páginas 22, 24, 26, 27, 28, 30, 31 e 32.
- BHATIA, S. et al. Classification of electrocardiogram signals based on hybrid deep learning models. *Sustainability*, MDPI, v. 14, n. 24, p. 16572, 2022. Citado na página 36.
- BHIRUD, B.; PACHGHARE, V. Arrhythmia detection using ecg signal: a survey. In: SPRINGER. *Proceeding of International Conference on Computational Science and Applications*. [S.l.], 2020. p. 329–341. Citado na página 32.
- BLANCO-VELASCO, M.; WENG, B.; BARNER, K. E. Ecg signal denoising and baseline wander correction based on the empirical mode decomposition. *Computers in biology and medicine*, Elsevier, v. 38, n. 1, p. 1–13, 2008. Citado na página 22.
- BOJCHEVSKI, A. et al. Netgan: Generating graphs via random walks. In: PMLR. *International conference on machine learning*. [S.l.], 2018. p. 610–619. Citado na página 46.
- BOSS, M. et al. Network topology of the interbank market. *Quantitative finance*, Taylor & Francis, v. 4, n. 6, p. 677–684, 2004. Citado na página 39.
- BRUNA, J. et al. Spectral networks and locally connected networks on graphs. *arXiv preprint arXiv:1312.6203*, 2013. Citado na página 46.
- CAI, W.; HU, D. Qrs complex detection using novel deep learning neural networks. *IEEE Access*, IEEE, v. 8, p. 97082–97089, 2020. Citado na página 25.
- CAO, D. et al. Spectral temporal graph neural network for multivariate time-series forecasting. *Advances in neural information processing systems*, v. 33, p. 17766–17778, 2020. Citado na página 37.

- CAO, M. et al. Ecg heartbeat classification using deep transfer learning with convolutional neural network and stft technique. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2023. v. 2547, n. 1, p. 012031. Citado na página 36.
- CAO, N. D.; KIPF, T. Molgan: An implicit generative model for small molecular graphs. *arXiv preprint arXiv:1805.11973*, 2018. Citado na página 46.
- CAO, S.; LU, W.; XU, Q. Deep neural networks for learning graph representations. In: *Proceedings of the AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2016. v. 30, n. 1. Citado na página 46.
- CHAZAL, P. D.; O'DWYER, M.; REILLY, R. B. Automatic classification of heartbeats using ecg morphology and heartbeat interval features. *IEEE transactions on biomedical engineering*, IEEE, v. 51, n. 7, p. 1196–1206, 2004. Citado 5 vezes nas páginas 17, 18, 34, 52 e 55.
- CHEN, S. et al. Heartbeat classification using projected and dynamic features of ecg signal. *Biomedical Signal Processing and Control*, Elsevier, v. 31, p. 165–173, 2017. Citado na página 28.
- CHENG, P.; DONG, X. Life-threatening ventricular arrhythmia detection with personalized features. *IEEE access*, IEEE, v. 5, p. 14195–14203, 2017. Citado na página 16.
- CHIANG, W.-L. et al. Cluster-gcn: An efficient algorithm for training deep and large graph convolutional networks. In: *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*. [S.l.: s.n.], 2019. p. 257–266. Citado na página 46.
- CHOI, S. et al. Performance improvement of deep learning based multi-class ecg classification model using limited medical dataset. *IEEE Access*, IEEE, 2023. Citado na página 36.
- ÇINAR, A.; TUNCER, S. A. Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ecg signals using lstm and hybrid cnn-svm deep neural networks. *Computer methods in biomechanics and biomedical engineering*, Taylor & Francis, v. 24, n. 2, p. 203–214, 2021. Citado na página 18.
- CLIFFORD, G. D. et al. *Advanced methods and tools for ECG data analysis*. [S.l.]: Artech house Boston, 2006. v. 10. Citado na página 21.
- COHEN, A. *Biomedical Signal Processing: Compression and automatic recognition*. 1st. ed. [S.l.]: CRC Press, 1986. Citado 2 vezes nas páginas 16 e 20.
- COLIZZA, V. et al. Predictability and epidemic pathways in global outbreaks of infectious diseases: the sars case study. *BMC medicine*, Springer, v. 5, n. 1, p. 1–13, 2007. Citado na página 39.
- DAAMOUCHE, A. et al. A wavelet optimization approach for ecg signal classification. *Biomedical Signal Processing and Control*, Elsevier, v. 7, n. 4, p. 342–349, 2012. Citado na página 28.

- DAI, H. et al. Learning steady-states of iterative algorithms over graphs. In: PMLR. *International conference on machine learning*. [S.l.], 2018. p. 1106–1114. Citado na página 46.
- DAS, H. S.; ROY, P. Chapter 5 - a deep dive into deep learning techniques for solving spoken language identification problems. In: DEY, N. (Ed.). *Intelligent Speech Signal Processing*. 1st. ed. Academic Press, 2019. p. 81–100. ISBN 978-0-12-818130-0. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B978012818130000052>>. Citado 2 vezes nas páginas 32 e 33.
- DEFFERRARD, M.; BRESSON, X.; VANDERGHEYNST, P. Convolutional neural networks on graphs with fast localized spectral filtering. *Advances in neural information processing systems*, v. 29, 2016. Citado na página 46.
- DIAS, F. M. et al. Arrhythmia classification from single-lead ecg signals using the inter-patient paradigm. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 202, p. 105948, 2021. Citado 2 vezes nas páginas 27 e 28.
- DIKER, A. et al. A new technique for ecg signal classification genetic algorithm wavelet kernel extreme learning machine. *Optik*, Elsevier, v. 180, p. 46–55, 2019. Citado na página 31.
- DO, K.; TRAN, T.; VENKATESH, S. Graph transformation policy network for chemical reaction prediction. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. [S.l.: s.n.], 2019. p. 750–760. Citado na página 44.
- DONGES, J. F. et al. Nonlinear detection of paleoclimate-variability transitions possibly related to human evolution. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 108, n. 51, p. 20422–20427, 2011. Citado na página 41.
- DONNER, R. V. et al. Recurrence networks—a novel paradigm for nonlinear time series analysis. *New Journal of Physics*, IOP Publishing, v. 12, n. 3, p. 033025, 2010. Citado na página 41.
- DOYE, J. P. Network topology of a potential energy landscape: A static scale-free network. *Physical review letters*, APS, v. 88, n. 23, p. 238701, 2002. Citado na página 38.
- ELHAJ, F. A. et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ecg signals. *Computer methods and programs in biomedicine*, Elsevier, v. 127, p. 52–63, 2016. Citado na página 32.
- ERDŐS, P.; RÉNYI, A. et al. On the evolution of random graphs. *Publ. Math. Inst. Hung. Acad. Sci.*, v. 5, n. 1, p. 17–60, 1960. Citado na página 38.
- ERGIN, S. et al. Ecg based biometric authentication using ensemble of features. In: IEEE. *2014 9th Iberian Conference on Information Systems and Technologies (CISTI)*. [S.l.], 2014. p. 1–6. Citado na página 30.
- ESSA, E.; XIE, X. An ensemble of deep learning-based multi-model for ecg heartbeats arrhythmia classification. *IEEE Access*, IEEE, v. 9, p. 103452–103464, 2021. Citado 2 vezes nas páginas 35 e 36.

FALOUTSOS, M.; FALOUTSOS, P.; FALOUTSOS, C. On power-law relationships of the internet topology. *ACM SIGCOMM computer communication review*, ACM New York, NY, USA, v. 29, n. 4, p. 251–262, 1999. Citado na página 38.

FOUT, A. M. *Protein interface prediction using graph convolutional networks*. Tese (Doutorado) — Colorado State University, 2017. Citado na página 44.

FREITAS, V. L.; LACERDA, J. C.; MACAU, E. E. Complex networks approach for dynamical characterization of nonlinear systems. *International Journal of Bifurcation and Chaos*, World Scientific, v. 29, n. 13, p. 1950188, 2019. Citado na página 38.

FREITAS, V. L. D. S. et al. The correspondence between the structure of the terrestrial mobility network and the spreading of covid-19 in brazil. *Cadernos de Saude Publica*, v. 36, p. 1–12, 2020. ISSN 16784464. Citado na página 39.

FREITAS, V. L. S.; MOREIRA, G. J. P.; SANTOS, L. B. L. Robustness analysis in an inter-cities mobility network: modeling municipal, state and federal initiatives as failures and attacks. *PeerJ*, v. 8, p. 1–15, 2020. Citado na página 39.

GACEK, A. Data structure-guided development of electrocardiographic signal characterization and classification. *Artificial intelligence in medicine*, Elsevier, v. 59, n. 3, p. 197–204, 2013. Citado na página 31.

GAI, N. D. Ecg beat classification using machine learning and pre-trained convolutional neural networks. *arXiv preprint arXiv:2207.06408*, 2022. Citado na página 36.

GALLICCHIO, C.; MICHELI, A. Graph echo state networks. In: IEEE. *The 2010 international joint conference on neural networks (IJCNN)*. [S.l.], 2010. p. 1–8. Citado na página 46.

GARCIA, G. et al. Improving automatic cardiac arrhythmia classification: Joining temporal-vcg, complex networks and svm classifier. In: IEEE. *2016 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2016. p. 3896–3900. Citado na página 30.

GARCIA, G. et al. Inter-patient ecg heartbeat classification with temporal vcg optimized by pso. *Scientific reports*, Nature Publishing Group, v. 7, n. 1, p. 1–11, 2017. Citado 8 vezes nas páginas 13, 16, 30, 31, 38, 57, 70 e 71.

GHONGADE, R. et al. A brief performance evaluation of ecg feature extraction techniques for artificial neural network based classification. In: IEEE. *TENCON 2007-2007 IEEE Region 10 Conference*. [S.l.], 2007. p. 1–4. Citado na página 24.

GOTODA, H. et al. Characterization of combustion dynamics, detection, and prevention of an unstable combustion state based on a complex-network theory. *Physical Review Applied*, APS, v. 7, n. 4, p. 044027, 2017. Citado na página 41.

GRANOVETTER, M. S. The strength of weak ties. *American journal of sociology*, University of Chicago Press, v. 78, n. 6, p. 1360–1380, 1973. Citado na página 38.

GUIMERA, R.; AMARAL, L. A. N. Modeling the world-wide airport network. *The European Physical Journal B*, Springer, v. 38, n. 2, p. 381–385, 2004. Citado na página 39.

- GÜLER, İ.; ÜBEYLI, E. D. Ecg beat classifier designed by combined neural network model. *Pattern recognition*, Elsevier, v. 38, n. 2, p. 199–208, 2005. Citado 2 vezes nas páginas 29 e 33.
- GUO, M. et al. Neural graph matching networks for fewshot 3d action recognition. In: *Proceedings of the European conference on computer vision (ECCV)*. [S.l.: s.n.], 2018. p. 653–669. Citado na página 37.
- GUO, S. et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting. In: *Proceedings of the AAAI conference on artificial intelligence*. [S.l.: s.n.], 2019. v. 33, n. 01, p. 922–929. Citado na página 37.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of machine learning research*, v. 3, n. Mar, p. 1157–1182, 2003. Citado na página 31.
- HAGBERG, A. A.; SCHULT, D. A.; SWART, P. J. Exploring network structure, dynamics, and function using networkx. In: VAROQUAUX, G.; VAUGHT, T.; MILLMAN, J. (Ed.). *Proceedings of the 7th Python in Science Conference*. Pasadena, CA USA: [s.n.], 2008. p. 11 – 15. Citado na página 58.
- HAMILTON, W. L.; YING, R.; LESKOVEC, J. Inductive representation learning on large graphs. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*. [S.l.: s.n.], 2017. p. 1025–1035. Citado na página 48.
- HAMMAD, M. et al. Detection of abnormal heart conditions based on characteristics of ecg signals. *Measurement*, Elsevier, v. 125, p. 634–644, 2018. Citado na página 32.
- HANNUN, A. Y. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, Nature Publishing Group, v. 25, n. 1, p. 65, 2019. Citado 5 vezes nas páginas 17, 18, 24, 34 e 36.
- HASSAN, A. R.; HAQUE, M. A. An expert system for automated identification of obstructive sleep apnea from single-lead ecg using random under sampling boosting. *Neurocomputing*, Elsevier, v. 235, p. 122–130, 2017. Citado na página 29.
- HE, Z. et al. A novel unsupervised domain adaptation framework based on graph convolutional network and multi-level feature alignment for inter-subject ecg classification. *Expert Systems with Applications*, Elsevier, v. 221, p. 119711, 2023. Citado na página 37.
- HENAFF, M.; BRUNA, J.; LECUN, Y. Deep convolutional networks on graph-structured data. *arXiv preprint arXiv:1506.05163*, 2015. Citado na página 46.
- HERMES, R. E.; GESELOWITZ, D. B.; OLIVER, G. C. Development, distribution, and use of the american heart association database for ventricular arrhythmia detector evaluation. *Computers in cardiology*, p. 263–266, 1980. Citado na página 25.
- HUANG, F. et al. Predicting ct-based coronary artery disease using vascular biomarkers derived from fundus photographs with a graph convolutional neural network. *Diagnostics*, Multidisciplinary Digital Publishing Institute, v. 12, n. 6, p. 1390, 2022. Citado na página 37.
- HUGHES, N.; TARASSENKO, L.; ROBERTS, S. J. Markov models for automated ecg interval analysis. *Advances in Neural Information Processing Systems*, v. 16, 2003. Citado na página 25.

- INCE, T.; KIRANYAZ, S.; GABBOUJ, M. A generic and robust system for automated patient-specific classification of ecg signals. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 56, n. 5, p. 1415–1426, 2009. Citado na página 33.
- IZCI, E. et al. Cardiac arrhythmia detection from 2d ecg images by using deep learning technique. In: IEEE. *2019 Medical Technologies Congress (TIPTEKNO)*. [S.l.], 2019. p. 1–4. Citado na página 36.
- JAIN, A. et al. Structural-rnn: Deep learning on spatio-temporal graphs. In: *Proceedings of the iee conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 5308–5317. Citado na página 46.
- JAIN, S.; BAJAJ, V.; KUMAR, A. Riemann liouville fractional integral based empirical mode decomposition for ecg denoising. *IEEE journal of biomedical and health informatics*, IEEE, v. 22, n. 4, p. 1133–1139, 2017. Citado na página 23.
- JEONG, H. et al. The large-scale organization of metabolic networks. *Nature*, Nature Publishing Group, v. 407, n. 6804, p. 651–654, 2000. Citado na página 38.
- JHA, C. K.; KOLEKAR, M. H. Cardiac arrhythmia classification using tunable q-wavelet transform based features and support vector machine classifier. *Biomedical Signal Processing and Control*, Elsevier, v. 59, p. 101875, 2020. Citado na página 32.
- JHA, C. K.; KOLEKAR, M. H. Tunable q-wavelet based ecg data compression with validation using cardiac arrhythmia patterns. *Biomedical Signal Processing and Control*, Elsevier, v. 66, p. 102464, 2021. Citado na página 29.
- JIN, Z. et al. Sparse ecg denoising with generalized minimax concave penalty. *Sensors*, MDPI, v. 19, n. 7, p. 1718, 2019. Citado 2 vezes nas páginas 22 e 23.
- KANTARDZIC, M. *Data mining: concepts, models, methods, and algorithms*. 2nd. ed. [S.l.]: John Wiley & Sons, 2011. Citado na página 31.
- KAYA, Y.; PEHLIVAN, H.; TENEKECI, M. Effective ecg beat classification using higher order statistic features and genetic feature selection. *BIOMEDICAL RESEARCH-INDIA*, v. 28, n. 17, 2017. Citado na página 31.
- KHUSHABA, R. N. et al. Driver drowsiness classification using fuzzy wavelet-packet-based feature-extraction algorithm. *IEEE transactions on biomedical engineering*, IEEE, v. 58, n. 1, p. 121–131, 2010. Citado na página 31.
- KIPF, T. N.; WELLING, M. Semi-supervised classification with graph convolutional networks. *arXiv:1609.02907*, 2016. Citado 3 vezes nas páginas 46, 47 e 48.
- KIPF, T. N.; WELLING, M. Variational graph auto-encoders. *arXiv preprint arXiv:1611.07308*, 2016. Citado na página 46.
- KOHLER, B.-U.; HENNIG, C.; ORGLMEISTER, R. The principles of software qrs detection. *IEEE Engineering in Medicine and biology Magazine*, IEEE, v. 21, n. 1, p. 42–57, 2002. Citado na página 25.
- KOJIMA, R. et al. kgcn: a graph-based deep learning framework for chemical structures. *Journal of Cheminformatics*, Springer, v. 12, n. 1, p. 1–10, 2020. Citado na página 55.

- KUMAR, M.; PACHORI, R. B.; ACHARYA, U. R. Characterization of coronary artery disease using flexible analytic wavelet transform applied on ecg signals. *Biomedical signal processing and control*, Elsevier, v. 31, p. 301–308, 2017. Citado na página 29.
- KUTLU, Y.; KUNTALP, D. Feature extraction for ecg heartbeats using higher order statistics of wpd coefficients. *Computer methods and programs in biomedicine*, Elsevier, v. 105, n. 3, p. 257–267, 2012. Citado na página 28.
- LACASA, L. et al. From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 105, n. 13, p. 4972–4975, 2008. Citado 2 vezes nas páginas 41 e 42.
- LAGUNA, P. et al. A database for evaluation of algorithms for measurement of qt and other waveform intervals in the ecg. In: IEEE. *Computers in cardiology 1997*. [S.l.], 1997. p. 673–676. Citado na página 25.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Ieee, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 45.
- LI, G. et al. Effective graph classification based on topological and label attributes. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, Wiley Online Library, v. 5, n. 4, p. 265–283, 2012. Citado na página 29.
- LI, H. et al. Genetic algorithm for the optimization of features and neural networks in ecg signals classification. *Scientific reports*, Nature Publishing Group, v. 7, n. 1, p. 1–12, 2017. Citado na página 29.
- LI, M.; CHEN, H.; CHENG, Z. An attention-guided spatiotemporal graph convolutional network for sleep stage classification. *Life*, MDPI, v. 12, n. 5, p. 622, 2022. Citado na página 37.
- LI, S.-F.; HUANG, M.-L.; WU, Y.-S. Combining the taguchi method and convolutional neural networks for arrhythmia classification by using ecg images with single heartbeats. *Mathematics*, MDPI, v. 11, n. 13, p. 2841, 2023. Citado na página 36.
- LI, Y. et al. Gated graph sequence neural networks. *arXiv preprint arXiv:1511.05493*, 2015. Citado na página 46.
- LI, Y. et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. *arXiv preprint arXiv:1707.01926*, 2017. Citado na página 46.
- LIN, C.-H.; DU, Y.-C.; CHEN, T. Adaptive wavelet network for multiple cardiac arrhythmias recognition. *Expert Systems with Applications*, Elsevier, v. 34, n. 4, p. 2601–2611, 2008. Citado na página 28.
- LIPTON, Z. C.; ELKAN, C.; NARAYANASWAMY, B. Thresholding classifiers to maximize f1 score. *arXiv preprint arXiv:1402.1892*, 2014. Citado na página 54.
- LIU, Z. et al. Geniepath: Graph neural networks with adaptive receptive paths. In: *Proceedings of the AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2019. v. 33, n. 01, p. 4424–4431. Citado na página 46.
- LUQUE, B. et al. Horizontal visibility graphs: Exact results for random time series. *Physical Review E*, APS, v. 80, n. 4, p. 046103, 2009. Citado na página 41.

- LUZ, E.; MENOTTI, D. How the choice of samples for building arrhythmia classifiers impact their performances. In: IEEE. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.], 2011. p. 4988–4991. Citado 2 vezes nas páginas 17 e 52.
- LUZ, E. J. d. S. et al. Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer methods and programs in biomedicine*, Elsevier, v. 127, p. 144–164, 2016. Citado 13 vezes nas páginas 16, 17, 20, 21, 22, 25, 26, 27, 28, 29, 32, 51 e 53.
- MA, H.; XIA, L. Atrial fibrillation detection algorithm based on graph convolution network. *IEEE Access*, IEEE, 2023. Citado na página 37.
- MA, T.; CHEN, J.; XIAO, C. Constrained generation of semantically valid graphs via regularizing variational autoencoders. *Advances in Neural Information Processing Systems*, v. 31, 2018. Citado na página 46.
- MADAN, P. et al. A hybrid deep learning approach for ecg-based arrhythmia classification. *Bioengineering*, MDPI, v. 9, n. 4, p. 152, 2022. Citado na página 36.
- MALLAT, S. *A wavelet tour of signal processing*. 2nd. ed. [S.l.]: Elsevier, 1999. Citado na página 28.
- MARK, B. *Nexus: Small Worlds and the Groundbreaking Science of Networks*. 1st. ed. [S.l.]: WW Norton, New York, 2002. Citado na página 39.
- MATHEWS, S. M.; KAMBHAMETTU, C.; BARNER, K. E. A novel application of deep learning for single-lead ecg classification. *Computers in biology and medicine*, Elsevier, v. 99, p. 53–62, 2018. Citado na página 36.
- MATHUR, P.; CHAKKA, V. K. Graph signal processing of eeg signals for detection of epilepsy. In: IEEE. *2020 7th International Conference on Signal Processing and Integrated Networks (SPIN)*. [S.l.], 2020. p. 839–843. Citado na página 37.
- MATHUR, S. *Neural Network in Matlab*. GitHub, 2020. Disponível em: <<https://github.com/sammathur4/Neural-Network-in-Matlab>>. Citado na página 33.
- MCSHARRY, P. E. et al. A dynamical model for generating synthetic electrocardiogram signals. *IEEE transactions on biomedical engineering*, IEEE, v. 50, n. 3, p. 289–294, 2003. Citado na página 20.
- MICHELI, A. Neural network for graphs: A contextual constructive approach. *IEEE Transactions on Neural Networks*, IEEE, v. 20, n. 3, p. 498–511, 2009. Citado na página 45.
- MONDÉJAR-GUERRA, V. et al. Heartbeat classification fusing temporal and morphological information of ecgs via ensemble of classifiers. *Biomedical Signal Processing and Control*, Elsevier, v. 47, p. 41–48, 2019. Citado na página 24.
- MOODY, G. B.; MARK, R. G. The mit-bih arrhythmia database on cd-rom and software for use with it. In: IEEE. *[1990] Proceedings Computers in Cardiology*. [S.l.], 1990. p. 185–188. Citado 2 vezes nas páginas 25 e 51.

- MOODY, G. B.; MARK, R. G. The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 20, n. 3, p. 45–50, 2001. Citado 2 vezes nas páginas 25 e 51.
- MOSKALENKO, V.; ZOLOTYKH, N.; OSIPOV, G. Deep learning for ecg segmentation. In: SPRINGER. *international conference on Neuroinformatics*. [S.l.], 2019. p. 246–254. Citado na página 25.
- MOUSAVI, S.; AFGHAH, F. Inter-and intra-patient ecg heartbeat classification for arrhythmia detection: a sequence to sequence deep learning approach. In: IEEE. *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.], 2019. p. 1308–1312. Citado 4 vezes nas páginas 25, 35, 36 e 61.
- MUELLER, T. T. et al. Differentially private graph classification with gnns. *arXiv preprint arXiv:2202.02575*, 2022. Citado na página 37.
- NEWMAN, M. E. The structure and function of complex networks. *SIAM review*, SIAM, v. 45, n. 2, p. 167–256, 2003. Citado na página 39.
- NIELSEN, J. B. et al. Risk of atrial fibrillation as a function of the electrocardiographic pr interval: results from the copenhagen ecg study. *Heart Rhythm*, Elsevier, v. 10, n. 9, p. 1249–1256, 2013. Citado na página 27.
- NURMAINI, S. et al. Deep learning-based stacked denoising and autoencoder for ecg heartbeat classification. *Electronics*, MDPI, v. 9, n. 1, p. 135, 2020. Citado na página 36.
- OLIVEIRA, R. F. et al. Um método ensemble para classificação de arritmias: Uma avaliação com mais de 10 mil registros de sinais de ecg. In: SBC. *Anais do XXII Simpósio Brasileiro de Computação Aplicada à Saúde*. [S.l.], 2022. p. 13–24. Citado 2 vezes nas páginas 19 e 50.
- OLIVEIRA, R. F. et al. Explorando redes neurais de grafos para classificação de arritmias. In: SBC. *Anais do XXII Simpósio Brasileiro de Computação Aplicada à Saúde*. [S.l.], 2022. p. 178–189. Citado 2 vezes nas páginas 19 e 50.
- OSOWSKI, S.; MARKIEWICZ, T.; HOAI, L. T. Recognition and classification system of arrhythmia using ensemble of neural networks. *Measurement*, Elsevier, v. 41, n. 6, p. 610–617, 2008. Citado na página 33.
- ÖZBAY, Y.; CEYLAN, R.; KARLIK, B. A fuzzy clustering neural network architecture for classification of ecg arrhythmias. *Computers in Biology and Medicine*, Elsevier, v. 36, n. 4, p. 376–388, 2006. Citado na página 33.
- OZPOLAT, Z.; KARABATAK, M. Performance evaluation of quantum-based machine learning algorithms for cardiac arrhythmia classification. *Diagnostics*, MDPI, v. 13, n. 6, p. 1099, 2023. Citado na página 36.
- PADHY, S.; DANDAPAT, S. Third-order tensor based analysis of multilead ecg for classification of myocardial infarction. *Biomedical Signal Processing and Control*, Elsevier, v. 31, p. 71–78, 2017. Citado na página 29.
- PAGANI, G. A.; AIELLO, M. The power grid as a complex network: a survey. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 392, n. 11, p. 2688–2700, 2013. Citado na página 38.

- PAN, J.; TOMPKINS, W. J. A real-time qrs detection algorithm. *IEEE transactions on biomedical engineering*, IEEE, n. 3, p. 230–236, 1985. Citado na página 25.
- PAN, S. et al. Adversarially regularized graph autoencoder for graph embedding. *arXiv preprint arXiv:1802.04407*, 2018. Citado na página 46.
- PANDEY, S. K.; JANGHEL, R. R. Automatic detection of arrhythmia from imbalanced ecg database using cnn model with smote. *Australasian physical & engineering sciences in medicine*, Springer, v. 42, n. 4, p. 1129–1139, 2019. Citado na página 16.
- PANDEY, S. K.; JANGHEL, R. R.; VANI, V. Patient specific machine learning models for ecg signal classification. *Procedia Computer Science*, Elsevier, v. 167, p. 2181–2190, 2020. Citado 2 vezes nas páginas 27 e 32.
- PASZKE, A. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: WALLACH, H. et al. (Ed.). *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019. p. 8024–8035. Disponível em: <<http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>>. Citado na página 58.
- PEIMANKAR, A.; PUTHUSSERYPADY, S. Dens-ecg: A deep learning approach for ecg signal delineation. *Expert systems with applications*, Elsevier, v. 165, p. 113911, 2021. Citado na página 24.
- PLAWIAK, P.; ACHARYA, U. R. Novel deep genetic ensemble of classifiers for arrhythmia detection using ecg signals. *Neural Computing and Applications*, Springer, v. 32, n. 15, p. 11137–11161, 2020. Citado na página 36.
- POLI, R.; CAGNONI, S.; VALLI, G. Genetic design of optimum linear and nonlinear qrs detectors. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 42, n. 11, p. 1137–1141, 1995. Citado na página 25.
- POUNGPONSRI, S.; YU, X.-H. An adaptive filtering approach for electrocardiogram (ecg) signal noise reduction using neural networks. *Neurocomputing*, Elsevier, v. 117, p. 206–213, 2013. Citado na página 24.
- QUEIROZ, V. et al. Automatic cardiac arrhythmia detection and classification using vectorcardiograms and complex networks. In: IEEE. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2015. p. 5203–5206. Citado na página 29.
- RAJ, S.; RAY, K. C. Ecg signal analysis using dct-based dost and pso optimized svm. *IEEE Transactions on instrumentation and measurement*, IEEE, v. 66, n. 3, p. 470–478, 2017. Citado na página 27.
- RAJESH, K. N.; DHULI, R. Classification of ecg heartbeats using nonlinear decomposition methods and support vector machine. *Computers in biology and medicine*, Elsevier, v. 87, p. 271–284, 2017. Citado na página 32.
- RAJPURKAR, P. et al. Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv:1707.01836*, 2017. Citado na página 24.

- RAKSHIT, M.; DAS, S. An efficient ecg denoising methodology using empirical mode decomposition and adaptive switching mean filter. *Biomedical signal processing and control*, Elsevier, v. 40, p. 140–148, 2018. Citado na página 24.
- RAMKUMAR, M. et al. Ecg cardiac arrhythmias classification using dwt, ica and mlp neural networks. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2021. v. 1831, n. 1, p. 012015. Citado na página 32.
- REN, W.; JIN, N. Vector visibility graph from multivariate time series: a new method for characterizing nonlinear dynamic behavior in two-phase flow. *Nonlinear Dynamics*, Springer, v. 97, p. 2547–2556, 2019. Citado 5 vezes nas páginas 40, 41, 43, 44 e 58.
- SAI, Y. P. et al. A review on arrhythmia classification using ecg signals. In: IEEE. *2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*. [S.l.], 2020. p. 1–6. Citado na página 32.
- SAMENI, R. et al. A nonlinear bayesian filtering framework for ecg denoising. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 54, n. 12, p. 2172–2185, 2007. Citado na página 24.
- SANNINO, G.; PIETRO, G. D. A deep learning approach for ecg-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems*, Elsevier, v. 86, p. 446–455, 2018. Citado na página 36.
- SAYADI, O.; SHAMSOLLAHI, M. B. Ecg denoising and compression using a modified extended kalman filter structure. *IEEE transactions on biomedical engineering*, IEEE, v. 55, n. 9, p. 2240–2248, 2008. Citado na página 23.
- SCARSELLI, F. et al. The graph neural network model. *IEEE transactions on neural networks*, IEEE, v. 20, n. 1, p. 61–80, 2008. Citado 2 vezes nas páginas 45 e 46.
- SHARMA, M. et al. Automated detection of shockable and non-shockable arrhythmia using novel wavelet-based ecg features. *Computers in biology and medicine*, Elsevier, v. 115, p. 103446, 2019. Citado na página 29.
- SHARMA, P.; DINKAR, S. K.; GUPTA, D. A novel hybrid deep learning method with cuckoo search algorithm for classification of arrhythmia disease using ecg signals. *Neural Computing and Applications*, Springer, v. 33, n. 19, p. 13123–13143, 2021. Citado na página 36.
- SHARMA, P.; RAY, K. C. Efficient methodology for electrocardiogram beat classification. *IET Signal Processing*, Wiley Online Library, v. 10, n. 7, p. 825–832, 2016. Citado na página 30.
- SHOBANADEVI, A.; VEERAMAKALI, T. Classification and interpretation of ecg arrhythmia through deep learning techniques. 2023. Citado 2 vezes nas páginas 36 e 65.
- SHOUGHI, A.; DOWLATSHAHI, M. B. A practical system based on cnn-blstm network for accurate classification of ecg heartbeats of mit-bih imbalanced dataset. In: IEEE. *2021 26th international computer conference, Computer Society of Iran (CSICC)*. [S.l.], 2021. p. 1–6. Citado na página 24.

- SHUMAN, D. I. et al. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains. *IEEE signal processing magazine*, IEEE, v. 30, n. 3, p. 83–98, 2013. Citado na página 47.
- SIMONOVSKY, M.; KOMODAKIS, N. Graphvae: Towards generation of small graphs using variational autoencoders. In: SPRINGER. *International conference on artificial neural networks*. [S.l.], 2018. p. 412–422. Citado na página 46.
- SINGH, B. N.; TIWARI, A. K. Optimal selection of wavelet basis function applied to ecg signal denoising. *Digital signal processing*, Elsevier, v. 16, n. 3, p. 275–287, 2006. Citado na página 23.
- SÖRNMO, L.; LAGUNA, P. *Bioelectrical signal processing in cardiac and neurological applications*. [S.l.]: Academic Press, 2005. v. 8. Citado na página 16.
- SPERDUTI, A.; STARITA, A. Supervised neural networks for the classification of structures. *IEEE Transactions on Neural Networks*, IEEE, v. 8, n. 3, p. 714–735, 1997. Citado na página 45.
- SRAITHI, M.; JABRANE, Y.; ATLAS, A. An overview on intra-and inter-patient paradigm for ecg heartbeat arrhythmia classification. In: IEEE. *2021 International Conference on Digital Age & Technological Advances for Sustainable Development (ICDATA)*. [S.l.], 2021. p. 1–7. Citado na página 52.
- SUN, X. et al. Characterizing system dynamics with a weighted and directed network constructed from time series data. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, American Institute of Physics, v. 24, n. 2, p. 024402, 2014. Citado na página 40.
- TANG, X.; HU, Q.; TANG, W. A real-time qrs detection system with pr/rt interval and st segment measurements for wearable ecg sensors using parallel delta modulators. *IEEE transactions on biomedical circuits and systems*, IEEE, v. 12, n. 4, p. 751–761, 2018. Citado na página 27.
- THOMAS, M.; DAS, M. K.; ARI, S. Automatic ecg arrhythmia classification using dual tree complex wavelet based features. *AEU-International Journal of Electronics and Communications*, Elsevier, v. 69, n. 4, p. 715–721, 2015. Citado na página 29.
- TOMAR, D.; AGARWAL, S. A comparison on multi-class classification methods based on least squares twin support vector machine. *Knowledge-Based Systems*, Elsevier, v. 81, p. 131–147, 2015. Citado na página 32.
- TRAVERS, J.; MILGRAM, S. An experimental study of the small world problem. In: *Social networks*. [S.l.]: Elsevier, 1977. p. 179–197. Citado na página 38.
- ÜBEYLI, E. D. Adaptive neuro-fuzzy inference system for classification of ecg signals using lyapunov exponents. *Computer methods and programs in biomedicine*, Elsevier, v. 93, n. 3, p. 313–321, 2009. Citado na página 30.
- VAFIAIE, M. H.; ATAEI, M.; KOOFIGAR, H. R. Heart diseases prediction based on ecg signals' classification using a genetic-fuzzy system and dynamical model of ecg signals. *Biomedical Signal Processing and Control*, Elsevier, v. 14, p. 291–296, 2014. Citado na página 30.

- VALENTIN, J.-P. Reducing qt liability and proarrhythmic risk in drug discovery and development. *British Journal of Pharmacology*, Wiley Online Library, v. 159, n. 1, p. 5–11, 2010. Citado na página 27.
- VAPNIK, V. *The nature of statistical learning theory*. 2nd. ed. [S.l.]: Springer science & business media, 1999. Citado na página 32.
- VARATHARAJAN, R.; MANOGARAN, G.; PRIYAN, M. A big data classification approach using lda with an enhanced svm method for ecg signals in cloud computing. *Multimedia Tools and Applications*, Springer, v. 77, n. 8, p. 10195–10215, 2018. Citado na página 31.
- VELICKOVIC, P. et al. Deep graph infomax. *ICLR (Poster)*, v. 2, n. 3, p. 4, 2019. Citado na página 46.
- VENKATESAN, C. et al. Ecg signal preprocessing and svm classifier-based abnormality detection in remote healthcare applications. *IEEE Access*, IEEE, v. 6, p. 9767–9773, 2018. Citado 2 vezes nas páginas 18 e 32.
- WANG, D.; CUI, P.; ZHU, W. Structural deep network embedding. In: *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 1225–1234. Citado na página 46.
- WANG, H. et al. A weighted graph attention network based method for multi-label classification of electrocardiogram abnormalities. In: IEEE. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. [S.l.], 2020. p. 418–421. Citado na página 37.
- WANG, J.-S. et al. An effective ecg arrhythmia classification algorithm. In: SPRINGER. *International Conference on Intelligent Computing*. [S.l.], 2011. p. 545–550. Citado na página 33.
- WANG, L. et al. Wavelet transform based ecg denoising using adaptive thresholding. In: *Proceedings of the 2018 7th International Conference on Bioinformatics and Biomedical Science*. [S.l.: s.n.], 2018. p. 35–40. Citado na página 23.
- WANG, M. et al. Deep graph library: A graph-centric, highly-performant package for graph neural networks. *arXiv:1909.01315*, 2019. Citado na página 58.
- WANG, T. et al. Automatic ecg classification using continuous wavelet transform and convolutional neural network. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 23, n. 1, p. 119, 2021. Citado 4 vezes nas páginas 16, 25, 28 e 29.
- WANG, Z. et al. Deep reasoning with knowledge graph for social relationship understanding. *arXiv:1807.00504*, 2018. Citado na página 44.
- WASIMUDDIN, M. et al. Stages-based ecg signal analysis from traditional signal processing to machine learning approaches: A survey. *IEEE Access*, IEEE, v. 8, p. 177782–177803, 2020. Citado na página 34.
- WATTS, D. J. *Six degrees: The science of a connected age*. 1st. ed. [S.l.]: WW Norton & Company, 2004. Citado na página 39.

- WHO. *Cardiovascular diseases (CVDs)*. 2021. Disponível em: <https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-cvds>). Citado na página 16.
- WIDROW, B. et al. Adaptive noise cancelling: Principles and applications. *Proceedings of the IEEE*, IEEE, v. 63, n. 12, p. 1692–1716, 1975. Citado na página 23.
- WIENS, J.; GUTTAG, J. Active learning applied to patient-adaptive heartbeat classification. *Advances in neural information processing systems*, v. 23, 2010. Citado na página 28.
- WOSIAK, A. Principal component analysis based on data characteristics for dimensionality reduction of ecg recordings in arrhythmia classification. *Open Physics*, De Gruyter Open Access, v. 17, n. 1, p. 489–496, 2019. Citado na página 31.
- WU, Q. et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems. In: *The World Wide Web Conference*. [S.l.: s.n.], 2019. p. 2091–2102. Citado na página 44.
- WU, Y. et al. Graph convolutional networks with markov random field reasoning for social spammer detection. In: *Proceedings of the AAAI conference on artificial intelligence*. [S.l.: s.n.], 2020. v. 34, n. 01, p. 1054–1061. Citado na página 37.
- WU, Y. et al. Filtering electrocardiographic signals using an unbiased and normalized adaptive noise reduction system. *Medical engineering & physics*, Elsevier, v. 31, n. 1, p. 17–26, 2009. Citado na página 22.
- WU, Z. et al. A comprehensive survey on graph neural networks. *IEEE transactions on neural networks and learning systems*, IEEE, v. 32, n. 1, p. 4–24, 2020. Citado 7 vezes nas páginas 29, 39, 44, 45, 46, 47 e 48.
- WU, Z. et al. Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint arXiv:1906.00121*, 2019. Citado na página 46.
- XU, K. et al. How powerful are graph neural networks? *arXiv preprint arXiv:1810.00826*, 2018. Citado 2 vezes nas páginas 46 e 56.
- XUE, Q.; HU, Y. H.; TOMPKINS, W. J. Neural-network-based adaptive matched filtering for qrs detection. *IEEE Transactions on biomedical Engineering*, IEEE, v. 39, n. 4, p. 317–329, 1992. Citado na página 23.
- YAN, S.; XIONG, Y.; LIN, D. Spatial temporal graph convolutional networks for skeleton-based action recognition. In: *Thirty-second AAAI conference on artificial intelligence*. [S.l.: s.n.], 2018. Citado na página 46.
- YANG, H.; WEI, Z. Arrhythmia recognition and classification using combined parametric and visual pattern features of ecg morphology. *IEEE Access*, IEEE, v. 8, p. 47103–47117, 2020. Citado 3 vezes nas páginas 20, 26 e 27.
- YAO, L.; MAO, C.; LUO, Y. Graph convolutional networks for text classification. In: *Proceedings of the AAAI conference on artificial intelligence*. [S.l.: s.n.], 2019. p. 7370–7377. Citado na página 44.

- YE, C.; KUMAR, B. V.; COIMBRA, M. T. Heartbeat classification using morphological and dynamic features of ecg signals. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 59, n. 10, p. 2930–2941, 2012. Citado na página 24.
- YU, B.; YIN, H.; ZHU, Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. *arXiv preprint arXiv:1709.04875*, 2017. Citado na página 46.
- YU, S.-N.; CHEN, Y.-H. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recognition Letters*, Elsevier, v. 28, n. 10, p. 1142–1150, 2007. Citado na página 29.
- YU, S.-N.; CHEN, Y.-H. Noise-tolerant electrocardiogram beat classification based on higher order statistics of subband components. *Artificial intelligence in medicine*, Elsevier, v. 46, n. 2, p. 165–178, 2009. Citado na página 27.
- YU, X. et al. Resgnet-c: A graph convolutional neural network for detection of covid-19. *Neurocomputing*, Elsevier, v. 452, p. 592–605, 2021. Citado na página 37.
- ZAORÁLEK, L.; PLATOŠ, J.; SNÁŠEL, V. Patient-adapted and inter-patient ecg classification using neural network and gradient boosting. *Neural Network World*, Czech Technical University in Prague, Faculty of Transportation Sciences, v. 28, n. 3, p. 241–254, 2018. Citado 3 vezes nas páginas 16, 24 e 33.
- ZHANG, D. et al. An ecg heartbeat classification method based on deep convolutional neural network. *Journal of Healthcare Engineering*, Hindawi, v. 2021, 2021. Citado na página 36.
- ZHANG, J.; SMALL, M. Complex network from pseudoperiodic time series: Topology versus dynamics. *Physical review letters*, APS, v. 96, n. 23, p. 238701, 2006. Citado na página 40.
- ZHANG, Z. et al. Heartbeat classification using disease-specific feature selection. *Computers in biology and medicine*, Elsevier, v. 46, p. 79–89, 2014. Citado na página 28.
- ZHENG, J. et al. A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients. *Scientific Data*, Nature Publishing Group, v. 7, n. 1, p. 1–8, 2020. Citado na página 23.
- ZHOU, J. et al. Graph neural networks: A review of methods and applications. *AI Open*, Elsevier, v. 1, p. 57–81, 2020. Citado 2 vezes nas páginas 45 e 49.
- ZIDELMAL, Z. et al. Qrs detection based on wavelet coefficients. *Computer methods and programs in biomedicine*, Elsevier, v. 107, n. 3, p. 490–496, 2012. Citado na página 25.