



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DISSERTAÇÃO DE MESTRADO

SÉRGIO TEIXEIRA CORRÊA FILHO

DM: 16/23

**CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS ATRAVÉS DE UMA
ESTRUTURA COMPETITIVA DE REDES NEURAIS CONVOLUCIONAIS
AUTOASSOCIATIVAS**

**UFPA/ITEC/PPGEE
Campus Universitário do Guamá
BELÉM-PA
2023**



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SÉRGIO TEIXEIRA CORRÊA FILHO

**CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS ATRAVÉS DE UMA
ESTRUTURA COMPETITIVA DE REDES NEURAIIS CONVOLUCIONAIS
AUTOASSOCIATIVAS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal do Pará, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica na Área de Computação Aplicada.
Orientadora: Adriana Rosa Garcez Castro

**UFPA/ITEC/PPGEE
Campus Universitário do Guamá
BELÉM-PA
2023**

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS ATRAVÉS DE UMA ESTRUTURA
COMPETITIVA DE REDES NEURAS CONVOLUCIONAIS AUTOASSOCIATIVAS”**

AUTOR: SÉRGIO TEIXEIRA CORRÊA FILHO

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA
PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE
EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 11/05/2023

BANCA EXAMINADORA:

Prof.^a Dr.^a Adriana Rosa Garcez Castro
(Orientadora – PPGEE/UFPA)

Prof. Dr. Roberto Célio Limão de Oliveira
(Avaliador Interno – PPGEE/UFPA)

Prof. Dr. Orlando Shigueo Ohashi Júnior
(Avaliador Externo – UFRA)

VISTO:

Prof. Dr. Diego Lisboa Cardoso
(Coordenador do PPGEE/ITEC/UFPA)

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

F478c Filho, Sérgio Teixeira Corrêa.
Classificação de arritmias cardíacas através de uma estrutura competitiva de redes neurais convolucionais autoassociativas / Sérgio Teixeira Corrêa Filho. — 2023.
79 f. : il. color.

Orientador(a): Prof. Dr. Adriana Rosa Garcez Castro Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2023.

1. Rede Neural. 2. Convolucional. 3. Autoassociativa. 4. Arritmia. 5. Eletrocardiograma. I. Título.

CDD 006.3

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado força, coragem e determinação para superar todas as dificuldades que surgiram durante esta jornada acadêmica e por me proteger de todo e qualquer mal que possa me atingir.

Agradeço aos meus pais, Sérgio Teixeira Corrêa e Elcicarla Silva dos Santos Corrêa, assim como todos meus familiares, por todo o amor, ensinamento, carinho e apoio que me foi dado. Obrigado por sempre estarem ao meu lado e fazerem tudo ao seu alcance para que não faltasse nada para mim.

Agradeço a minha avó Auristela Silva dos Santos, por todas as lições, suporte e incentivo moral e financeiro durante a minha carreira acadêmica. Obrigado por sempre estar disposta a me ajudar em toda a minha vida.

Agradeço a minha amada, Ítala Campos Nery, por todo o amor, apoio e colaboração durante este trabalho para superar todos os obstáculos e por compreender meus momentos de ausência.

Aos meu tios Elcione Moura, Marcos Moura e meu primo Marcos Pedro, por sempre me apoiarem e estarem presentes em minha vida. Obrigado por me proporcionarem momentos felizes e por todo o auxílio durante a minha vida.

À minha orientadora Adriana Rosa Garcez Castro, pelo suporte, correções e incentivos que foram realizados com sabedoria, paciência e maestria durante o desenvolvimento deste trabalho. Obrigado por todos os ensinamentos que levarei adiante na vida acadêmica.

Meus agradecimentos aos meus amigos Caio Henrique Esquina Limão e Rafael Ferreira Ribeira Bernardo, que pacientemente me ajudaram em momentos de dificuldade e que fizeram parte da minha vida acadêmica. Obrigado pela amizade e companheirismo.

Agradeço ao meu companheiro de pesquisa Ítalo Flexa Di Paolo, por sempre sanar minhas dúvidas e me auxiliar durante o estudo e desenvolvimento deste trabalho. Meus sinceros agradecimentos.

Agradecimentos a todos que direta ou indiretamente contribuíram para o desenvolvimento deste trabalho.

“Não se amolde ao padrão deste mundo, mas transforme-se!

Romanos 12:1

LISTA DE ILUSTRAÇÕES

Figura 1 - Sinal de um batimento cardíaco normal, contendo a onda P, complexo QRS e onda T.....	14
Figura 2 - Estrutura simplificada de um coração.....	18
Figura 3 - Sinal Cardíaco e suas ondas características.	19
Figura 4 - Eletrocardiógrafo Analógico.....	21
Figura 5 - Eletrocardiógrafo Digital.	22
Figura 6 - Leitura de sinais elétricos por método on the person.	23
Figura 7 - Pontos de coleta de frequências cardíacas em um ECG	24
Figura 8 - Tipos de leituras de um sinal ECG.	25
Figura 9 - Sinal ECG de arritmia supraventricular.....	25
Figura 10 – Sinal ECG de arritmia ventricular.....	26
Figura 11- Sinal de ECG - Taquicardia sinusal.....	26
Figura 12 - Sinal de ECG - Bradicardia sinusal.	26
Figura 13 - Bradicardia atrioventricular.	27
Figura 14 - Pausa Sinusal.	27
Figura 15 – Etapas do sistema de classificação de arritmias.....	27
Figura 16 - Intervalo RR.....	30
Figura 17 - Exemplo de matriz de confusão simples.....	34
Figura 18 - Estrutura de uma RNA.....	38
Figura 19 - Estrutura representativa de uma CNN.	40
Figura 20 - Exemplo de aplicação do filtro ou kernel para reconhecer o padrão do número 4.	41
Figura 21- Funcionamento da Max Pooling.....	42
Figura 22 - Representação da estrutura de uma CNN Autoassociativa.....	43
Figura 23 - Exemplo de aplicação de Padding.	44
Figura 24 - Estrutura do sistema para classificação de arritmias.	45
Figura 25 - Fluxograma da metodologia adotada.....	47
Figura 26 - Exemplo de registro no banco de dados MIT-BIH.....	48
Figura 27 - Imagens dos tipos de arritmias presentes na base de dados e suas respectivas classes.	49
Figura 28 - exemplos de imagens de sinais ECG em escala de cinza.	51

Figura 29 - Arquitetura das CAEs propostas.....	52
Figura 30 - Sinais originais e reconstruídos pela CAE 1 (batimento Normal).....	55
Figura 31 - Sinais originais e reconstruídos pela CAE 2 (batimento Supraventricular).	55
Figura 32 - Sinais originais e reconstruídos pela CAE 3 (batimento Ventricular).....	56
Figura 33 - Matriz de confusão gerada para o banco de testes.....	56
Figura 34 - Exemplo de sinal Normal classificado corretamente, com menor erro para CAE 1 (Normal).	57
Figura 35 - Exemplo de sinal Supraventricular classificado corretamente, com menor erro para CAE 2 (Supraventricular).....	58
Figura 36 - Exemplo de sinal Ventricular classificado corretamente, com menor erro para CAE 3 (Ventricular).	58
Figura 37 - Sinais originais e reconstruídos pela CAE 1 (Batimento normal).	60
Figura 38 - Sinais originais e reconstruídos pela CAE 2 (batimento Supraventricular).	60
Figura 39 – Sinais originais e reconstruídos pela CAE 3 (batimento Ventricular).	61
Figura 40 - Matriz de confusão gerada para o banco de testes.....	61
Figura 41 - Exemplo de sinal Normal classificado corretamente, com menor erro para CAE1 (Normal).	63
Figura 42 - Exemplo de sinal Supraventricular classificado corretamente, com menor erro para CAE2 (supraventricular).	63
Figura 43 - Exemplo de sinal Ventricular classificado corretamente, com menor erro para CAE 3(Ventricular).	64

LISTA DE TABELAS

Tabela 1- Medida em mV de cada componente do batimento cardíaco em uma frequência cardíaca de 60 bpm.	22
Tabela 2 - Bases de dados públicas de sinais ECG recomendadas pela AAMI.	33
Tabela 3 - Classes do MIT-BIH e seu mapeamento para o AAMI.	33
Tabela 4 - Resumo de trabalhos usando abordagem interpaciente.	36
Tabela 5 - Resumo de trabalhos usando abordagem intrapaciente.	37
Tabela 6 - Número de amostras da base de dados interpaciente.	50
Tabela 7 - Número de amostras da base de dados intrapaciente.	50
Tabela 8 - Parâmetros e Arquitetura das CAEs.	52
Tabela 9 - Número de registros da base de treino e teste para cada CAE.	54
Tabela 10 - Resultados obtidos para cada rede CAE.	55
Tabela 11 - Valores das métricas obtidas considerando base de teste.	56
Tabela 12 - Número de registros da base de treino e teste para cada CAE.	59
Tabela 13 - Resultados obtidos para cada rede CAE.	60
Tabela 14 - Valores das métricas obtidas considerando base de teste.	61
Tabela 15 - Resultados de sistemas classificadores de arritmia – Intrapaciente.	65
Tabela 16 - Resultados de sistemas classificadores de arritmia – Interpaciente.	66

RESUMO

Este trabalho apresenta a proposta de um sistema para classificação de arritmias cardíacas baseado em uma estrutura competitiva de Redes Neurais Convolucionais Autoassociativas. Três redes neurais foram treinadas para reconstruir sinais de Eletrocardiograma (ECG) para casos de pacientes com batimento supraventricular, ventricular e normal. Após o treinamento, as redes foram alocadas em uma estrutura paralela competitiva para classificação de arritmias. O banco de dados público de arritmia MIT-BIH de sinais ECG foi utilizado para o treinamento e testes das redes, sendo que para cada sinal ECG, de cada paciente, foram extraídos os complexos QRS dos batimentos cardíacos, que foram as características utilizadas como entrada para o sistema, sendo que estes sinais, que se encontravam em formato de sinais temporais (1D), foram transformados para imagens digitais (2D) com o objetivo de utilizar a capacidade das redes neurais convolucionais para reconhecimento de padrões e extração de características em imagens. Para desenvolvimento e análise de desempenho da estrutura proposta foram usados dois paradigmas que vêm sendo utilizados em trabalhos já apresentados na literatura: paradigma interpaciente e paradigma intrapaciente, sendo que o sistema obteve uma acurácia de 96,97%, sensibilidade de 96,30% e precisão de 93,59% para o caso intrapaciente e acurácia de 94,05%, sensibilidade de 70,43% e precisão de 65,74% para o caso interpaciente. Uma análise comparativa com resultados de sistemas de classificação de arritmia já apresentados na literatura mostra que o sistema proposto apresentou resultados próximos ou em alguns casos melhores que os já obtidos, mostrando assim a aplicabilidade da estrutura proposta para o problema.

PALAVRAS-CHAVE: Rede neural, Convolucional, Autoassociativa, Arritmia, ECG.

ABSTRACT

This work proposes a system for classifying cardiac arrhythmias based on a competitive structure of Autoassociative Convolutional Neural Networks. Three neural networks were trained to reconstruct Electrocardiogram (ECG) signals for cases of patients with supraventricular, ventricular and normal beats. After training, the networks were allocated in a competitive parallel structure for classification of arrhythmias. The MIT-BIH arrhythmia public database of ECG signals was used for training and testing the networks, and for each ECG signal, from each patient, the QRS complexes of the heartbeats were extracted, which were the characteristics used as input. for the system, and these signals, which were in the form of temporal signals (1D), were transformed into digital images (2D) in order to use the capacity of convolutional neural networks for pattern recognition and feature extraction in images. For the development and performance analysis of the proposed structure, two paradigms that have been used in works already presented in the literature were used: interpatient paradigm and inpatient paradigm, and the system obtained an accuracy of 96.97%, sensitivity of 96.30% and precision of 93.59% for the inpatient case and accuracy of 94.05%, sensitivity of 70.43% and precision of 65.74% for the interpatient case. A comparative analysis with results from arrhythmia classification systems already presented in the literature shows that the proposed system presented similar results or, in some cases, better results than those already obtained, thus showing the applicability of the proposed structure to the problem.

KEYWORDS: Neural network, Convolutional, Autoencoder, Arrhythmia, ECG.

SUMÁRIO

1 INTRODUÇÃO	14
1.1 Descrição do Problema	14
1.2 Objetivo.....	16
1.2.1 Objetivo Geral	16
1.2.2 Objetivos Específicos	16
1.3 Estrutura do trabalho	17
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 Introdução.....	18
2.2 O Coração	18
2.2.1 Sinal Cardíaco	19
2.2.2 Eletrocardiograma	20
2.2.3 Arritmias Cardíacas	25
2.2.4 Sistemas Automáticos para classificação de arritmias	27
2.3 Estado da Arte de sistemas para classificação de arritmias.....	34
2.3.1 Paradigma Interpaciente	35
2.3.2 Abordagem Intrapaciente	36
2.4 Redes Neurais Artificiais.....	37
2.2.2. Redes Neurais Convolucionais.....	40
2.2.3 Rede Neural Convolucional Autoassociativa	42
3 SISTEMA PARA CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS	45
3.1 Introdução.....	45
3.2 Metodologia.....	46
3.2.1 Etapa de Carregamento da base de dados MIT-BIH	48
3.2.2 Etapa de Conversão dos dados em imagens	50
3.2.3 Etapa de definição e treinamento das redes CAEs	51
3.2.4 Etapa de teste das estruturas competitivas e cálculo de todas as métricas para avaliação de desempenho e análise de resultados.....	53
4 RESULTADOS	54
4.1 Introdução.....	54

4.2 Resultados para paradigma intrapaciente	54
4.2.1 Treinamento das redes CAEs	54
4.2.2 Estrutura Competitiva Autoassociativa	56
4.3 Resultados para Paradigma Interpaciente.....	59
4.3.1 Treinamento das Redes Autoassociativas.....	59
4.3.2 Estrutura Competitiva Autoassociativa	61
4.4 Comparação com Resultados de Sistemas Apresentados Na Literatura	64
4.4.1 Paradigma Intrapaciente	64
4.4.2 Paradigma Interpaciente	66
5 CONCLUSÃO E TRABALHOS FUTUROS.....	68
REFERÊNCIAS BIBLIOGRÁFICAS	69

1 INTRODUÇÃO

1.1 Descrição do Problema

As doenças cardiovasculares vêm se constituindo como uma das principais causas de morte no mundo, afetando anualmente cerca de 17.9 milhões de pessoas (WORLD HEALTH ORGANIZATION, 2021).

A arritmia é definida como uma doença cardiovascular que se caracteriza por alterações na sequência normal dos impulsos elétricos que ocorrem, ou de forma muito lenta, ou de forma muito rápida, fazendo com que o coração bata de forma irregular, prejudicando desta forma o bombeamento de sangue e podendo afetar diversos órgãos (AMERICAN HEART ASSOCIATION, 2016).

O Eletrocardiograma (ECG) é um dos exames que vêm sendo utilizados para análise de arritmias. Este exame é um dos mais utilizados, principalmente devido a sua praticidade e por ser um procedimento não invasivo. O ECG realiza o registro de impulsos elétricos produzidos pelo coração, permitindo que um especialista possa visualizar e medir o ritmo das batidas e desta forma indicar se existe uma arritmia (MORSCH, 2018).

Os batimentos cardíacos são formados pela onda P, complexo QRS e onda T, conforme apresentado na Figura 1. Na fase de batimento normal de um coração os principais parâmetros inspecionados incluem a forma, a duração e a relação entre si da onda P, complexo QRS e componentes da onda T e intervalo R-R. As mudanças nesses parâmetros podem indicar a existência de doenças do coração, como por exemplo a arritmia, sendo que esta pode ocorrer por variados motivos (OH et al., 2018).

Figura 1 - Sinal de um batimento cardíaco normal, contendo a onda P, complexo QRS e onda T.



Fonte (ISIN; OZDALILI, 2017).

Dentre os vários benefícios trazidos pelo uso do eletrocardiograma, um deles é a capacidade de identificar outras doenças além da arritmia, tais como infarto do miocárdio, doença cardíaca coronária e outras comorbidades, assim como diabetes e pressão alta (LIU et al., 2021). Apesar das diversas vantagens, o processo de interpretação dos dados obtidos por

meio do ECG requer bastante tempo para alguns casos e o diagnóstico é bastante complexo (ROHMANTRI; SURANTHA, 2020).

Com o intuito de prestar auxílio à detecção de anomalias em batimentos cardíacos e um melhor apoio aos profissionais da área médica, alguns trabalhos vêm sendo apresentados na literatura fazendo o uso de sinais ECG e métodos de aprendizado de máquina, como no trabalho de (REXY; VELMANI; RAJAKUMAR, 2021), onde os autores apresentam uma rede neural bidimensional LSTM capaz de classificar sinais ECG, utilizando a base de dados de arritmia MIT-BIH, dividindo em 90% dos dados para fase de treinamento e 10% para testes. O sistema proposto obteve métricas de desempenho de 93,9% de acurácia, 96,19 % de especificidade e 90,16% de sensibilidade.

Em (SEITANIDIS, GIALELIS; PAPACONSTANTINO, 2022), é proposto um sistema composto por uma rede neural convolucional 2D que também realiza a classificação de sinais ECG, fazendo uso da base de dados de arritmia MIT-BIH para o desenvolvimento, com 80% dos dados utilizados para treinamento e 20% para teste. O trabalho obteve em suas métricas de desempenho, 95,2% de acurácia, 98,8% de especificidade, 95,2% de sensibilidade e 95,38% de precisão.

No trabalho desenvolvido por (AHMAD et al.,2021) é demonstrado o uso do classificador AlexNet para a mesma tarefa, tendo alcançado excelentes resultados de classificação. A aplicação também faz uso da base de dados de arritmia MIT-BIH, dividindo em 80% dos dados para treino e 20% para testes. Ao término do trabalho, o sistema obteve 97,3% de acurácia, 85% de precisão e 91% de sensibilidade.

Muitos outros trabalhos vêm sendo apresentados na literatura, tais como em (PASSO et al.,2020), (COSTA; GOVINDA; REGIS, 2016) e (PENHA; CASTRO, 2017) que também, com ótimos resultados para o problema de classificação de arritmias, utilizam diretamente sinais temporais de ECG como entrada de dados para o sistema. Alguns trabalhos disponíveis na literatura, tais como em (NARDELLI et al., 2018), (AHMAD et al., 2021) e (SHAKER et al., 2020) aplicam a transformação do sinal ECG de série temporal (1D) para imagem (2D) para serem utilizadas como entrada para redes neurais convolucionais, com o objetivo de aproveitar a funcionalidade deste tipo de rede para extração de características a partir de imagens de entrada.

Muitos dos trabalhos encontrados na literatura, utilizando aprendizado de máquina, têm obtido bons resultados para o problema de classificação de arritmias, entretanto como apresentado em (LUZ et al., 2015), muitos destes utilizaram o paradigma intrapaciente para desenvolvimento dos sistemas classificadores, onde durante a fase de teste dos sistemas, as

métricas de avaliação são calculadas considerando dados de pacientes que tiveram parte de seus dados utilizados para treinamento do sistema. Para alguns autores, que compartilham com o mesmo objetivo deste trabalho, que vêm utilizando a abordagem interpaciente, ou seja, o desenvolvimento do sistema utilizando pacientes diferentes para base de treino e teste, a abordagem intrapaciente pode levar o modelo a superestimar o desempenho dos sistemas, tornando os resultados questionáveis. A abordagem intrapaciente pode trazer melhores resultados de classificação, porém o modelo não representa métricas clinicamente úteis pois não demonstra a situação real em clínicas de atendimento hospitalar. Para estes autores, que utilizam a abordagem interpaciente, apenas classificadores que demonstrem boa capacidade de generalização do modelo em dados de pacientes não utilizados na fase de treinamento podem ser considerados clinicamente úteis.

1.2 Objetivo

1.2.1 Objetivo Geral

Este trabalho tem como objetivo geral apresentar os resultados obtidos do estudo e desenvolvimento de um sistema de classificação de arritmias cardíacas baseado em uma estrutura competitiva de rede neurais convolucionais autoassociativas. Para desenvolvimento do sistema foram utilizados dados de ECG obtidos da base de dados pública de arritmia MIT-BIH, de onde foram extraídos os complexos QRS para cada paciente e estes sinais temporais (1D) foram transformados para imagem (2D) para servirem de entrada para as redes neurais convolucionais autoassociativas.

1.2.2 Objetivos Específicos

- Levantamento relacionado a estudos disponíveis na literatura sobre a utilização de rede neurais artificiais para classificação de arritmias cardíacas para a abordagem interpaciente e intrapaciente.
- Estudo da base de dados MIT-BIH.
- Conversão dos sinais ECG (complexo QRS) de série temporal para imagem.
- Estudo, desenvolvimento e teste das estruturas competitivas autoassociativas baseadas no paradigma interpaciente e no paradigma intrapaciente.
- Estudo comparativo de desempenho para paradigma interpaciente e intrapaciente.

- Comparar resultados finais com sistemas de classificação disponíveis na literatura desenvolvidos para paradigma interpaciente e intrapaciente.
- Demonstrar através dos resultados obtidos que com abordagem intrapaciente, como já visto em diversos trabalhos na literatura, tem-se modelos com melhores resultados das métricas de avaliação mas que entretanto, estes modelos são treinados em situações que não representam a realidade em clínicas de diagnóstico médico.

1.3 Estrutura do trabalho

O trabalho proposto se encontra dividido em 5 capítulos e referências.

No capítulo 1 são apresentados a descrição do problema e os objetivos almejados pelo trabalho.

O capítulo 2 expõe a fundamentação teórica, apresentando os conceitos teóricos importantes para o entendimento sobre Arritmias cardíacas e Redes Neurais Artificiais, demonstrando suas aplicações para classificações das arritmias.

No capítulo 3, é exposta a metodologia, apresentando todo o processo necessário para a implementação da estrutura competitiva de redes neurais convolucionais autoassociativas. Desde a análise exploratória do banco de dados utilizado neste trabalho, passando pela formatação dos dados que servirão de entrada para a rede neural, até o desenvolvimento das redes.

No capítulo 4 são apresentados os resultados alcançados e análise comparativa com outros trabalhos apresentados na literatura para paradigma interpaciente e intrapaciente. Finalizando, o capítulo 5 apresenta as devidas conclusões finais e possíveis ideias para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA


2.1 Introdução

Neste capítulo abordam-se os aspectos teóricos necessários para um bom entendimento da proposta deste trabalho. Inicialmente será apresentada uma breve teoria sobre a estrutura do coração e seu funcionamento, em seguida será abordado o Eletrocardiograma (ECG), o Eletrocardiógrafo, as arritmias cardíacas e por fim, conceitos relacionados as redes neurais convolucionais e redes neurais convolucionais autoassociativas.

2.2 O Coração

O coração é definido como um órgão muscular, singular, localizado no mediastino médio, à esquerda do plano do mediastino. A principal função deste órgão é bombear o sangue por meio dos vasos sanguíneos, fazendo-o chegar em todas as células do organismo (SEELEY et al., 2016). A figura 2 apresenta a estrutura simplificada do coração.

Figura 2 - Estrutura simplificada de um coração.



Fonte: (GELMEK HEALTHCARE, 2021).

Ambos os lados do coração são formados pelos átrios que recebem o sangue vindo das veias e ventrículo que bombeia o sangue para as artérias, mas com atribuições diferentes. O lado direito do coração é responsável por transportar o sangue venoso (rico em dióxido de carbono) através da artéria pulmonar para o pulmão, que por meio da etapa de respiração (trocas gasosas entre o organismo e o meio ambiente) expira o gás carbônico e enriquece o sangue com oxigênio. O lado esquerdo do coração é responsável por irrigar o sangue oxigenado em todo o corpo humano por meio da artéria aorta (BRAUNWALD, 2006).

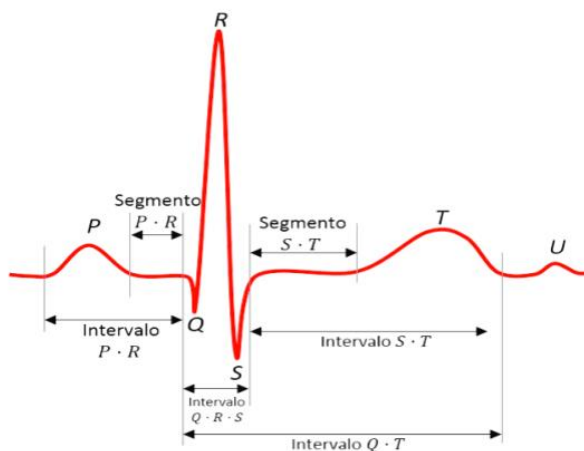
O ciclo cardíaco é formado por dois períodos: a sístole e a diástole, sendo a primeira um período de contração ventricular, que ejeta o sangue dos ventrículos; e o segundo, um período

de relaxamento ventricular, quando os átrios são encheidos de sangue. Uma onda de despolarização elétrica é propagada pelo coração, precedendo e sendo responsável por cada contração mecânica. Após a despolarização ventricular, é feita a contração ventricular e os ventrículos voltam ao seu estado original devido à repolarização elétrica. Os processos de despolarização e repolarização geram correntes elétricas que circundam as membranas das células miocárdicas e se fecham no volume condutor do tórax, dentro do coração, gerando um campo elétrico detectável na superfície corporal (WOLF, 2004).

2.2.1 Sinal Cardíaco

A contração dos átrios, movimento conhecido como sístole, seguida da abertura das válvulas, que permitem que o sangue seja bombeado para os ventrículos que estão relaxados (diástole), compõem o ciclo cardíaco, que geram um sinal elétrico (sinal cardíaco) com determinado padrão (MAGALHÃES, 2018). O sinal cardíaco é formado por ondas padronizadas como apresentado na Figura 3.

Figura 3 - Sinal Cardíaco e suas ondas características.



Fonte: (REGIS; CALDEIRA; GURJÃO, 2016).

A onda P é a primeira curva do sinal e ocorre quando acontece a despolarização auricular, isto é, ativação sequencial das aurículas. Como o nó sinusal está situado na parte superior da aurícula direita, o impulso sinusal percorre desde a aurícula direita até à aurícula esquerda e, posteriormente, até aos ventrículos. A primeira metade da onda P (início da curva e despolarização da aurícula direita) se dá pela ativação da aurícula direita. Já a segunda metade (fim da curva e despolarização da aurícula esquerda) é devido à ativação da aurícula esquerda. Uma onda P nítida, isto é, que não teve nenhum problema na contração das aurículas, antes do complexo QRS, representa o ritmo normal. Por outro lado, a ausência desta onda pode sugerir fibrilação auricular ou outro tipo de doença cardiovascular (BALTAZAR, 2009).

O segmento PR corresponde ao período entre a ativação dos átrios até a ativação dos ventrículos e é usado com o objetivo de verificar o diagnóstico do bloqueio completo cardíaco de primeiro, segundo (quando existe um prolongamento do intervalo e ausência de alguns batimentos) e terceiro grau, contrações atriais prematuras e para determinar a gravidade de doenças como por exemplo, a febre reumática (FONSECA, 2003).

O Complexo QRS demonstra a despolarização ventricular, que está ligada à ativação dos ventrículos. Este produz a maior deflexão no sinal, uma vez que, os ventrículos contêm a maior massa de células musculares do coração, denominadas coletivamente de miocárdio. O complexo QRS é medido desde o início da primeira deflexão, podendo começar com uma onda Q ou uma onda R, dependendo da situação, e prolonga-se até o final da última deflexão. A duração do QRS é aumentada quando ocorre hipertrofia ventricular, excitação prematura dos ventrículos ou bloqueio de ramo (BALTAZAR, 2009).

O segmento ST é plano ou isoelétrico (carga elétrica de valor zero) e corresponde à fase 2 do potencial de ação das células miocárdicas ventriculares. Tem lugar no final da despolarização ventricular, porém antes do começo da repolarização. Consoante a deflexão da onda T são diagnosticadas doenças como isquemia miocárdica e hipertrofia ventricular esquerda (BALTAZAR, 2009).

A onda T ocorre durante a repolarização dos ventrículos e possui a frequência de aproximadamente 1 a 2 Hz (CARR; BROWN 2001). Relacionada as mudanças na forma do complexo QRS, a inversão de polaridade representa a contração prematura dos ventrículos (CARDOSO, 2010). Representa a repolarização ventricular com voltagem menor que a do QRS.

O fim da onda T finaliza o ciclo cardíaco normal. Esta última, no entanto, pode frequentemente ser seguida por uma pequena deflexão positiva chamada onda U. Esta nem sempre está presente, porém pode ser a última onda registrada no sinal. As ondas U são geralmente vistas em pacientes normais, contudo são consideradas anormais sempre que se encontram invertidas ou, quando igualam ou excedem a onda T. Esta situação ocorre num contexto de hipocalémia (BALTAZAR, 2009).

2.2.2 Eletrocardiograma


O sinal elétrico gerado pelo coração se propaga pelo corpo gerando atividade elétrica sob a pele e provocando assim uma tensão em determinadas partes do corpo. Se forem colocados eletrodos sobre a pele em pontos opostos do coração, os potenciais elétricos gerados por estes sinais elétricos podem ser registrados, sendo que este registro corresponde a um

Eletrocardiograma (ECG). O sinal ECG pode ser obtido através de um Eletrocardiógrafo, sendo que para a medida dos sinais elétricos são utilizados sensores (eletrodos) no tórax, punhos e tornozelos, sendo possível também realizar a medição com os sensores apenas no tórax.

O ECG é um exame não invasivo, de baixo custo, isento de riscos e usado diariamente na prática clínica diária para diagnóstico de doenças cardíacas e outras condições graves, tais como infarto do miocárdio, arritmias cardíacas, tromboembolismo pulmonar e distúrbios hidroeletrólíticos (PASTORE, et al., 2016).

Na cardiologia, os eletrocardiógrafos podem ser classificados em analógicos ou digitais. Os aparelhos analógicos possuem como função amplificar de forma linear as medições dos potenciais cardíacos, registrando o sinal de forma contínua por meio de uma saída com um papel térmico e um estilete aquecido, que se desloca sobre o papel, registrando o sinal ECG obtido (SILVA, 2008). Nesse tipo de dispositivo, o papel opera com taxas de impressão de 25 mm/s e 50 mm/s, enquanto os ganhos de sinais podem variar na faixa de 5 mm/mV até 20 mm/mV. Podem possuir de 1 a 3 canais e, sendo assim, possuem a capacidade de realizar medições simultâneas em até 3 derivações. Além disso, podem apresentar filtros para eliminar ruídos da rede e de outros sinais biológicos que podem interferir na medição do sinal (SILVA, 2008). A figura 4 demonstra um modelo de eletrocardiógrafo analógico, sendo possível visualizar o estilete responsável por imprimir no papel térmico milimetrado o eletrocardiograma, à medida que a atividade cardíaca é captada pelos eletrodos.

Figura 4 - Eletrocardiógrafo Analógico.



Fonte: (SILVA, 2008).

Os eletrocardiógrafos digitais são os mais comuns de serem utilizados na área médica. Nesses modelos, os registros do eletrocardiograma podem ser analisados por meio de um display, bem como impressos em um papel térmico ou ainda armazenados em unidades de memória, como cartões de memória e *pen drives*. Os filtros responsáveis por eliminar os ruídos

existentes são digitais e podem ser ajustados para filtrar frequências específicas, dependendo da aplicação necessária pelo médico.

A figura 5 apresenta um eletrocardiógrafo de 3 canais com aquisição simultânea de 12 derivações da marca Ecafex. O modelo ECG-12SPCI, por exemplo, possibilita a impressão do traçado em 25 ou 50 mm/s, além de possuir comunicação USB (Universal Serial Bus) e *software* próprio para a execução e armazenamento do exame em computador.

Figura 5 - Eletrocardiógrafo Digital.



Fonte: (CENTER MEDICAL, 2018).

A medição dos sinais elétricos obtidas pelo eletrocardiógrafo digital são feitas em milivolt (mV), assim como o total de batimentos cardíacos é demonstrado utilizando a medida de batidas por minuto (bpm). A tabela 1 apresenta os valores usados em cada componente do batimento cardíaco.

Tabela 1- Medida em mV de cada componente do batimento cardíaco em uma frequência cardíaca de 60 bpm.

Componente	Valor Normal	Variação Normal
Onda P	110 ms	± 20 ms
Intervalo PQ/PR	160 ms	± 40 ms
Complexo QRS	100 ms	± 20 ms
Intervalo QT	400 ms	± 40 ms
Amplitude de P	0,115 mV	± 0,05 mV
Amplitude do QRS	1,5 mV	± 0,5 mV
Nível ST	0 mV	± 0,1 mV
Amplitude de T	0,3 mV	± 0,2 mV

Fonte: (LUZ et al., 2015).


A medição de um sinal cardíaco pode ser realizada pelo especialista por meio de três abordagens, sendo estas:

- *In-the-person*: nesta abordagem, os equipamentos utilizados para a medição do

batimento são inseridos no corpo do paciente sendo que a inserção pode ser feita por meio de cirurgia ou pelo consumo de pílulas (SILVA et al., 2015).

- *On-the-person*: nesta metodologia, têm-se aparelhos conectados no corpo do paciente, como é o caso dos eletrodos, que possuem a função de obter os sinais elétricos cardíacos, como pode ser visto na Figura 6. Também é necessário que entre o eletrodo e a pele do paciente haja uma substância que possa servir como superfície fixadora, aumentando a aderência, de forma que o eletrodo possa permanecer na mesma posição onde foi colocado, e também a presença de um gel condutor, permitindo que toda a superfície do eletrodo possa captar o sinal, além de evitar interferências por conta da movimentação do dispositivo (CUNHA, 2012).
- *Off-the-person*: categoria onde existe um mínimo contato com o corpo do paciente para a medição do sinal, sendo que exemplos de equipamentos para tal coleta são equipamentos baseados em capacitores, que medem os sinais elétricos a cerca de 1cm da pele (SILVA et al., 2015).

Figura 6 - Leitura de sinais elétricos por método *on the person*.




Fonte: (MAGAZINE MÉDICA, 2022).

A maioria dos eletrocardiógrafos realiza a medição do sinal ECG por meio da metodologia *on-the-person*, onde a medição do sinal ECG é realizada por meio de eletrodos posicionados sobre a pele do paciente em diversos locais, tais como peito, pulsos e tornozelos. A quantidade necessária de eletrodos a serem posicionados pelo corpo pode variar de seis a dezoito, sendo seis o valor mínimo de eletrodos para que o sinal possa ser captado com uma maior qualidade de informação (MEDICALEXPO, 2014). Vale ressaltar que a quantidade de eletrodos não influencia na qualidade do sinal e sim outros fatores, tais como defeitos dos cabos, ausência de gel condutor, uso de tomadas sem aterramento e entre outros (MORSCH, 2019). Existem diversas configurações para conectar os eletrodos ao corpo do paciente para obter a medição do sinal cardíaco e existem cinco localizações utilizadas:

- Braço Esquerdo (LA);
- Braço Direito (RA);
- Perna Esquerda (LL);
- Perna Direita (RL);
- Direita do Esterno (V ou V1).

Também é possível fazer o uso de 10 eletrodos para realizar a medição, que além das 5 posições citadas anteriormente, outros cinco eletrodos são posicionados no tórax do paciente (V2 a V6). A Figura 7 apresenta o posicionamento dos eletrodos no corpo.

Figura 7 - Pontos de coleta de frequências cardíacas em um ECG.



Fonte: (SCHWARZ, 2009).

A partir do posicionamento dos eletrodos, a diferença de potencial entre eles é medida e assim obtém-se o sinal do eletrocardiograma, com a batida do coração do paciente ao longo do tempo. Cada combinação de pontos leva a um determinado tipo de leitura, como é demonstrado na Figura 8, onde a leitura I é formada pela diferença de potencial entre LA e RA, enquanto que a leitura II é feita pela diferença de potencial entre LL e RA e por fim, a leitura III é realizada pela diferença de potencial entre LL e LA.

Figura 8 - Tipos de leituras de um sinal ECG.



Fonte: (LUZ et al, 2015).

Para efetuar o diagnóstico de doenças cardíacas, a leitura do tipo II é a mais utilizada por equipes médicas, pois a mesma acentua os diversos segmentos que compõem um batimento cardíaco, como a Onda P e complexo QRS. Desta forma, qualquer alteração no padrão desses componentes pode indicar a ocorrência de uma arritmia cardíaca (LUZ et al., 2015).

2.2.3 Arritmias Cardíacas


Dentre as várias doenças cardíacas existentes, as mais comuns são as arritmias cardíacas, que afetam mais de 20 milhões de brasileiros e geram mais de 300 mil mortes ao ano (SOBRAC, 2020).

As arritmias cardíacas são caracterizadas pela má formação e condução irregular do impulso elétrico do coração, fazendo com que os batimentos sejam acelerados (taquicardia) ou mais devagar (bradicardia) (SOBRAC, 2020).

A arritmia cardíaca pode ocasionar alguns sintomas, tais como tonteados e palpitações, e suas principais causas são estresse e diabetes. As arritmias podem causar acidente vascular ou insuficiência cardíaca. Apesar dos sintomas e causas bastante visíveis, é possível existir casos onde os sintomas não são detectados, assim como pode acontecer casos em que um ritmo fraco de batidas do coração não seja suficiente para ser um sinal de arritmia (NORDQVIST, 2017).


É crucial levar em consideração o local de origem e o ritmo dos batimentos durante o diagnóstico de arritmias. Quanto ao local de origem da doença, quando surge nos átrios, no nó sinoatrial ou nó atrioventricular é chamada de arritmia supraventricular, e quando aparece nos ventrículos é chamada de arritmia ventricular (SANARMED, 2019) As figuras 9 e 10 apresentam sinais ECG para arritmias supraventricular e ventricular.

Figura 9 - Sinal ECG de arritmia supraventricular.



Fonte: (CUREM, 2022).

Figura 10 – Sinal ECG de arritmia ventricular.



Fonte: (PADILLA, 2016).

Em relação ao ritmo, a arritmia pode ser classificada em taquicardia (Figura 11), caracterizada pelo batimento rápido, ou bradicardia (Figura 12), caracterizada pelo batimento lento. A união do local de origem da arritmia com a velocidade do batimento gera a classe da arritmia (BAIA, 2019).

Figura 11- Sinal de ECG - Taquicardia sinusal.



Fonte: (ACLS, 2022).

Figura 12 - Sinal de ECG - Bradicardia sinusal.



Fonte: (GOMES, 2019).


Existe a possibilidade de existirem combinações de velocidade de batimentos com doenças específicas, como por exemplo a pausa sinusal (MY EKG, 2018), a qual é classificada dentro da bradicardia. Considerando casos de bradicardias, a Figura 13 ilustra um sinal ECG de um paciente com bradicardia atrioventricular, enquanto a Figura 14 exibe um ECG de paciente com bradicardia de pausa sinusal.

Figura 13 - Bradicardia atrioventricular.



Fonte: (MY EKG, 2018).

Figura 14 - Pausa Sinusal.



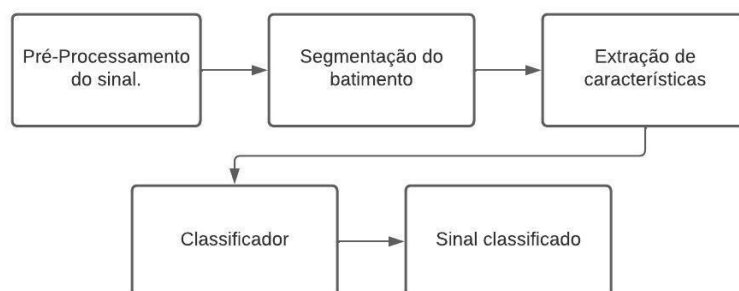
Fonte: (MY EKG, 2018).

2.2.4 Sistemas Automáticos para classificação de arritmias

A análise manual para diagnóstico dos batimentos cardíacos por meio de sinais ECG necessita muito tempo do cardiologista. Em alguns casos, é preciso registrar o sinal pelo período de até uma semana para identificar determinadas arritmias, possibilitando a perda de informações importantes e dificultando resultados imediatos. Uma opção é o uso de sistemas para a identificação automática de arritmia, onde técnicas de reconhecimento de padrões, processamento de sinal, e classificação automática de sinais cardíacos podem ser utilizadas, com o objetivo de otimizar o tempo e servir de ferramenta de auxílio para equipes médicas durante a etapa de diagnóstico da doença (LUZ, 2012).

Um sistema automático para classificação de arritmias é formado por quatro etapas: pré-processamento do sinal, segmentação do sinal, extração de características e classificação. A Figura 15 ilustra um diagrama de blocos apresentando como essas etapas estão conectadas.

Figura 15 – Etapas do sistema de classificação de arritmias.



Fonte: Autoral.

A seguir será apresentada com mais detalhes cada uma destas etapas.

2.2.4.1 Pré-Processamento do Sinal

A qualidade do diagnóstico de doenças cardíacas por meio da classificação de sinais ECG depende diretamente da etapa de pré-processamento, onde são filtradas as frequências de ruído e de artefatos que possam causar interferências na banda de frequência do sinal ECG (MARTIS et al., 2014).

Em conjunto com os sinais provenientes da passagem da corrente elétrica nos tecidos musculares do coração, outros sinais também podem ser captados no ECG. Esses sinais, misturam-se e poluem o registro, inserindo ruídos e informações desnecessárias no sinal que representa o batimento cardíaco. Entre os diversos tipos de ruídos, podem ser destacados: interferência da rede de alimentação elétrica, ruído de contato do eletrodo, ruído por contrações de outros músculos, movimentação da linha de base, modulação devido à movimento de respiração e artefatos de movimento (FRIESEN et al., 1990).

Dentre os mais variados métodos para reduzir o ruído no sinal ECG, o mais simples e comumente utilizado é a implementação de filtros digitais de resposta de pulso finito, sendo possibilitado devido ao avanço do uso de microcontroladores e microprocessadores. Estes métodos funcionam para a atenuação da frequência de banda conhecidas, tais como ruídos vindo da rede elétrica, pois eles permitem uma rápida aplicação de filtros do sinal (LYNN, 1979). O filtro FIR apresenta uma ótima performance nas frequências de bandas de ruídos da rede. A desvantagem deste filtro é que existem situações em que a frequência do ruído não é conhecida, o que faz com que em muitos casos filtros com várias faixas de frequências tenham que ser aplicados ao sinal. O uso indiscriminado destes filtros pode deformar a morfologia do sinal, o que prejudica a análise das arritmias morfológicas, podendo levar a diagnósticos incorretos. Para solucionar este problema em (FERRARA; WIDROW, 1982) é proposto a utilização de filtros adaptativos, porém foi também comprovado que este tipo de filtro apresenta desvantagens em relação ao FIR.

O filtro passa-alta também pode ser utilizado para a redução de ruídos do tipo baseline em sinais ECG, que podem ser provocados pelos meios externos, como a movimentação e respiração do paciente (JEYARANI; SINGH, 2010).

Ainda dentro das aplicações de filtros, pode-se aplicar o filtro FIR de terceira ordem para amenizar ruídos provenientes da interferência causada pela fonte de energia do próprio instrumento para a coleta do ECG (JEYARANI; SINGH, 2010).

Uma terceira metodologia ainda ligada a filtros utiliza o filtro passa-baixa para reduzir ruídos eletromiográficos, que podem ser originados de outras contrações musculares do próprio paciente (JEYARANI; SINGH, 2010).

Por fim, a Transformada Wavelet também tem sido implementada para eliminar ruídos no sinal, sendo que essa abordagem tem a vantagem de preservar as propriedades do sinal ECG medido, possibilitando assim uma menor diferença no aspecto fisiológico do sinal e reduzindo ruídos oriundos da obtenção deles. (SINGH; TIWARI, 2006).

2.2.4.2 Segmentação do Sinal

A etapa de segmentação de batimentos é composta em particionar o sinal ECG de forma a destacar determinados segmentos do batimento cardíaco, como por exemplo segmentação para detecção do Complexo QRS ou segmentação para detecção do Pico R, sendo o objetivo facilitar o processo de detecção e classificação de arritmias baseadas em padrões destes sinais (SAYADI; SHAMSOLLAHI, 2009).

No que diz respeito à detecção do complexo QRS, vários estudos apresentam o uso de transformadas matemáticas tais como Wavelet e Hilbert para detecção e segmentação do complexo QRS, como por exemplo em (MADEIRO, 2013), (MANZAN, 2006) e entre outros.

Existem ainda outros métodos utilizados para a detecção e segmentação do complexo QRS, tais como redes neurais artificiais, filtros adaptativos e o algoritmo Pan & Tompkins (OLIVEIRA, 2007).

De acordo com o trabalho publicado por (COSTA; COSTA; REGIS 2015), o algoritmo de Pan-Tompkins realiza o reconhecimento do complexo QRS, utilizando limiares ajustados automaticamente de acordo com a frequência cardíaca e morfologia do complexo QRS, o que oferece uma adaptação periódica às mudanças no ECG e também a filtragem de ruídos significativos. O algoritmo é constituído por duas etapas de processamento: filtragem digital e regras de decisão. No processo de filtragem, o sinal de ECG é percorrido por um filtro passa-faixa com frequências de corte de 5Hz e 15Hz, com o objetivo de amenizar a influência das fontes de ruído e otimizar a relação sinal/ruído. Em seguida, a fim de realçar as deflexões de QRS, o sinal é derivado, elevado ao quadrado e então integrado com uma média móvel.

No trabalho proposto por (YOCHUM et al., 2016), é descrito uma metodologia baseada em Transformada Contínua de Wavelet para detectar ondas QRS, P e T. Este trabalho utiliza 12 variações de ECG para melhorar a detecção, uma vez que uma dessas variações pode conter mais perturbações do que outras. Combinando esses pontos encontrados em cada variação, determina-se quais pontos formam as ondas do ECG.

O trabalho apresentado por (ELGENDI, 2016) utiliza duas médias móveis para detectar o complexo QRS. Esse método, chamado TERMA, compara tais médias móveis para gerar blocos de interesse que correspondem aos complexos QRS e determina os picos R através dos máximos locais. Vale ressaltar que a metodologia TERMA não detecta todos os pontos de importância, concentrando-se apenas na detecção do complexo QRS e do pico R.


É importante ressaltar que o processo de segmentação do sinal é crucial para um bom funcionamento de um sistema automático para classificação de arritmias.

2.2.4.5 Extração das Características

Para a extração de características de um sinal ECG, técnicas tanto no domínio da frequência quanto no domínio do tempo podem ser utilizadas.

No domínio do tempo, a distância entre duas ondas R sucessivas conhecida como Intervalo RR é uma das características mais simples que pode ser extraída do sinal ECG (LUZ et al, 2015). As variações que ocorrem neste intervalo estão relacionadas à muitos casos de arritmia, sobretudo a rítmica, pois é a partir do Intervalo RR que se mede o ritmo cardíaco. A Figura 16 exibe um Intervalo RR em um sinal ECG.

Figura 16 - Intervalo RR



Fonte: (MY EKG, 2018).

O intervalo RR é um exemplo de padrão que pode ser facilmente visualizado por um especialista humano, mas devido ao longo registro de um sinal ECG, este processo acaba se tornando exaustivo.

Em (BAYDOUN et al., 2019) os autores propõem métodos para extração de características no domínio do tempo que permitem extrair do sinal ECG segmentos a partir da identificação dos pontos PQRST, assim como determinar os intervalos PR, QRS, RR e QT. Em (PAN; TOMPKINS, 1985) é proposto o algoritmo de Pan-Tompkins para detecção do intervalo QRS, sendo que com o complexo QRS identificado, os picos P e T podem ser determinados por meio da análise do comportamento do sinal, tendo em vista que o ponto P é o pico mais próximo antes de Q e o ponto T é o pico mais próximo depois de S. A escala do sinal é obtida com o auxílio do pulso quadrado de referência (tendo o usuário a possibilidade de selecionar

manualmente esse pulso para melhor precisão). No trabalho de (MITRA et al., 2012), os autores determinam a localização dos picos R através da segunda derivada do sinal utilizando interpolação de 5 pontos de Lagrange para diferenciação, tendo em vista que em geral, o pico R corresponde a componente de alta frequência no complexo QRS. Descobrir a localização dos picos R, é possível calcular a frequência cardíaca média.

Algoritmos de otimização, tais como o Algoritmo Genético (AG) e a Otimização por Enxame de Partículas (PSO) podem também ser utilizados para extração de características, onde a base de dados pode ser otimizada para que apenas os atributos mais relevantes de cada amostra alimentem o sistema de classificação (LUZ et al, 2015).

No trabalho apresentado em (YUSUF; HIDAYAT, 2019), é desenvolvido um sistema para extração de características para classificação de eletrocardiogramas em normal e anormal, fazendo uso de um algoritmo conhecido como *Mel-Frequency Cepstral Coefficient* (MFCC). O algoritmo é responsável por detectar os padrões de cada sinal por meio do domínio da frequência em conjunto com a transformada *Wavelet* e por fim, usando uma rede neural do tipo KNN para realizar a identificação e classificação de cada tipo de ECG.

Em (KHAN et al., 2019), é proposto um sistema para autenticação baseado em sinais de eletrocardiograma, onde o mesmo utiliza sinais ECG em sua camada de entrada. Cada registro é filtrado por meio de decomposição *Wavelet* e as características de cada amostra são identificadas e extraídas por meio do algoritmo de Decomposição do Modo Empírico, utilizando o domínio da frequência e do tempo.

2.1.3.4 Classificação dos sinais ECG

Após a etapa de extração de características, com os padrões mais significativos extraídos das amostras, é iniciado o processo de classificação das arritmias. Existem na literatura diversos algoritmos para esta tarefa, dos quais podem-se citar as Máquinas de Vetores de Suporte (SMVs), as Redes Neurais Artificiais (RNAs), o Discriminante Linear (LD) (RASCHKA, 2014) e a Computação por Reservatório (RC) (GAUTHIER, 2018).

As técnicas mais utilizadas na literatura são os classificadores baseados em Máquinas de Vetores de Suporte (ABAWAJY; KELAREV; CHOWDHURY, 2013) e Redes Neurais Artificiais (MARTIS et al., 2012; WANG et al., 2013). Outras técnicas como Discriminantes Lineares (CHAZAL; O'DWYER; REILLY, 2004) e a hibridização entre Máquinas de Vetores de Suporte e Redes Neurais Artificiais (HOMAEINEZHAD et al., 2012) também são aplicadas na classificação desses sinais.

A Computação por Reservatório (CR) é uma arquitetura indicada para trabalhar com séries temporais, o que permite sua implementação em sistemas que operam com sinal ECG. Como mostrado em (ESCALONA-MORAN et al., 2015), as CRs para estes sistemas mostram-se como um processo de aprendizado equivalente a uma regressão logística, possuindo a capacidade de operar com a adversidade de classes desbalanceadas e utilizar pouco poder computacional, facilitando assim seu uso para sistemas que realizam a etapa de classificação em tempo real.

Para desenvolvimento e testes dos sistemas classificadores de arritmia, dois paradigmas vêm sendo utilizados por diversos autores na literatura: interpaciente e intrapaciente.

Na abordagem interpaciente a bases de dados de treinamento e teste não possuem sinais dos mesmos pacientes. Enquanto que na abordagem intrapaciente, parte dos dados dos pacientes são utilizados para treino enquanto a outra parte, dos mesmos pacientes utilizados para treino, são utilizadas para teste.

2.1.3.5 Bancos De Dados Para Sistemas Automáticos e o Padrão AAMI.

A Associação para o Avanço da Instrumentação Médica (AAMI, 2012) tem por objetivo o avanço do desenvolvimento e uso seguro e eficaz de tecnologias médicas e, com o intuito de padronizar o processo de avaliação dos métodos que vêm sendo propostos e desenvolvidos para classificação automática de arritmia, desenvolveu um protocolo especificado pela norma ANSI/AAMI EC57:1998 (AAMI EC57). O protocolo procura definir direcionamentos para a realização de testes e análise de resultados para que possam ser comparáveis e reproduzidos por outros trabalhos (LUZ et al., 2016).

Para o desenvolvimento de sistemas de classificação de arritmia cardíaca, a norma da AAMI recomenda o uso de uma das 5 bases de dados públicas de sinais de ECG apresentadas na tabela 2.

Tabela 2 - Bases de dados públicas de sinais ECG recomendadas pela AAMI.

Base de dados	Característica
<i>AHA</i> , The American Heart Association Database for Evaluation of Ventricular Arrhythmia Detectors (PHYSIONET, 2003).	80 registros de 35 minutos cada.
<i>CU</i> , The Creighton University Sustained Ventricular Arrhythmia Database (PHYSIONET, 2016).	35 registros de 8 minutos cada.
<i>ESC</i> : The European Society of Cardiology ST-T Database (PHYSIONET, 2016).	90 registros de 2 horas cada.
<i>NST</i> , The Noise Stress Test Database (PHYSIONET, 2016).	12 registros de ECG de 30 minutos cada.
<i>MIT-BIH</i> , The Massachusetts Institute of Technology - Beth Israel Hospital Arrhythmia Database (PHYSIONET, 2018).	48 registros de 30 minutos cada.

Fonte: Adaptada de (LUZ et al., 2016).

A base de dados da MIT-BIH vem sendo utilizada pela maioria dos trabalhos encontrados na literatura (PETMEZAS et al., 2022), devido principalmente por ser a base mais representativa de sinais de arritmias, apresentando sinais de 15 classes, que podem ser mapeadas para as superclasses recomendadas pela AAMI (Tabela 3).

Tabela 3 - Classes do MIT-BIH e seu mapeamento para o AAMI.

Classes da AAMI	Batimentos no MIT-BIH
Batimentos Normais (N)	Normais; De escape; Escape Atrial; Nodal (Juncional); Bloqueio no ramo esquerdo do feixe de His; Bloqueio no ramo direito do feixe de His.
Batimentos Ectópicos Supraventriculares(S)	Prematura atrial aberrante; Contração atrial prematura; Prematura Nodal (Juncional).
Batimentos Ectópicos Ventriculares(V)	Escape ventricular; Contração ventricular prematura
Batimentos de Fusão (F)	Fusão de ventricular e normal
Batimentos desconhecidos(Q)	Ritmado; Não classificado; Fusão de ritmado e normal

Fonte: Elaboração própria a partir de (DE CHAZAL; O'DWYER; REILLY, 2004).

A AAMI recomenda como medidas de avaliação dos métodos automáticos de classificação desenvolvidos as seguintes métricas: Acurácia, Sensibilidade e Precisão.

A acurácia (Acc) mede o desempenho geral do modelo indicando o quanto determinado número de amostras foram corretamente classificadas, positivas ou negativas, sendo definida por:

$$Acc = \frac{TP+TN}{(TP+TN+FP+FN)} \quad (1)$$

Onde os Verdadeiros positivos são representados pela variável TP, os Verdadeiros negativos por TN, os Faltos positivos por FP e os Falsos negativos por FN.

A Sensibilidade (Sen) mede a taxa de elementos Verdadeiros Positivos que foram classificados corretamente, sendo definida por:

$$Sen = \frac{TP}{(TP+FN)} \quad (2)$$

A Precisão (+P) mede a taxa de elementos que realmente são Verdadeiros Positivos, dentro os que foram classificados, sendo definida por:

$$+p = \frac{TP}{(TP+FP)} \quad (3)$$

Nos sistemas de classificação automática apresentados na literatura, a Sensibilidade e Precisão são métricas importantes para avaliação do sistema, pois ambas têm um impacto maior na análise devido suas equações possuírem um peso maior dos Verdadeiros Positivos. Na literatura existem diversos trabalhos que se baseiam nestas métricas para avaliação do desempenho dos sistemas automáticos (BAIA, 2019).

O F1-Score (F1) é definido como uma métrica de avaliação que mostra a média entre sensibilidade e precisão do modelo de predição (CHAVES; ANDRADE, 2022). Seu cálculo é demonstrado por:

$$F1-Score = 2 * \frac{(precisão * sensibilidade)}{(precisão + sensibilidade)} \quad (4)$$

Por fim, os sistemas de classificação automática também fazem uso da matriz de confusão para expor seus resultados. Uma matriz de confusão é uma matriz de duas dimensões que apresenta todos os resultados (TP, TN, FP e FN) de um classificador. A Figura 17 apresenta a estrutura de uma matriz de confusão simples.

Figura 17 - Exemplo de matriz de confusão simples.

		Classe Verdadeira	
		Positivo	Negativo
Classe Predita	Positivo	TP	FP
	Negativo	FN	TN

Fonte: Adaptado de (FAWCETT, 2006).

2.3 Estado da Arte de sistemas para classificação de arritmias

Diversos trabalhos vêm sendo apresentados na literatura com resultados de sistemas desenvolvidos para classificação de arritmias. A seguir serão apresentados os trabalhos de acordo com o paradigma utilizado: interpaciente ou intrapaciente. É importante ressaltar que os

trabalhos descritos neste tópico não são os mesmos utilizados para a comparação de resultados obtidos.

2.3.1 Paradigma Interpaciente

Em (LIMA, 2022), é proposto um sistema composto por uma rede neural convolucional 1D para detecção e classificação dos batimentos cardíacos de alguns tipos de arritmias. Para o treinamento da rede, foi utilizada a base de dados do MIT-BIH, usando o formato em série temporal. O sistema obteve resultados de 93,35% de acurácia, 93,12% para precisão e 93,08% para recall.

No sistema proposto por (NAGATA; CANDIDO; SILVA, 2021), é implementada uma CNN-1D para o diagnóstico automático de arritmias, usando a base de dados do *MIT-BIH Arrhythmia Database*, adotando o formato de sinal ECG em série temporal para a camada de entrada. O estudo obteve a acurácia média de 98,8%.

No trabalho proposto por (PASSO et al., 2020), foi desenvolvido uma arquitetura de rede neural convolucional 1D para a classificação de arritmias cardíacas conforme a morfologia do sinal do eletrocardiograma apresentado ao sistema. A base de dados utilizada para o treinamento da rede foi a *MIT-BIH Arrhythmia Database*, onde as amostras em formato de sinal temporal foram convertidas para imagem 2D. A metodologia proposta obteve acurácia de 98,52%.

Em (Baia, 2019), foram implementados dois sistemas, um rítmico e um morfológico. Ambos os sistemas são fundamentados em uma estrutura competitiva de Redes Neurais Convolucionais Auto-associativas 1D, onde as mesmas foram treinadas para reproduzir o sinal codificado na camada de entrada. O classificador rítmico foi desenvolvido a partir do uso dos sinais ECG, não sendo necessário o processo de extração de padrões; o classificador morfológico se baseou no complexo QRS extraído do sinal ECG. Foi utilizada a base de dados *MIT-BIH Arrhythmia*. Para o sistema proposto foi obtida a acurácia de 88,9%, e 81,73% para o Classificador Morfológico.

No sistema proposto por (WANG et al., 2019), foi aplicada *data augmentation* para realizar o balanceamento das classes para base de dados (MIT-BIH) de treino por meio da geração de dados artificiais. O modelo de classificação é composto por uma rede neural LSTM e utilizando a métrica F1 score como referência, o autor afirma que obteve o valor de 88.3%.

No trabalho proposto por (LUZ, 2012), foi desenvolvido uma nova solução para classificação de arritmias baseado em classificação hierárquica, assim como foram investigadas novas características para representação do batimento cardíaco, estas que são baseadas em

representação bidimensional do sinal ECG, conhecida como Vectocardiograma ou VCG. Foi utilizado o banco de dados MIT-BIH e o sistema obteve acurácia de 88,8%.

Em (ROHMANTRI; SURANTHA, 2020), o sistema proposto faz uso de redes neurais convolucionais 2D, usando imagens com dimensões 128x128, obtidas através da conversão de sinais de eletrocardiograma. Os autores tentam realizar a classificação de arritmias utilizando o banco de dados MIT-BIH e elaboram testes referentes a diferentes tamanhos para a imagem que será apresentada para a rede neural, visando encontrar a dimensão com melhor eficiência. Também são testadas diferentes quantidades de classes de arritmia para treino e teste, onde é obtida acurácia de 98,91% para duas classes e 98,10% para 7 classes.

A tabela 4 apresenta um resumo de todas as referências utilizadas para o estado da arte de sistemas de classificação de arritmias usando a abordagem interpaciente.

Tabela 4 - Resumo de trabalhos usando abordagem interpaciente.

Autor	Técnica	Acurácia	Sensibilidade	Precisão
LIMA, 2022	CNN-1D	93,35%	93,12%	93,08%
NAGATA; CANDIDO; SILVA, 2021	CNN-1D	98,8%	93,33%	96,36
PASSO et al., 2020	CNN-1D	90,39%	56%	65,11%
Baia, 2019	CNN <i>Autoencoder</i> 1D	81,73%	78,42%	65,68%
WANG et al., 2019	LSTM	99,53%	99,88%	99,81%
LUZ, 2012	Classificação hierárquica	89,1%	79,1%	82,33%
ROHMANTRIL; SURANTHA, 2020	CNN-2D	98,45%	98,43%	98,45%

Fonte: Autoral.

2.3.2 Abordagem Intrapaciente

No sistema proposto por (SANTANA, 2021), é desenvolvida uma metodologia para detecção de arritmias, por meio de CNN 2D. A principal característica do sistema é o uso de imagens em nível de cinza de 15 x 15 pixels, contendo os valores de um batimento cardíaco do sinal de ECG. Para validar e testar a metodologia proposta, foi utilizado o banco de dados MIT-BIH e o mesmo obteve precisão de 92,31% e acurácia de 99,13%.

Na metodologia proposta por (SILVA; MATOS; LOPES, 2022), é implementado um sistema por meio de aprendizado de máquina SVM para o reconhecimento de arritmias. Utilizando a base de dados do MIT-BIH, onde é realizada a conversão de série temporal para imagens digital para serem usados como entrada. O trabalho apresenta seu resultado obtido por meio de acurácia de 94%.

No trabalho proposto por (MESSIAS, 2022), é elaborado um estudo onde são utilizadas arquiteturas CNN com um e dois canais para classificação de arritmias. O sistema faz uso de sinais de ECG do banco de dados do MIT-BIH por meio de imagens digitais, fazendo também o uso da técnica de *Data Augmentation* para o balanceamento de dados. O trabalho obteve métricas de 84,11% de acurácia, 84% de sensibilidade e 78% de precisão para o modelo CNN. Para a arquitetura DC-CNN, obteve-se 85,66% de acurácia, 86% de sensibilidade e 79% de precisão.

No sistema desenvolvido por (YU, 2020), é utilizado uma rede neural convolucional 1D para treinar e classificar sinais ECG. A base de dados do MIT-BIH foi processada visualmente e um método de detecção por formas de onda foi também implementado para a extração das características do complexo QRS, assim usando imagens 2D dos sinais ECG na camada de entrada do algoritmo. O experimento obteve métricas de 95.9% de acurácia (Acc), sensibilidade de 93.0% e especificidade de 91.9% para o batimento ectópico ventricular. Para os batimentos ectópicos supraventriculares, o sistema obteve acurácia de 93.2%, sensibilidade de 81.3% e especificidade de 90.5%.

Em (LU et al., 2021), foi proposta a elaboração de uma rede neural convolucional 1 D com perda focal para a classificação de arritmias aplicado em base de dados de arritmias desbalanceados. O sistema usa para o treinamento da rede neural a base de dados do MIT-BIH, usando também a perda focal para aprimorar o desempenho do sistema quando o mesmo utiliza base de dados desbalanceados, ou seja, que possuam poucas amostras em suas classes. O formato utilizado das amostras na camada de entrada foi o de imagens 2D dos sinais ECG. O sistema obteve métricas de 98.55% de acurácia, precisão de 95% e sensibilidade de 93%.

Tabela 5 - Resumo de trabalhos usando abordagem intrapaciente.

Autor	Técnica	Acurácia	Sensibilidade	Precisão
(SANTANA, 2021)	CNN-2D	93,35%	93,12%	93,08%
(SILVA; MATOS; LOPES, 2022)	Subspace Knn / SVM	94% 94,1%	-	-
(MESSIAS, 2022)	CNN 1D/ DC-CNN	84,11% 85,66%	84% 86%	78% 79%
(YU, 2020)	CNN-1D	94.55	87,15%	-
(LU et al., 2021)	CNN-1D	98.55%	95%	93%

Fonte: Autoral.

2.4 Redes Neurais Artificiais


As redes neurais artificiais são técnicas computacionais que possuem um modelo inspirado na estrutura neural de organismos inteligentes que adquirem conhecimento por meio

da experiência. Assim, a RNA é capaz de identificar padrões, ou seja, detêm a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, o que torna o seu uso bastante eficiente em diversas aplicações (BRAGA et al., 2000)

As RNAs foram inspiradas baseando-se nos neurônios presentes no cérebro humano, que através de uma estrutura complexa, é capaz de efetuar o processamento da informação de forma rápida e reconhecer padrões. Uma RNA possui uma propensão natural para armazenar conhecimento experimental, de forma que o conhecimento é adquirido durante um processo de aprendizagem e pela força de conexão entre os neurônios (pesos sinápticos), que são utilizados para armazenar o conhecimento através de um algoritmo de aprendizagem. Através da sua estrutura e da capacidade de generalização, que consiste em produzir uma resposta para uma entrada que não estava presente no momento da aprendizagem, torna-se possível a resolução de problemas de complexidade alta (HAYKIN,1999).

A RNA portanda é caracterizada por sua arquitetura e pela aprendizagem. A arquitetura é determinada pelo tipo, número de unidades de processamento e a forma que é dada a conexão entre os neurônios e a aprendizagem diz respeito as regras utilizadas para o ajuste de pesos entre os neurônios e o tipo de informação que ela está utilizando para submeter a essas regras (FACELI et al., 2011). A figura 18 apresenta a estrutura de uma RNA do tipo Perceptron de múltiplas camadas.

Figura 18 - Estrutura de uma RNA.



Fonte: (FIORIN et al., 2011).

Modelos computacionais que utilizam técnicas de aprendizado de máquina tais como redes neurais artificiais, são amplamente indicados para a resolução de tarefas consideradas complexas, como reconhecimento e classificação de padrões em imagens, detecção de anomalias e etc. (GOODFELLOW; BENGIO; COURVILLE, 2016).

Aprendizado de máquina é uma área de pesquisa da Inteligência Artificial que busca o desenvolvimento de sistemas com a capacidade de aprender a executar uma dada tarefa com

sua própria experiência (FACELI et al., 2011). Isso leva ao desenho de sistemas capazes de aprender de forma automática, utilizando um conjunto de dados que representam experiências passadas. Trata-se de uma área de pesquisa multidisciplinar que engloba inteligência artificial, probabilidade e estatística, teoria da complexidade computacional, teoria da informação e entre outros. Exemplos de tarefas de Aprendizado de Máquina são: classificação e agrupamento de dados, regressão e previsão de séries temporais.

O processo de aprendizado pode ser do tipo supervisionado, não-supervisionado e por reforço. No método de aprendizado supervisionado, para cada amostra apresentada ao algoritmo de aprendizado é necessário apresentar a resposta desejada. No aprendizado não supervisionado, as amostras são fornecidas ao algoritmo sem uma resposta desejada. O algoritmo então, armazena as amostras por meio das similaridades de seus atributos. O algoritmo analisa as amostras fornecidas e tenta determinar se algumas delas podem ser aglomeradas de alguma forma, formando agrupamentos ou *clusters*. Após a determinação dos *clusters*, em geral é necessária uma análise para determinar o que cada agrupamento significa no contexto do problema (LUDERMIR, 2021). A aprendizagem por reforço é um método no qual o agente, sem o conhecimento prévio de quais ações são melhores para executar, deve experimentar o ambiente e adquirir conhecimento conforme a progressão da interação com ele. A expectativa é que, conforme o agente interage com o ambiente, seja capaz de aprimorar seu desempenho.

O Aprendizado Profundo é um ramo do aprendizado de máquina que utilizam arquiteturas hierárquicas para aprender abstrações de alto nível em um determinado conjunto de dados. É uma abordagem que se encontra em constante progresso na literatura atual e comumente usada em diversas aplicações da inteligência artificial, como por exemplo, transferência de aprendizado, análise semântica, processamento de linguagem natural e visão computacional (GUO et al., 2016). As redes com arquitetura de aprendizagem profunda possuem múltiplas camadas de processamento não linear para reconhecimento de padrões. (LECUN; BENGIO; HINTON, 2015). Essas camadas possibilitam a extração automática de características de um conjunto de treinamento, sem a necessidade de implementação direta de técnicas de extração de características, reconhecimento de padrões e processamento de imagens (HUA et al., 2015). Como resultado, as etapas de extração, seleção e classificação de características são realizadas pelo próprio sistema, com pouca necessidade de intervenção humana (HUA et al., 2015; CHENG et al., 2016).


As RNAs baseadas em aprendizado profundo apresentam algumas arquiteturas e dentre elas destacam-se as Redes Neurais Recorrentes (RNN), as Redes de Memória de Longo Prazo

(LSTM), as Redes Neurais Auto Associativas, as Redes Auto Associativas Empilhadas, e as Redes Neurais Convolucionais (CNN) (BAIA, 2019). Considerando que neste trabalho foi desenvolvido um sistema de uma estrutura competitiva de redes neurais convolucionais autoassociativas para classificação de arritmias, será apresentado a seguir com mais detalhes as redes neurais convolucionais e as redes neurais convolucionais autoassociativas.

2.2.2. Redes Neurais Convolucionais

Uma Rede Neural Convolucional (Convolutional Neural Network – CNN) é uma arquitetura de rede neural artificial, variante do *Perceptron* de múltiplas camadas, sendo comumente usada em aplicações de detecção, classificação e reconhecimento em imagens e vídeos. A arquitetura de uma CNN é apresentada na figura 19.

Figura 19 - Estrutura representativa de uma CNN.



Fonte: (ARAÚJO et al., 2017).

A camada de entrada desempenha a função de receber os padrões que são apresentados para que a CNN possa processar, sendo esta entrada geralmente em formato de imagens digitais (FREITAS et al, 2019).

A camada convolucional define filtros que executam o processo de convolução para converter as imagens de entrada ou mapas de características da camada de entrada nos mapas de características de saída. Os neurônios localizados nesta camada aplicam filtros de convolução na imagem de entrada e os resultados são considerados como padrões aprendidos e armazenados em um mapa de características na saída da camada. As camadas convolucionais aplicam os filtros de convolução em uma pequena região dos dados de entrada para compor um padrão específico da componente sendo tratada, como por exemplo cor em uma imagem RGB. Este processo costuma ser executado com o apoio de uma função de ativação que adiciona um comportamento não linear à operação. Funções de ativação comuns são a função do tipo linear retificada (ReLU), a tangente hiperbólica, a sigmoide e a *Softmax*. Os mapas de características,

após a função de ativação, representam os padrões extraídos e são entradas para a próxima camada (LOPEZ; MATTOS, 2021).

Quando uma CNN é aplicada para trabalhar com imagens digitais, é utilizado o formato bidimensional para o armazenamento dos valores de cada pixel, e em cada posição da imagem é aplicado um detector de características otimizável, conhecido como filtro ou *kernel* (YAMASHITA et al., 2018). A figura 20 apresenta um exemplo de aplicação de um filtro ou kernel.

Figura 20 - Exemplo de aplicação do filtro ou kernel para reconhecer o padrão do número 4.




Fonte: (CHOLLET, 2021).

A camada de *Pooling*, após a camada convolucional, tem a finalidade de reduzir o número de parâmetros que foram resultado da camada de convolução, dividindo a matriz, proveniente dessa etapa anterior, em várias partes e obtendo novos os parâmetros. O *Pooling* é definido como um processo importante durante a construção de uma CNN, pois ele realiza a redução das dimensões do mapa de ativação, mantendo apenas os padrões considerados importantes, enquanto reduz a invariância espacial, assim reduzindo o número de padrões que podem ser aprendidos para o modelo e evitando que a rede neural seja sobrecarregada durante o processo de aprendizagem. O *Pooling* permite que a CNN incorpore todas as três dimensões de uma imagem, para que assim ela tenha sucesso em reconhecer um determinado objeto, mesmo que o seu formato esteja distorcido ou apresentado de um ângulo diferente, por exemplo. Existem vários tipos de *Pooling*, além do *Max Pooling* e *Average Pooling*, tais como, *Stochastic Pooling* e *Spatial Pyramid Pooling*, sendo que o *Max Pooling* é o mais utilizado em implementações de CNN's no meio acadêmico (AJIT; ACHARYA; SAMANTA, 2020).

O *Max Pooling* faz a redução das dimensões das amostras, obtendo o maior valor de cada matriz do mapa de ativação e forma uma matriz separada dela. Esta metodologia assegura que os padrões que podem ser aprendidos permaneçam limitados em número, enquanto os padrões que mais se destacam são preservados de cada amostra. O *Max Pooling* costuma ser

realizado utilizando um filtro 2x2 (AJIT; ACHARYA; SAMANTA, 2020). A Figura 21 apresenta um exemplo do funcionamento do *Max Pooling*.

Figura 21- Funcionamento da Max Pooling.



Fonte: (KNOWLEDGE TRANSFER, 2021).

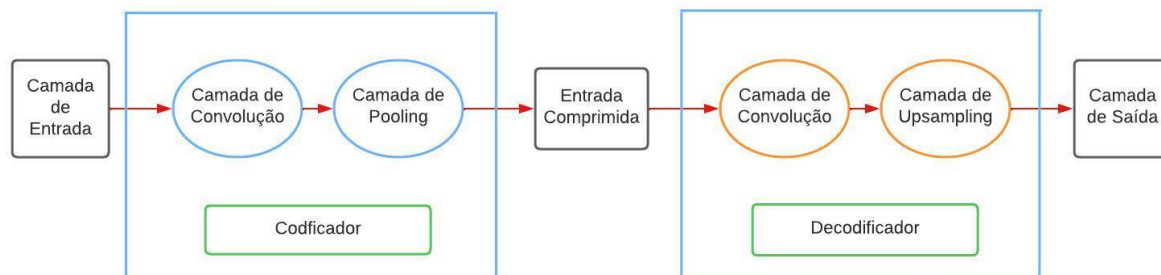
A última camada, a camada densa, tem cada um dos seus neurônios conectados a todos os outros da camada anterior. Esta camada realiza uma avaliação abrangente dos padrões extraídos nas camadas convolucionais e geram um vetor de probabilidades N-dimensional, em que N é o número de características na saída da camada densa. Após a camada densa final, uma função de ativação é utilizada para fornecer a probabilidade de classificação final de cada amostra de dados (LOPES; MATTOS, 2021).

Para os casos em que é necessário executar uma tarefa de classificação, a camada de saída é designada para operar com a função de ativação *softmax*. Esta função converte um vetor não formalizado em um normalizado, dentro de uma distribuição de probabilidade, onde cada elemento é alocado em um intervalo de valor 0 a 1 (CS231N, 2017).

2.2.3 Rede Neural Convolutacional Autoassociativa

Uma CNN-Autoassociativa (CAE – Convolutional Autoencoder) como apresentada na Figura 22, é uma arquitetura de rede que tem por objetivo a reconstrução na sua saída das imagens apresentadas em sua entrada. Este tipo de arquitetura tem a capacidade de compactar a entrada em uma representação de espaço latente, podendo então reconstruir a saída dessa representação, sendo sua arquitetura composta por duas partes, a camada codificadora e a camada decodificadora. (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 22 - Representação da estrutura de uma CNN Autoassociativa.



Fonte: Adaptada de (GOODFELLOW; BENGIO; COURVILLE, 2016).

A camada codificadora (representada pela função $f(x)$) tem a função de compactar (comprimir) a entrada em uma representação de espaço latente, podendo ser formada por diversas camadas de convolução e *pooling*, para que o sinal possa ser comprimido com suas principais características filtradas, e a camada decodificadora (representada pela função $g(x)$) tem a função de reconstruir a entrada, sendo que neste caso as camadas de convolução e *pooling* também estão presentes, mas realizando operações de forma contrária, para a reconstrução dos dados de entrada. O codificador e decodificador devem ser treinados simultaneamente para redução do erro de reconstrução na saída da CAE. As CAE's podem ter diversas aplicações, como por exemplo, como modelos geracionais, para eliminação de ruídos em imagens, para detecção de outliers e para segmentação de imagens (GOODFELLOW; BENGIO; COURVILLE, 2016).

Uma rede neural em sua estrutura, pode se adaptar ao conjunto de dados por meio de uma função de custo. O objetivo dessa função é oferecer uma métrica do quão longe, ou próximo, o modelo está da reprodução fidedigna ao conjunto de dados. No caso das CNN autoassociativas, a função de custo mais utilizada é a média das distâncias euclidianas entre o resultado esperado e a reconstrução efetuada pelo sistema (JABBAR et al., 2020) podendo ser calculada de acordo com:

$$L_{ae} = \frac{1}{n} \sum_{i=0}^n \|x - f_{\theta}(g_{\theta}(x))\| \quad (4)$$

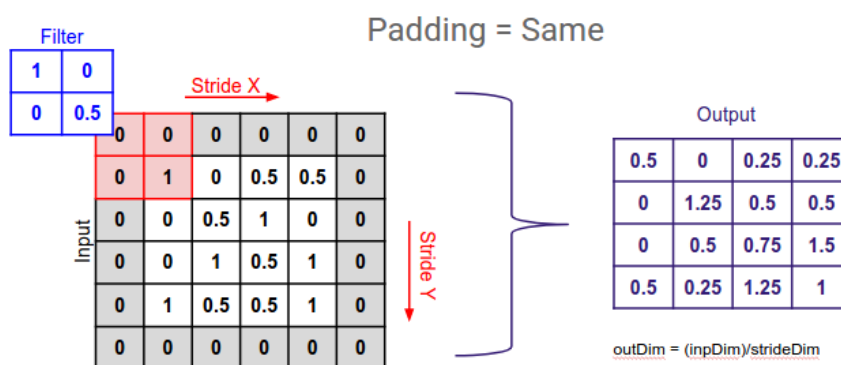
Onde f_{θ} representa a camada (ou $f(x)$) do decodificador e g_{θ} a camada (ou $g(x)$) do codificador. Cada função, $f(\theta)$ e $g(\theta)$, representa uma estrutura do modelo. Sendo assim, o número de camadas e neurônios da arquitetura dependem do problema e deve ser definida pelo usuário. Após a aplicação de g_{θ} nos dados de entrada obtemos uma nova representação dos

dados de entrada. Esse novo conjunto de dados é conhecido como o espaço latente resultante da aplicação da função g_θ (GOODFELLOW; BENGIO; COURVILLE, 2016).

É importante observar que tradicionalmente, CNNs autoassociativas são treinadas para reproduzir o sinal da camada de saída o mais similar possível ao apresentado na camada de entrada. A diferença entre o sinal de entrada e saída pode ser medido por meio de uma função de perda, como por exemplo, o erro médio quadrático (PIHLGREN; SANDIN; LIWICKI, 2020).

Em relação às redes neurais convolucionais autoassociativas, uma outra técnica que pode também ser utilizadas durante sua implementação é o *Padding*. Este processo é responsável por adicionar pixels ao redor da imagem antes da operação de convolução, para que assim seja mantida a dimensionalidade original da imagem durante sua etapa de reconstrução, assim como facilitar a identificação da classe alvo para a rede (CLAPPIS, 2019). A figura 23 demonstra uma exemplificação da aplicação de *Padding*.

Figura 23 - Exemplo de aplicação de *Padding*.



Fonte: (PERERA, 2018).


Como mencionando anteriormente, as redes neurais convolucionais autoassociativas possuem camadas de codificação e decodificação, sendo que a camada de decodificação costuma ser implementada com uso da técnica de *Upsampling*, que é responsável por permitir que o sinal reconstruído pela CAE produzido na saída possua as mesmas dimensões que o sinal de entrada (MITTELMAN, 2015).

3 SISTEMA PARA CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS

3.1 Introdução

Neste trabalho é proposto um sistema para classificação de arritmias cardíacas baseado em uma estrutura competitiva de redes neurais convolucionais *autoassociativas*. O sistema para classificação a partir de sinais de ECG é composto por três redes neurais convolucionais autoassociativas (CAE 1, CAE 2 e CAE 3), organizadas em uma estrutura paralela, e operando de forma competitiva. A estrutura pode classificar 3 classes: batimentos Normais (N), Ectópicos Supraventriculares (S) e Ectópicos Ventriculares (V). A Figura 24 apresenta a estrutura do sistema proposto.

Figura 24 - Estrutura do sistema para classificação de arritmias.



Fonte: Autoral.

Para o desenvolvimento da estrutura competitiva classificadora, cada CAE foi treinada individualmente para reconstrução da imagem do sinal ECG (complexo QRS) apresentado na sua entrada. Ao invés da utilização direta do sinal de ECG temporal 1D como sinal de entrada do sistema, foi realizada a conversão e armazenamento desses dados para o formato 2D. O dado tabular 1D que possui 180 amostras por registro, onde cada um representa um segmento de batimento extraído dos sinais ECG, foi convertido e armazenado diretamente em imagens digitais, com o objetivo de utilizar a capacidade das CNNs para reconhecimento de padrões e extração de características em imagens. Com o objetivo de encontrar a melhor configuração para a estrutura competitiva proposta, considerando as dimensões da imagem, os dados em série temporal 1D foram convertidos para os tamanhos 32x32, 64x64 e 128x128, e separadamente foram efetuados testes comparativos, onde as imagens serviram de entrada para a rede. O

formato 64x64 obteve as melhores métricas de desempenho quando comparado aos dois outros formatos analisados, como apresentado na Tabela X, na seção de Resultados.

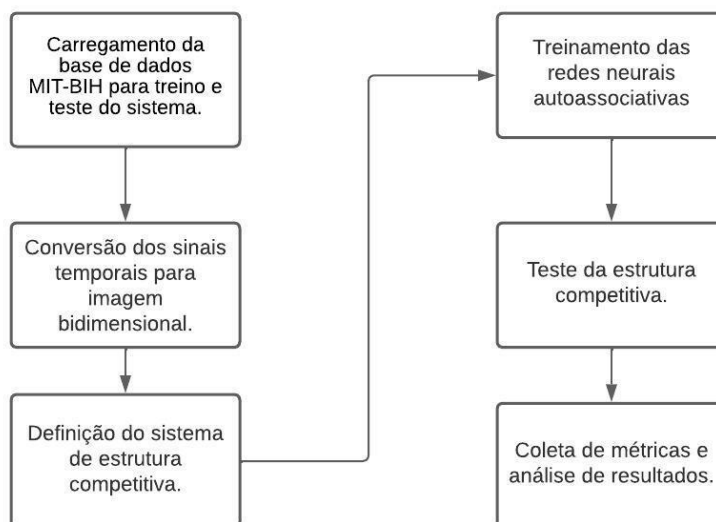
A CAE 1 foi treinada apenas com imagens de sinais ECG de pacientes com batimentos cardíacos normais, a CAE 2 for treinada com sinais ECG de pacientes com batimentos Ectópicos Supraventriculares e a CAE 3 treinada com dados de pacientes com batimentos Ectópicos Ventriculares. Cada CAE, durante o seu processo de treinamento, aprendeu as características dos sinais (imagem do complexo QRS) apresentadas para as mesmas, sendo que após treinamento, quando se apresenta para cada CAE novos padrões não utilizados na fase de treino, mas que fazem parte da mesma distribuição dos dados usados para seu treinamento, cada CAE consegue reconstruir o sinal (imagem do complexo QRS), com um valor pequeno de erro.

Após a finalização da fase de treinamento das CAEs, as mesmas foram organizadas na estrutura paralela competitiva da Figura 14, podendo então a estrutura atuar como um sistema de classificação de arritmias, sendo que quando um sinal ECG (imagem complexo QRS) for apresentado para a estrutura competitiva, as três redes CAEs tentarão reconstruir simultaneamente a imagem nas suas saídas, sendo que uma delas apresentará um menor erro/maior similaridade entre as imagens de entrada/saída (devido a mesma ter sido treinada com padrões próximos ao padrão que está sendo apresentado na entrada da estrutura). A CAE que apresentar o menor erro, ou seja, maior similaridade entre as imagens de entrada e saída será considerada a CAE vencedora e a imagem de entrada será classificada de acordo com a classe representativa da CAE vencedora. Duas estruturas foram desenvolvidas para análise comparativa de desempenho, uma estrutura usando paradigma interpaciente e outra usando paradigma intrapaciente.

3.2 Metodologia

A figura 25 apresenta o fluxograma da metodologia adotada para desenvolvimento do sistema proposto para classificação de arritmias. A metodologia foi adotada tanto para a análise interpaciente quanto para a análise intrapaciente.

Figura 25 - Fluxograma da metodologia adotada.



Fonte: Elaboração própria.

Na primeira etapa foi realizado o carregamento da base de dados para treino e teste do sistema de classificação proposto, sendo que entre as bases de dados recomendadas pela AAMI, optou-se pelo uso da base de dados MIT- BIH, por esta ser a base mais representativa de sinais de arritmias, apresentando sinais de 15 classes, que podem ser mapeadas para as superclasses recomendadas pela AAMI apresentadas na tabela 3.

Na segunda etapa foi realizada a conversão dos sinais temporais de ECG (complexo QRS) para imagens em escala de cinza que serviram de entrada para as redes CAE's. Vale ressaltar que a dimensão escolhida para as imagens fornecidas para a camada de entrada da estrutura competitiva foi de 64x64.

Na terceira etapa foram definidas as estruturas das redes CAE1, CAE 2 e CAE 3 que foram utilizadas posteriormente na estrutura competitiva classificadora, seguida então da quarta etapa onde foi realizado o treinamento de cada uma destas redes.

Na quinta etapa foi realizado o teste da estrutura competitiva, seguida da etapa de cálculo de todas as métricas necessárias para avaliação de desempenho e análise de resultados.

O ambiente de desenvolvimento utilizado neste trabalho foi um computador com as seguintes configurações:

- Processador Ryzen 5 2400 (3.6Ghz), contendo 4 núcleos e 8 threads;
- Placa de Vídeo Gigabyte GTX 1660 OC.
- Memória RAM de 16 GB 2666Mhz;

- Armazenamento SSD com 512Gb;
- Sistema Operacional Windows 10 Pro.

A seguir será apresentada com mais detalhes cada uma das etapas da metodologia utilizada para desenvolvimento do sistema proposto para classificação de arritmias cardíacas.

3.2.1 Etapa de Carregamento da base de dados MIT-BIH

Os sinais de ECG utilizados para o treinamento e teste da estrutura competitiva autoassociativa proposta foram obtidos a partir da base de dados pública MIT-BIH. Esta base possui 48 registros de sinais de ECG, com duração de 30 minutos cada, de 47 pacientes estudados pelo *BIH Arrhythmia Laboratory*. As gravações foram digitalizadas em 360 amostras por segundo por canal, com resolução de 11 bits, em uma faixa de 10 mV. Uma equipe de cardiologistas fez registros (Figura 26) independentemente para cada dado, resolvendo as discordâncias para que as anotações de referência fossem legíveis por computador em cada batida adicionada ao banco de dados (PHYSIONET, 2018).

Figura 26 - Exemplo de registro no banco de dados MIT-BIH.




Fonte: (ARCHIVE PHYSIONET, 2018).

Para análise de desempenho são propostos dois sistemas de classificação utilizando duas divisões da base de dados para treino e teste: interpaciente e intrapaciente. Para análise interpaciente foi utilizada a divisão do banco de dados MIT-BIH em DS1 (treino) e DS2 (teste) proposta em (DE CHAZAL et al. 2004), sendo que esta divisão da base de dados vem sendo utilizada em muitos trabalhos na literatura, facilitando assim a análise comparativa de resultados e desempenho para análise intrapaciente foi utilizada a divisão em treino e teste disponibilizados em (FAZELI, 2017) onde os dados são divididos em 80% para treino e 20% para testes. Para ambos os casos, seguindo a metodologia adotada por muitos trabalhos já apresentados na literatura, que utilizam a base de dados MIT-BIH, foram retirados do estudo os batimentos relativos à classe de batimentos desconhecidos e *fusion*, pois o número de registros pertencentes

a estas classes são consideravelmente reduzidos, ficando apenas as seguintes classes a serem utilizadas no sistema de classificação:

- Classe N (Figura 27), referente a sinais de ECG com batimento cardíaco considerado normal, considerando a classe de Batimentos Normais da AAMI.
- Classe S (Figura 27), referente a classe de Batimentos Ectópicos Supraventriculares da AAMI.
- Classe V (Figura 27), referente a classe de Batimentos Ectópicos Ventriculares da AAMI.

Figura 27 - Imagens dos tipos de arritmias presentes na base de dados e suas respectivas classes.



Fonte: Autoral.

Considerando o banco de dados para análise interpaciente, a Tabela 6 exibe o total de amostras por classes para base DS1 e DS2. A base de dados utilizada, que apresenta os sinais de ECG da base MIT-BIH já segmentada (complexo QRS) e separada em DS1 e DS2, foi obtida de (BAIA, 2019), que se baseou na extração dos complexos QRS do sinal ECG através do algoritmo de Pan-Tomkins (PAN e TOMPKINS, 1985) através de funções desenvolvidas em Matlab presentes em (SZNAJDER e ŁUKOWSKA, 2017), a qual também rotula as classes de cada complexo QRS. Cada registro da base de dados (complexo QRS) é composto por 180 amostras. É importante salientar aqui que, para divisão da base de dados em DS1 e DS2, em (DE CHAZAL et al. 2004) é indicado quais pacientes da base MIT-BIH deverão ir para base DS1 e quais pacientes deverão ir para base DS2, sendo que no total de 44 pacientes, 22 pacientes são usados na base DS1 de treino e 22 pacientes na base DS2 de teste.

Tabela 6 - Número de amostras da base de dados interpaciente.

	Classe N	Classe S	Classe V	Total
DS1 (treino)	45824	976	3788	50588
DS2 (teste)	44033	2050	3220	49303

Fonte: Autoral.

A tabela 7 apresenta a divisão da base de treino e teste para o caso intrapaciente.

Tabela 7 - Número de amostras da base de dados intrapaciente.

Classes	Número de amostras (base de treino)	Número de amostras (base de testes).
Classe N	72471	18118
Classe S	2223	556
Classe V	5788	1448


Fonte: Autoral.

Para o carregamento e análise da base de dados foi utilizada a linguagem de programação Python, utilizando a biblioteca Pandas e Seaborn.

3.2.2 Etapa de Conversão dos dados em imagens

Para a entrada de dados na estrutura competitiva autoassociativa, foi definido o formato em imagem digital (2D) do complexo QRS. Cada registro de complexo QRS (1D) da base de dados contém 180 amostras (tanto para base análise interpaciente quanto para intrapaciente), sendo que cada registro foi então convertido e armazenado como imagem digital (escala RGB) criando-se assim uma nova base de dados equivalente, sendo que posteriormente estas imagens foram convertidas para escala de cinza, considerando que a classificação da imagem do sinal ECG não precisa ser realizada considerando cores, e visando trabalhar com apenas dois canais para diminuir a complexidade da CNN autoassociativa. A Figura 28 apresenta algumas das imagens da base de dados convertidas em escala de cinza.

Figura 28 - exemplos de imagens de sinais ECG em escala de cinza.



Fonte: Autoral.


Em seguida, foi realizada a leitura das imagens em matrizes, sendo necessário definir quais dimensões de altura e largura seriam ideais para as imagens. Os dados em formato 2D, originalmente gerados em tamanho 300x300, foram convertidos para o tamanho 64x64. Para esta etapa da metodologia foi utilizada a linguagem de programação Python com as seguintes bibliotecas:

- Matplotlib: biblioteca usada para converter dados de série temporal para imagem;
- Numpy: biblioteca usada para o ajuste dos dados para o formato necessário;

3.2.3 Etapa de definição e treinamento das redes CAEs

Para cada caso, interpaciente e intrapaciente, três redes CAEs foram definidas e treinadas com a finalidade de reconstruir sinais ECG (complexo QRS). A rede CAE 1 foi definida e treinada somente com imagens da base de treino pertencentes a classe normal, a rede CAE 2 foi definida e treinada com imagens pertencentes à classe Supraventricular e por fim, a rede CAE 3 foi definida e treinada com imagens da classe Ventricular. Todas as CAEs foram implementadas utilizando a mesma estrutura, sendo composta por um *encoder* composto por três camadas de convolução e três de *pooling*, ocorrendo uma intercalação entre elas, e um *decoder* composto por três camadas de convolução e três de *upsampling*, conforme figura 29.

Figura 29 - Arquitetura das CAEs propostas.



Fonte: Autoral.

Os sinais de entrada/saída das CAEs durante a fase de treino foram imagens com dimensões 64x64. A implementação e o treinamento das redes foram realizados por meio da linguagem de programação Python (Python, 2012), por meio do módulo Keras (Keras, 2022), que permite operar com imagens através da função Conv2d.

A primeira janela de convolução trabalha com tamanho 16, enquanto a segunda e terceira janela operam com tamanho 8. Ambas aplicam *padding* do tipo *same* e a configuração se repete para a função *decoder* de uma rede CAE.

As camadas de *Maxpooling* e *Upsampling*, presentes respectivamente nas funções *encoder* e *decoder*, fazem uso de suas versões para o tratamento de dados em formato de imagem, MaxPooling2D e Upsampling2D, onde o primeiro tem o *pool size* de tamanho 2, e que divide pela metade os dados de entrada para a camada de *pooling*, onde eles serão processados. O *Upsampling2D* também utiliza a mesma configuração de *pool size* e esta função realiza a reconstrução do sinal original fornecido na entrada da rede, com o auxílio das camadas de convolução. A tabela 8 resume os parâmetros e arquitetura das CAEs.

Tabela 8 - Parâmetros e Arquitetura das CAEs.

Camada	Tipo	Tamanho do Kernel	Kernel	Tamanho da entrada
Layer 1	Conv2D	3 x 3	16	64 x 64 x 1
Layer 2	Pooling	2 x 2		62 x 62 x 16
Layer 3	Conv2D	3 x 3	8	32 x 32 x 16
Layer 4	Pooling	2 x 2		30 x 30 x 16
Layer 5	Conv2D	3 x 3	8	15 x 15 x 16
Layer 6	Pooling	2 x 2		30 x 30 x 16
Layer 7	Conv2D	3 x 3	8	15 x 15 x 16
Layer 8	Upsampling 2D	2 x 2		30 x 30 x 16
Layer 9	Conv2D	3 x 3	8	32 x 32 x 16
Layer 10	Upsampling 2D	2 x 2		62 x 62 x 16
Layer 11	Conv2D	3 x 3	16	64 x 64 x 1
Layer 12	Upsampling 2D	2 x 2		64 x 64 x 1

Fonte: Autoral.

Devido ao nível de complexidade de operação nas camadas de codificação e decodificação e a grande quantidade de amostras fornecidas como dados para entrada das redes, elas foram treinadas por meio de uma GPU GTX 1660 com suporte à tecnologia CUDA (Cuda, 2014), onde vale ressaltar que o módulo Keras possui como *backend* outro módulo Tensorflow (TENSORFLOW, 2022), que possibilita esta etapa.

3.2.4 Etapa de teste das estruturas competitivas e cálculo de todas as métricas para avaliação de desempenho e análise de resultados

Após a finalização da fase de treinamento das CAEs para cada caso, interpaciente e intrapaciente, as mesmas foram organizadas na estrutura paralela competitiva apresentada na figura 19. Desta forma, a estrutura atuou como um sistema de classificação de arritmias, sendo que quando um sinal ECG (imagem complexo QRS) foi apresentado para a estrutura, as três redes CAEs tentaram reconstruir simultaneamente a imagem nas suas saídas, sendo que uma delas apresenta um menor erro/maior similaridade entre as imagens de entrada/saída. A CAE que apresentou o menor erro foi considerada a CAE vencedora e a imagem de entrada classificada de acordo com a classe representativa da CAE vencedora.

Para análise de desempenho das duas estruturas competitivas (interpaciente e intrapaciente) foram calculadas as métricas sensibilidade, precisão, acurácia e F1-Score considerando a base de teste, conforme exposto nas Tabelas 11 e 14 da seção de Resultados.

4 RESULTADOS

4.1 Introdução

No capítulo anterior foi apresentada a metodologia adotada para a implementação das estruturas competitivas autoassociativas proposta para classificação de arritmias. Nesta seção, serão mostrados e discutidos os resultados obtidos para os sistemas propostos.

Após diversos testes, foram coletadas as métricas necessárias para análise de desempenho dos sistemas propostos considerando paradigma interpaciente e intrapaciente. As estruturas competitivas autoassociativas também tiveram seu desempenho comparado com diversos outros trabalhos apresentados na literatura.

4.2 Resultados para paradigma intrapaciente

Nesta seção serão apresentados os resultados obtidos após a implementação da estrutura competitiva autoassociativa utilizando o paradigma intrapaciente.

4.2.1 Treinamento das redes CAEs

Todas as 3 CAEs foram treinadas com diferentes números de épocas, utilizando o otimizador Adam (ADAM, 2022). Para análise de desempenho de cada CAE foi utilizada a função do erro médio quadrático.

A tabela 9 apresenta o número de registros da base de treino e teste utilizada para o desenvolvimento de cada CAE.

Tabela 9 - Número de registros da base de treino e teste para cada CAE.

Classes	Número de amostras (base de treino)	Número de amostras (base de teste)
CAE1 (Classe N)	72471	18118
CAE2 (Classe S)	2223	556
CAE3 (Classe V)	5788	1448

Fonte: Autoral.

A tabela 10 apresenta os resultados obtidos para rede CAE1, CAE2 e CAE 3 para dados de treino e teste, sendo que cada CAE foi treinada para reproduzir o sinal apresentado em sua entrada, sendo que a CAE 1 foi treinada com imagens da classe Normal, a CAE 2 com imagens da classe Supraventricular e a CAE 3 com imagens da classe Ventricular.

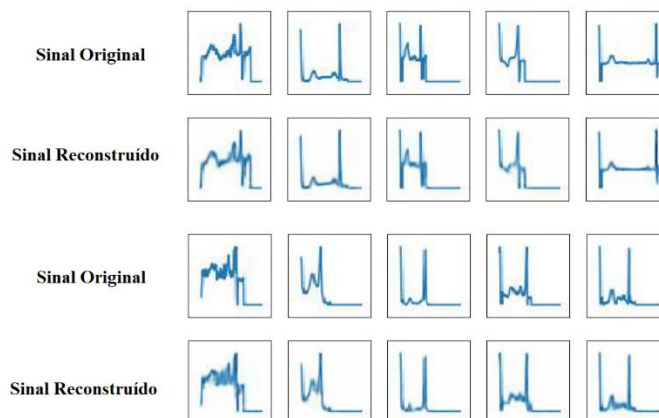
Tabela 10 - Resultados obtidos para cada rede CAE.

Rede	Épocas	Erro médio Quadrático (base de treino)	Erro médio Quadrático (base de teste)
CAE 1 (Classe N)	300	$1,22 \times 10^{-4}$	$1,55 \times 10^{-4}$
CAE 2 (Classe S)	4000	$2,57 \times 10^{-4}$	$1,91 \times 10^{-4}$
CAE 3 (Classe V)	450	$2,04 \times 10^{-4}$	$1,92 \times 10^{-4}$

Fonte: Autoral.

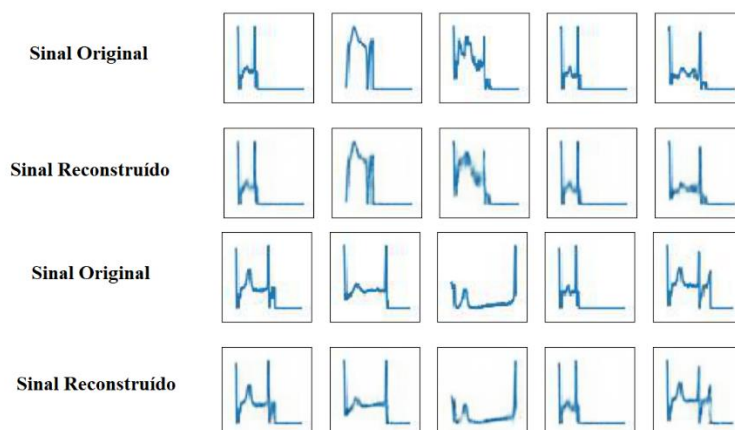
As figuras 30, 31 e 32 apresentam alguns exemplos de sinais reconstruídos pelas CAEs para casos de batimentos Normais, Supraventriculares e Ventriculares.

Figura 30 - Sinais originais e reconstruídos pela CAE 1 (batimento Normal).



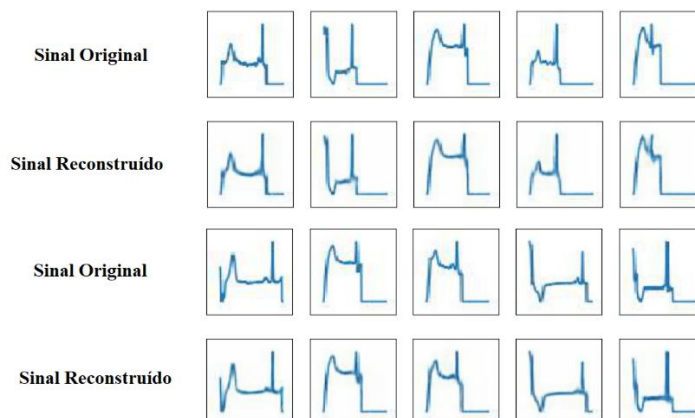
Fonte: Autoral.

Figura 31 - Sinais originais e reconstruídos pela CAE 2 (batimento Supraventricular).



Fonte: Autoral.

Figura 32 - Sinais originais e reconstruídos pela CAE 3 (batimento Ventricular).



Fonte: Autoral.

4.2.2 Estrutura Competitiva Autoassociativa

Após o treinamento das redes CAEs, a estrutura competitiva apresentada na Figura 14 foi organizada para teste do sistema de classificação de arritmias, sendo que foram apresentadas para a estrutura todas as imagens contidas na base de teste. Para analisar o desempenho do sistema classificador foram utilizadas as métricas sugeridas pela AAMI, sendo elas acurácia, sensibilidade e precisão, que foram obtidas para as classes N, S e V. A Tabela 11 apresenta as métricas obtidas após a implementação da estrutura competitiva classificadora.

Tabela 11 - Valores das métricas obtidas considerando base de teste.

	N (%)	S (%)	V (%)	Média (%)
Sensibilidade	99,86	84,89	98,61	94,45
Precisão	99,63	92,18	98,55	96,78
F1-Score	99,74	88,38	98,57	95,56
Acurácia				99,36

Fonte: Autoral.

A Figura 33 apresenta a matriz de confusão obtida para base de teste.

Figura 33 - Matriz de confusão gerada para o banco de testes.

N	18094	24	0
S	63	472	21
V	4	16	1428
	N	S	V

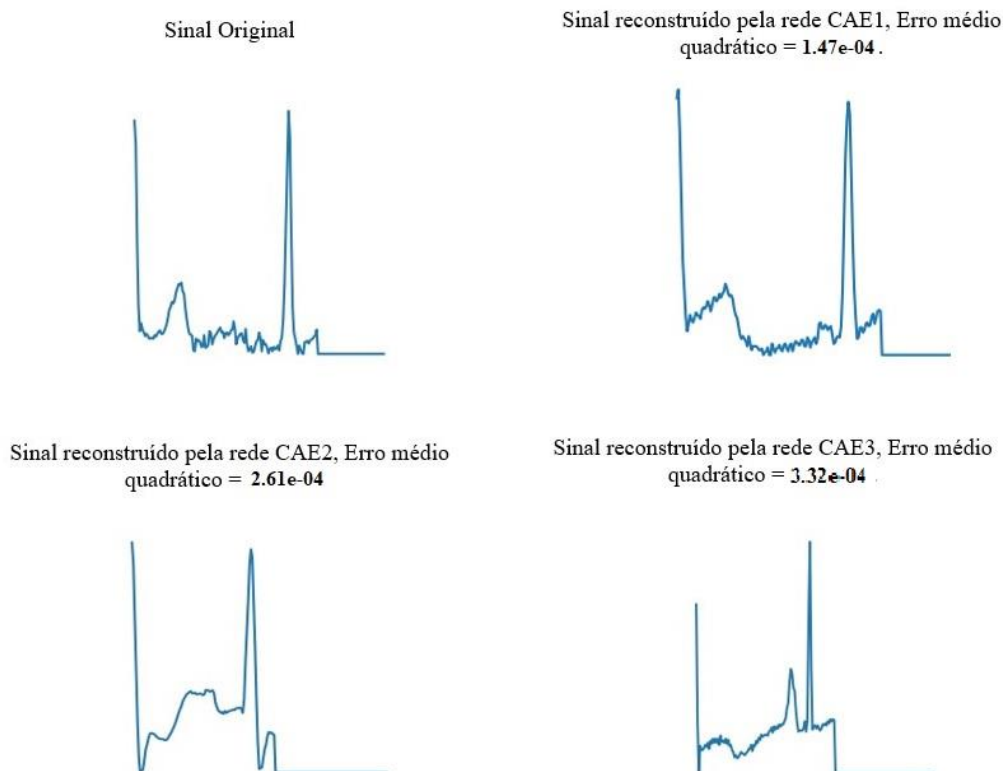
Fonte: Autoral.

Analisando a matriz de confusão pode ser observado que em relação à classe normal foram realizadas 18094 classificações corretas, enquanto 24 amostras foram incorretamente classificadas. Para a classe Supraventricular, a estrutura competitiva foi capaz de classificar 472 amostras corretamente e por fim, a classe Ventricular realizou 1428 acertos. Vale ressaltar que a estrutura realizou 24 classificações da classe Normal como supraventricular e da classe supraventricular classificou 63 casos como normal, pois para estes casos, os sinais ECG das duas classes possuem algumas similaridades em seus complexos QRS, assim ocasionando em erros de classificação.

Pode ser observado que a classe N, que possui o maior número de dados na base de teste, foi a que obteve a maior quantidade de acertos. A classe S obteve um bom resultado no que diz respeito à sensibilidade e precisão, porém foi a classe que obteve os menores resultados. A classe V também obteve valores satisfatórios em relação à sensibilidade e precisão, devido aos padrões dos complexos QRS serem bastante diferenciados em relação às outras classes.

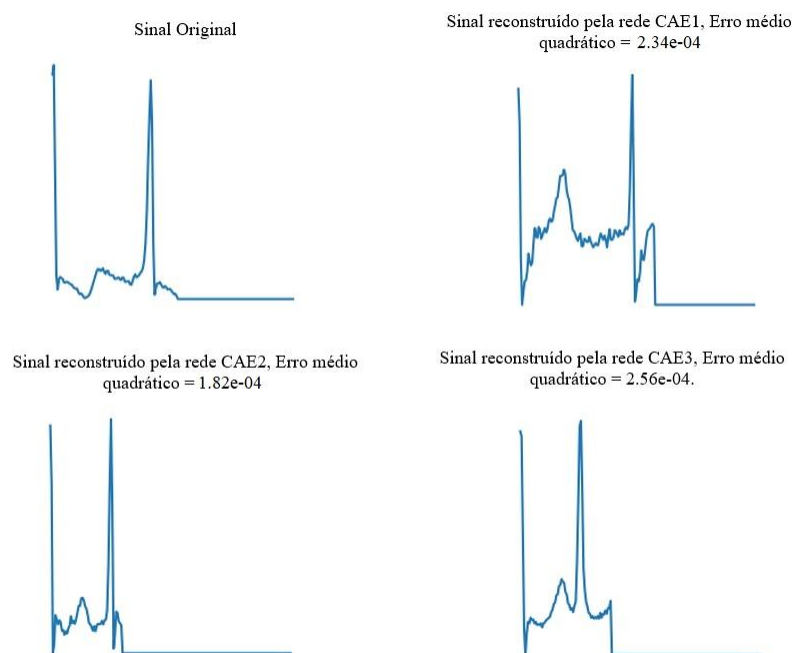
As figuras 34, 35 e 36 apresentam alguns exemplos de sinais classificados corretamente para as Classe N, S e V, respectivamente.

Figura 34 - Exemplo de sinal Normal classificado corretamente, com menor erro para CAE 1 (Normal).



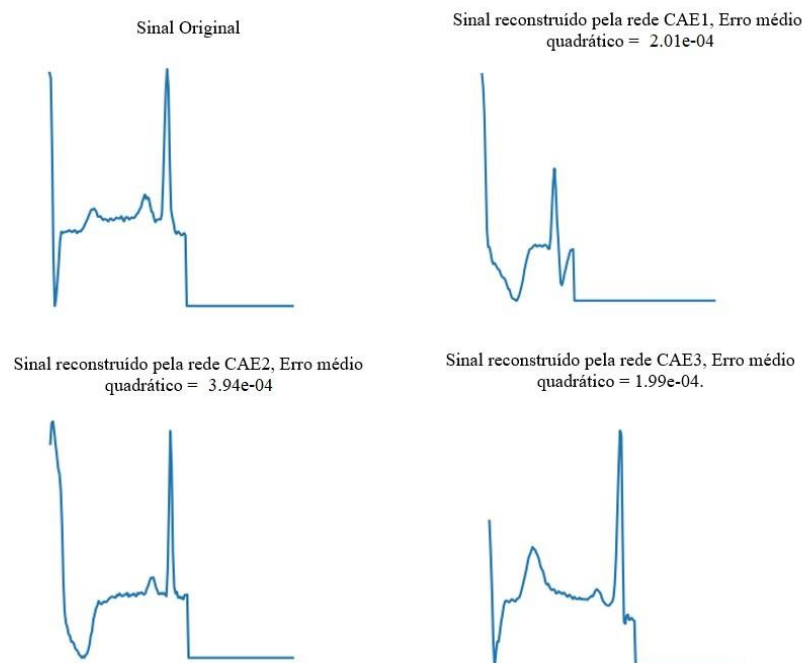
Fonte: Autoral.

Figura 35 - Exemplo de sinal Supraventricular classificado corretamente, com menor erro para CAE 2 (Supraventricular).



Fonte: Autoral.

Figura 36 - Exemplo de sinal Ventricular classificado corretamente, com menor erro para CAE 3 (Ventricular).



Fonte: Autoral.

Para o caso da Figura 34, o sinal na entrada na estrutura competitiva pertencia a classe Normal, sendo que após passar o sinal por cada CAE, a que obteve menor erro quadrático médio foi a CAE1, sendo então o sinal classificado pela estrutura como Normal.

Para o caso da Figura 35, o sinal na entrada na estrutura competitiva pertencia a classe Supraventricular, sendo que após passar o sinal por cada CAE, a que obteve menor erro quadrático médio foi a CAE2, sendo então o sinal classificado pela estrutura como supraventricular.

Para o caso da Figura 36, o sinal na entrada na estrutura competitiva pertencia a classe Ventricular, sendo que após passar o sinal por cada CAE, a que obteve menor erro quadrático médio foi a CAE3, sendo então o sinal classificado pela estrutura como ventricular.

4.3 Resultados para Paradigma Interpaciente

Nesta seção serão apresentados os resultados obtidos após a implementação da estrutura competitiva autoassociativa, utilizando o paradigma interpaciente.

4.3.1 Treinamento das Redes Autoassociativas

Seguindo a mesma metodologia utilizada para o paradigma intrapaciente, as CAEs foram treinadas utilizando números específicos de épocas para cada classe utilizando o otimizador Adam (ADAM, 2022). O erro médio quadrático também foi usado para análise de desempenho de cada CAE.

A divisão da base de dados segue os conjuntos DS1 e DS2 propostos em (DE CHAZAL et al. 2004), totalizando 50588 amostras para DS1 e 49303 amostras para DS2. A Tabela 12 apresenta o número de registros da base de treino e teste utilizada para o desenvolvimento de cada CAE para o paradigma interpaciente.

Tabela 12 - Número de registros da base de treino e teste para cada CAE.

Classes	Número de amostras (base de treino)	Número de amostras (base de teste)
CAE1 (Classe N)	45824	44032
CAE2 (Classe S)	976	2050
CAE3 (Classe V)	3788	3220

Fonte: Autoral.

A tabela 13 apresenta os resultados obtidos para rede CAE1, CAE2 e CAE 3 para dados de treino e teste, sendo que como foi explicado anteriormente, cada CAE foi treinada para reproduzir o sinal apresentado em sua entrada, onde a CAE 1 foi treinada com imagens da classe Normal, a CAE 2 com imagens da classe Supraventricular e a CAE 3 com imagens da classe Ventricular, seguindo o paradigma interpaciente.

Tabela 13 - Resultados obtidos para cada rede CAE.

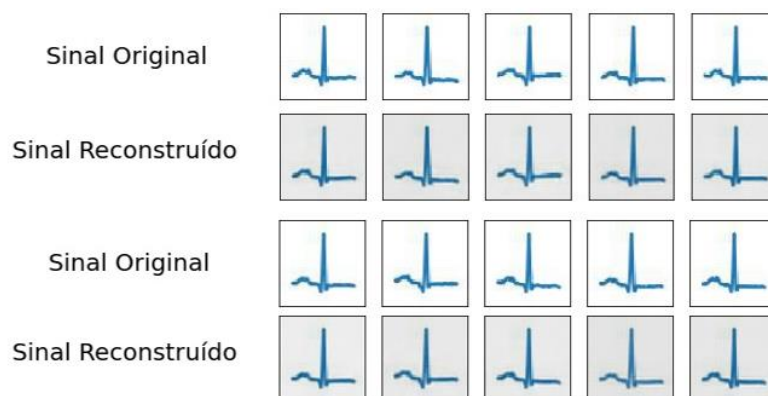
Rede	Épocas	Erro médio Quadrático (base de treino)	Erro médio Quadrático (base de teste)
CAE 1 (Classe N)	85	$1,25 \times 10^{-4}$	$1,56 \times 10^{-4}$
CAE 2 (Classe S)	750	$2,87 \times 10^{-4}$	$1,94 \times 10^{-4}$
CAE 3 (Classe V)	1000	$2,07 \times 10^{-4}$	$1,99 \times 10^{-4}$

Fonte: Autoral.

Após diversos testes realizados após o treinamento das CAEs, o número de épocas que melhor se adequou para fornecer o melhor resultado de erro médio quadrático está descrito na tabela 8. Os resultados de erro médio quadrático obtidos foram os mais adequados considerando os resultados de classificação quando as redes CAEs foram inseridas na estrutura competitiva.

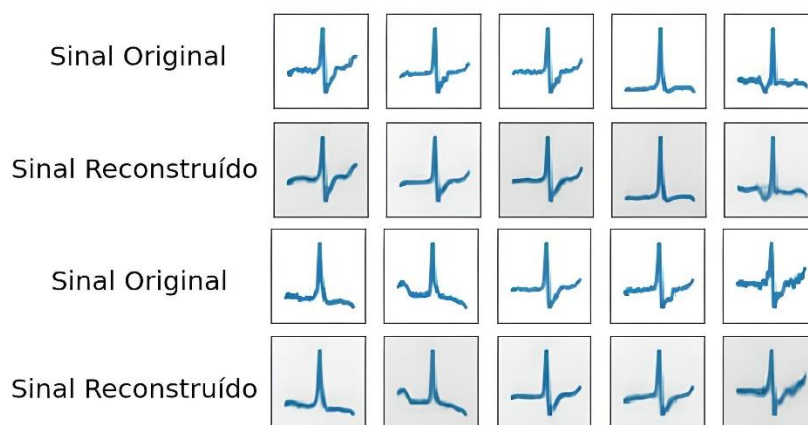
As figuras 37, 38 e 39 apresentam alguns exemplos de sinais reconstruídos pelas CAEs para casos de batimentos Normais, Supraventriculares e Ventriculares.

Figura 37 - Sinais originais e reconstruídos pela CAE 1 (Batimento normal).



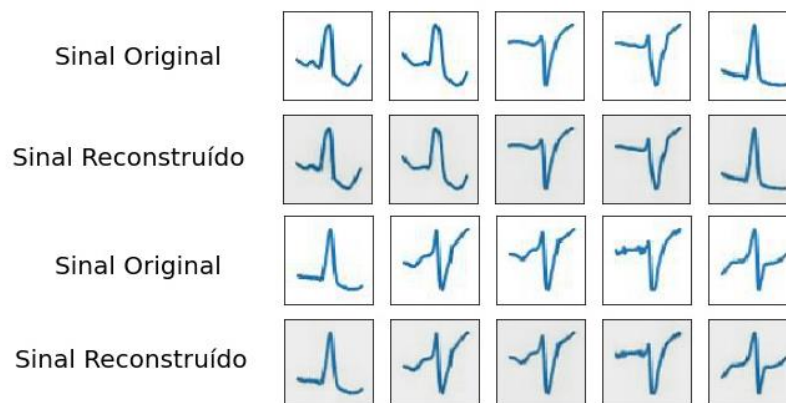
Fonte: Autoral.

Figura 38 - Sinais originais e reconstruídos pela CAE 2 (batimento Supraventricular).



Fonte: Autoral.

Figura 39 – Sinais originais e reconstruídos pela CAE 3 (batimento Ventricular).



Fonte: Autoral.

4.3.2 Estrutura Competitiva Autoassociativa

Após treinamento das redes CAEs utilizando o paradigma interpaciente, a estrutura competitiva foi organizada para teste do sistema de classificação de arritmias, sendo apresentadas todas as imagens contidas na base de teste para a estrutura. Para analisar o desempenho do sistema classificador foram também utilizadas as mesmas métricas sugeridas pela AAMI, sendo elas acurácia, sensibilidade e precisão que foram obtidas para as classes N, S e V. A Tabela 14 apresenta as métricas obtidas após a implementação da estrutura competitiva classificadora.

Tabela 14 - Valores das métricas obtidas considerando base de teste.

	N (%)	S (%)	V (%)	Média (%)
Sensibilidade	94,17	28,48	88,66	70,43
Precisão	96,27	22,56	78,32	65,74
F1-Score	95,20	25,17	83,16	67,84
Acurácia				91,07

Fonte: Autoral.

A Figura 40 apresenta a matriz de confusão obtida para base de teste.

Figura 40 - Matriz de confusão gerada para o banco de testes.

N	41465	1874	693
S	1369	584	97
V	235	130	2855
	N	S	V

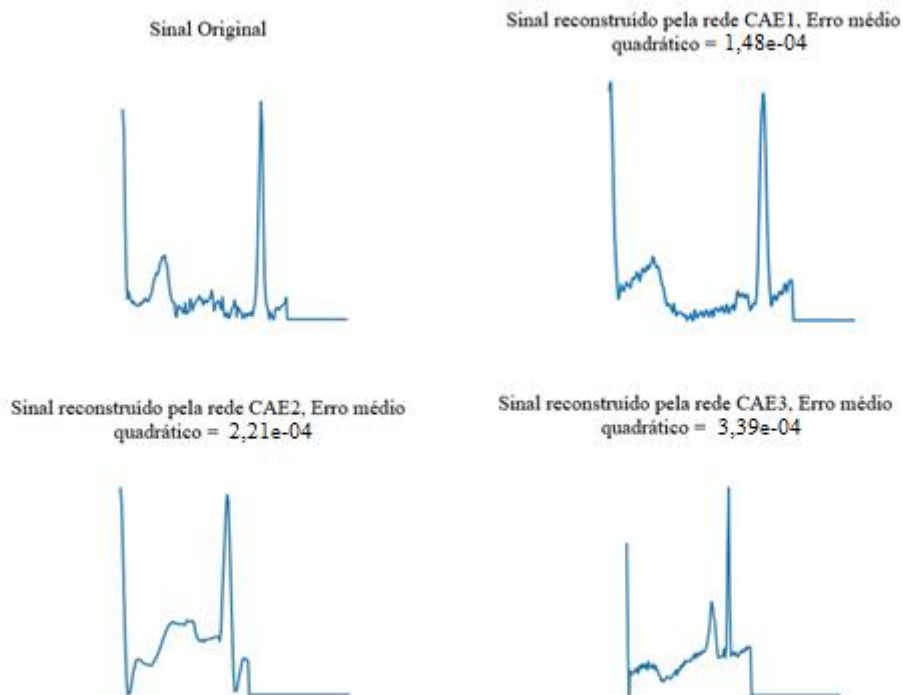
Fonte: Autoral.

Analisando a matriz de confusão, observa-se que em relação à classe normal (N), que possui a maior quantidade de registros na base de testes DS2, foram realizadas 41465 classificações corretas, enquanto 2567 amostras foram incorretamente classificadas, sendo a classe com a maior quantidade de acertos. Para a classe Supraventricular (S), a estrutura competitiva não obteve um desempenho satisfatório, pois classificou apenas 584 amostras corretamente e por fim, a classe Ventricular que realizou 2855 classificações corretas.

Uma hipótese para um desempenho insatisfatório ter ocorrido na classe S seria o fato de que existe uma semelhança entre os padrões dos complexos QRS das classes de batimento normal e supraventricular, assim como uma quantidade menor de registros da classe S no banco de dados seguindo o paradigma interpaciente. Também deve ser considerado que agora temos pacientes diferentes na base de teste dos que os usados na base de treino, trazendo então uma maior dificuldade para o aprendizado da rede, que passa a ter menos informações de características específicas por paciente, como no caso do treinamento para paradigma intrapaciente. Alguns autores relatam também em seus trabalhos esta dificuldade, principalmente por que para o caso Supraventricular, até mesmo para um mesmo paciente, os padrões do complexo QRS, variam muito. Já em relação à classe de batimento ventricular, o desempenho satisfatório pode ser justificado pelos padrões do complexo QRS serem mais marcantes e diferentes das demais classes.

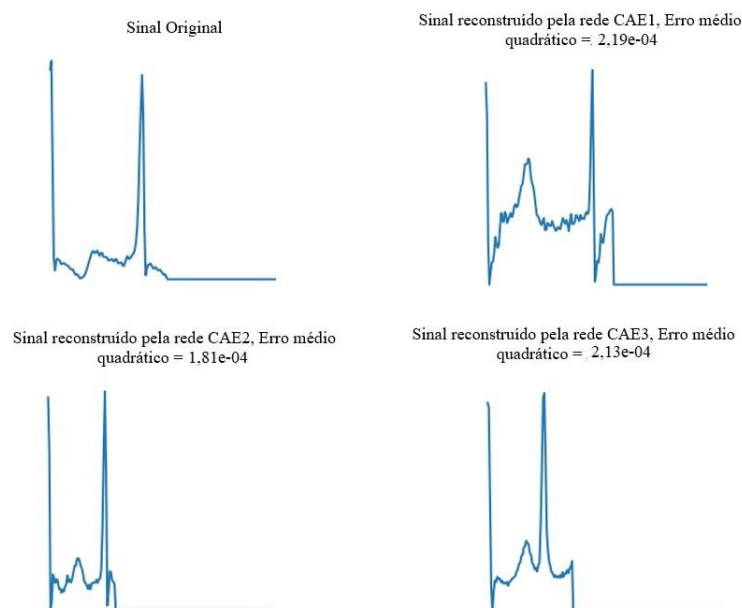
As figuras 41, 42 e 43 apresentam alguns exemplos de sinais classificados corretamente para as Classe N, S e V, respectivamente.

Figura 41 - Exemplo de sinal Normal classificado corretamente, com menor erro para CAE1 (Normal).



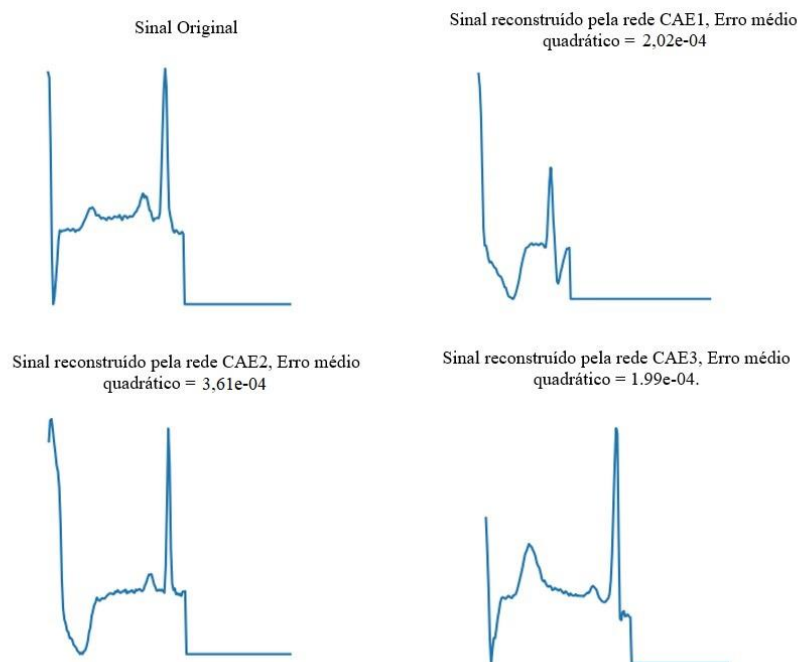
Fonte: Autoral.

Figura 42 - Exemplo de sinal Supraventricular classificado corretamente, com menor erro para CAE2 (supraventricular).



Fonte: Autoral.

Figura 43 - Exemplo de sinal Ventricular classificado corretamente, com menor erro para CAE 3(Ventricular).



Fonte: Autoral.

4.4 Comparação com Resultados de Sistemas Apresentados Na Literatura

Nesta seção serão apresentados os resultados de sistemas desenvolvidos para classificação de arritmia já apresentados na literatura, com o objetivo de comparar o desempenho dos sistemas propostos neste trabalho com os demais.

4.4.1 Paradigma Intrapaciente

A Tabela 15 reúne alguns resultados de trabalhos já apresentados na literatura que tinham por objetivo a classificação de arritmias cardíacas. Todos os trabalhos utilizaram a mesma base de dados utilizada neste trabalho (MIT-BIH) e com divisão da base de dados Intrapaciente. Considerando que a base de dados de treino, validação e teste para treino dos sistemas podem ser diferentes em alguns dos trabalhos, a análise comparativa deve ser feita com cuidado.

Tabela 15 - Resultados de sistemas classificadores de arritmia – Intrapaciente.

Trabalho	Classificador	Métricas						
		Acc(%)	Sen(%)			+p(%)		
			N	S	V	N	S	V
Sistema Proposto	Estrutura Competitiva CAEs	99,36	99,8	84,8	98,6	99,6	92,1	98,6
			Média: 94,45			Média: 96,7		
(ZHANG et al., 2012)	CNN – 2D	99,8	99,84	92,08	98,44	99,57	96,82	98,48
			Média: 96,78			Média: 98,29		
(RAWI; ELBASHIR; AHMED, 2022)	CNN – 2D XGBoost	97,91 95,66	-	-	-	-	-	98,09 95,64
(SANNINO; DE PIETRO, 2018)	DNN	94	-	-	-	-	-	-
(LI et al., 2019)	Bi-LSTM	100	-	-	-	-	-	-
(KACHUEE, M.; FAZELI; SARRAFZADEH, 2018)	CNN	95,9	-	-	-	-	-	95,2
(MOUSAVI; AFGHAH, 2019)	CNN	99,92	-	-	-	-	-	-
(REXY, VELMANI e RAJAKUMAR, 2021)	Bi-LSTM 2D	93,9	90,16			96,16		
(SEITANIDIS, GIALELIS E PAPAConstantinou, 2022)	CNN – 2D	-	92,94	96,94	95,75	86,53	98,70	97,46
			Média: 95,21			Média: 94,23		
(NATAGA; CANDIDO E SILVA, 2021)	MLP - LDA	84,2	90,4	56,8	89,3	91,1	68,0	84,1
			Média: 78,83			Média: 81,06		

Fonte: Autoral.

Dos resultados mostrados na Tabela 15, pode ser observado que o sistema desenvolvido para o paradigma intrapaciente obteve um desempenho satisfatório, pois apresentou métricas de acurácia superior aos classificadores analisados, exceto em alguns trabalhos, como em (LI et al, 2019), (MOUSAVI et al., 2019) e (ZHANG et al., 2012), onde o sistema desenvolvido apresenta valor um pouco abaixo de acurácia. No trabalho de (LI et al, 2019), foi adotada a divisão da base do MIT-BIH em 90% para treinamento e 10% para teste e fazendo uso dos dados desbalanceados. No sistema proposto por (MOUSAVI et al., 2019), utilizou-se a divisão de 80% dos dados para o treinamento e 20% para testes, também fazendo uso dos dados desbalanceados.

Em relação ao trabalho de (SEITANIDIS, GIALELIS E PAPAConstantinou, 2022), o sistema obteve valores da média de sensibilidade inferiores, porém em relação à média de precisão, o sistema proposto obteve valores superiores.

Em (NATAGA; CANDIDO E SILVA, 2021), pode ser observado que o sistema desenvolvido obteve valores superiores em todas as métricas. Por fim, comparado com o trabalho de (REXY, VELMANI e RAJAKUMAR, 2021), as médias de acurácia, sensibilidade e precisão obtidas pelo sistema proposto também foram superiores.

Vale ressaltar que nos trabalhos de (ZHANG et al., 2012) e (RAWI; ELBASHIR; AHMED, 2022), foram utilizadas a mesma base de dados deste trabalho (divisão de treino e teste), então uma comparação mais direta com estes pode ser realizada. Em comparação dos resultados obtidos, é possível notar que a estrutura competitiva obteve valor de acurácia superior em relação a maior parte dos trabalhos analisados, enquanto que a sensibilidade obtida estava na mesma faixa de valores dos outros sistemas, porém a precisão das CAEs foi maior que as demais, exceto em (ZHANG et al., 2012) e pela CNN-2D desenvolvida por (RAWI; ELBASHIR; AHMED, 2022).

4.4.2 Paradigma Interpaciente

A Tabela 16 apresenta resultados de algumas propostas de sistemas para diagnóstico de arritmia já apresentados na literatura. Todos os trabalhos utilizaram a base de dados do MIT-BIH e com divisão da base de dados Interpaciente, com a base dividida em DS1 para treino e DS2 para testes como proposto por (DE CHAZAL et al. 2004).

Tabela 16 - Resultados de sistemas classificadores de arritmia – Interpaciente.

Trabalho	Classificador	Métricas						
		Acc(%)	Sen(%)			+p(%)		
			N	S	V	N	S	V
(YE; COIMBRA; KUMAR, 2010)	SVM	86	88.0	60.0	81.0	97.0	53.0	63.0
(LIN e YANG, 2014)	Weighted LD	93	91.0	81.0	86.0	99.0	31.0	73.0
(LLAMEDO; MARTÍNEZ, 2011)	Weighted LD	93	95.0	77.0	81.0	98.0	39.0	87.0
(ZHANG et.al, 2014)	Combined SVM	87	88.0	74.0	88.0	98.0	59.0	82.0
(DE CHAZAL et. al, 2004) ok	Weighted LD	83	87.0	76.0	77.0	99.0	38.0	82.0
(ZHAI; TIN, 2018)	CNN	-	-	76.8	93.8	-	74.0	92.4
(SORIA e MARTINEZ, 2009)	Weighted LD	90	92.0	88.0	90.0	85.0	93.0	92.0
(GARCIA et. al, 2017)	SVM	92,04	94.0	62.0	87.3	98.0	53.0	59.4
Sistema proposto	Estrutura competitiva CAEs	91,07	94.1	28.4	88.6	96.2	22.5	78.3

Fonte: Autoral.

Analisando os resultados demonstrados na tabela 16, é possível ser observado que a acurácia do sistema desenvolvido neste trabalho foi superior aos trabalhos relacionados, exceto em (GARCIA et. al, 2017), (LLAMEDO; MARTÍNEZ, 2011) e (LIN e YANG, 2014). Em relação a sensibilidade da classe N, o sistema proposto também apresenta valores satisfatórios. A sensibilidade da classe V do sistema obteve valores na mesma faixa dos trabalhos relacionados, exceto em (ZHAI e TIN, 2018) e (SORIA e MARTINEZ, 2009). A precisão da

classe N do sistema proposto também obteve valores satisfatórios, se encontrando um pouco abaixo dos sistemas relacionados, exceto em (SORIA e MARTINEZ, 2009), onde foi maior. A estrutura competitiva apresentou um pior desempenho na sensibilidade e precisão da classe S, onde obteve resultados abaixo dos trabalhos relacionados. Por fim, a precisão da classe V obteve um bom desempenho, possuindo valores superiores em alguns trabalhos, tais como (GARCIA et. al, 2017), (LIN e YANG, 2014) e (YE; COIMBRA; KUMAR, 2010).

De um modo geral, os resultados alcançados pela classe S não foram satisfatórios e a estrutura competitiva classificou a maior parte das amostras dessa classe como pertencentes à classe N, o que é causado pela equivalência entre os padrões dos complexos QRS dessas duas classes e a baixa quantidade de registros da classe S no banco de dados.

Vale ressaltar a metodologia aplicada neste sistema desenvolvido segue a mesma abordagem que em (LIN e YANG, 2014), onde são utilizadas as classes N, S e V, devido ao desbalanceamento entre o número de registro de cada classe do MIT-BIH, enquanto que no trabalho proposto por (ZHAI e TIN, 2018), o sistema é otimizado para duas classes. As classes excluídas (F e Q), por possuírem um número muito pequeno de registros, pouco iriam contribuir para uma melhoria do desempenho.

5 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou os resultados obtidos da proposta de uma estrutura competitiva de Redes Neurais Convolucionais Autoassociativas para classificação de arritmias por meio de sinais ECG. Para a implementação do sistema foi utilizado o banco de dados MIT-BIH *Arrhythmia Database*, que é altamente recomendado pela AAMI para o desenvolvimento de sistemas automáticos e foi adotado a abordagem interpaciente proposta por (DE CHAZAL; O'DWYER; REILLY, 2004) e intrapaciente, com o objetivo de padronizar os métodos e comparação de resultados com os demais trabalhos.

Foi adotada a metodologia para conversão dos dados de entrada no formato de série temporal (1D) para imagens digitais, onde a dimensão utilizada foi a 64x64 para a estrutura competitiva.

A estrutura competitiva autoassociativa apresentou métricas que podem ser consideradas satisfatória seguindo as abordagens intrapaciente e interpaciente. O sistema obteve acurácia de 99,36%, sensibilidade de 94,45% e precisão de 96,78%, para a abordagem intrapaciente e acurácia de 91,07%, sensibilidade de 70,43% e precisão de 65,74%.

Considerando os resultados finais obtidos para o sistema desenvolvido, pode ser observado que o mesmo se mostrou adequada e com bons resultados para realizar a classificação de arritmias por meio de sinais ECG.

Este trabalho também conseguiu fazer uso das abordagens intrapaciente e interpaciente. Acredita-se que o sistema desenvolvido conseguiu expor com sucesso que com a utilização da abordagem intrapaciente, é possível obter melhores resultados de classificação, mas esta metodologia não representa métricas clinicamente úteis, pois não representa a situação real em clínicas hospitalares. Para diversos autores, que assim como este trabalho, utilizaram a abordagem interpaciente, apenas classificadores que demonstrem boa capacidade de generalização do modelo em dados de pacientes não utilizados na fase de treinamento podem ser considerados clinicamente úteis.

Para trabalhos futuros seria importante treinar a estrutura competitiva com um número maior de padrões para diferentes tipos de arritmias, com o intuito de aprimorar o desempenho da rede considerando as métricas de avaliação recomendadas pela AAMI, sendo que uma solução seria o uso de técnicas para criação de dados virtuais para criação de um banco de dados balanceado para melhoria da capacidade de generalização das redes neurais artificiais.

Como trabalho futuro também pode ser almejada a melhoria dos resultados para abordagem interpaciente, visto que esta reflete a situação real para diagnóstico clínico.

REFERÊNCIAS BIBLIOGRÁFICAS

4 dicas para posicionar eletrodos ecg. Magazine Médica, 2022. Disponível em: <https://blog.magazinemedica.com.br/4-dicas-para-posicionar-eletrodos-ecg/>. Acesso em: 16 de março de 2023.

AAMI EC57. Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms. 2012. Disponível em: <https://standards.globalspec.com/std/1589846/aami-ec57>. Acesso em: 07 de jul. 2022.

ABAWAJY, J.; KELAREV, A.; CHOWDHURY, M. Multistage approach for clustering and classification of ECG data. *Computer Methods and Programs in Biomedicine*, v. 112, p. 720–730, 2013.

ABOUT Arrhythmia. American Heart Association, 2016. Disponível em: <https://www.heart.org/en/health-topics/arrhythmia/about-arrhythmia>. Acesso em: 07 de jul. 2022.

ACLS Medical Training. Sinus Tachycardia. 2022. Disponível em: <https://www.aclsmedicaltraining.com/rhythm-recognition/>. Acesso em: 07 de jul. de 2022.

ADAM. (2022). Keras API reference. Disponível em: <https://keras.io/api/optimizers/adam/>. Acesso em: 10 de jul. de 2022.

AHMAD, Z. et al. ECG Heartbeat Classification Using Multimodal Fusion. *Institute of Electrical and Electronics Engineers*, vol. 9, 100615–100626. <https://doi.org/10.1109/access.2021.3097614>.

AJIT, A.; ACHARYA, K.; SAMANTA, A. A Review of Convolutional Neural Networks. *International Conference on Emerging Trends in Information Technology and Engineering*, 2020. Disponível em: doi:10.1109/ic-etite47903.2020.049.

AMARAL, Yuri Castro do. **Diagnóstico semiautomático de arritmias cardíacas utilizando técnicas de aprendizado de máquina e transformadas Wavelet**. 2019. 68 f., il. Trabalho de Conclusão de Curso (Bacharelado em Engenharia da Computação) —Universidade de Brasília, Brasília, 2019.

ARAÚJO, F. H, et al. Redes neurais convolucionais com tensorflow: Teoria e prática, Sociedade Brasileira de Computação. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos 1: 382–406.

ARRITMIAS resumo completo!, SANARMED, 2019. Disponível em: <https://www.sanarmed.com/arritmias>. Acesso em: 07 de jul. de 2022.

BAIA, Alexandre Farias. **Estrutura competitiva de redes neurais convolucionais auto-associativas para classificação de arritmias**. Orientadora: Adriana Rosa Garcez Castro. 2019. 71 f. Dissertação (Mestrado em Engenharia Elétrica) - Instituto de Tecnologia, Universidade Federal do Pará, Belém, 2019.

BALTAZAR, R. F. Basic and Bedside Electrocardiography. [S.l.] LWW, 2009.

BAYDOUN, M. et al. High Precision Digitization of Paper-Based ECG Records: A Step Toward Machine Learning. *IEEE Journal of Translational Engineering in Health and Medicine*Institute of Electrical and Electronics Engineers (IEEE), 2019. Disponível em: <http://dx.doi.org/10.1109/JTEHM.2019.2949784>.

BRAGA, A.P. et al. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC, 2000. 250 p.

BRAUNWALD, E. *Tratado de medicina cardiovascular*. ed. 6, v.1 e v.2, editora Roca, São Paulo. 2006.

CARDIOVASCULAR diseases (CVDs). World Health Organization, 2021. Disponível em: https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1. Acesso em: 09 de jul. de 2022.

CARDOSO, A. S. **Instrumentação e Metodologias de Medição de Biopotenciais**. Tese (Doutorado em Engenharia Elétrica) Universidade Federal de Minas Gerais, Minas Gerais. 2010.

CARR, J. J BROWN, J. M. **Introduction to Biomedical Equipment Technology**. Springdale: Prentice Hall, 2001.

CENTER MEDICAL. Eletrocardiógrafo. 2018. Disponível: <https://www.centermedical.com.br/eletrocardiografo-03-canais-12-derivacoes-ecafix-ecg12s/p>. Acesso em 14 jan 2023.

CHAVES, Gabriel Moreira; ANDRADE, Ian Bittencourt. **Identificação da estrutura de GitHub Wikis a partir de aprendizado de máquina**. 2022. Trabalho de Conclusão de Curso (TCC) (Bacharelado em Engenharia de Software) - Pontifícia Universidade Católica de Minas Gerais, [S. l.], 2022. Disponível em: <http://bib.pucminas.br:8080/pergamumweb/vinculos/000012/00001211.pdf>. Acesso em: 17 maio 2023.

CHAZAL, P.; O'DWYER, M.; REILLY, R. B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, v. 51, n. 7, p. 1196–1206, 2004.

CHENG, J.-Z. et al. Computer-Aided Diagnosis with Deep Learning Architecture: Applications to Breast Lesions in US Images and Pulmonary Nodules in CT Scans. *Scientific Reports*Springer Science and Business Media LLC, 15 abr. 2016. Disponível em: <http://dx.doi.org/10.1038/srep24454>.

CHOLLET, F. **Deep Learning with Python**. [S.L.]. Manning Publications, 2021.

CLAPPIS, Alan Melo. Uma introdução as redes neurais convolucionais utilizando o Keras. [S. l.], 12 jul. 2019. Disponível em: <https://medium.com/data-hackers/uma-introdu%C3%A7%C3%A3o-as-redes-neurais-convolucionais-utilizando-o-keras-41ee8dcc033e>. Acesso em: 18 mar. 2023.

COSTA, C. M.; GOVINDA, U.; REGIS, C. Detecção dos Principais Pontos no Sinal de ECG para Identificação do IAM por meio do Processamento Digital do Eletrocardiograma. *Revista de Tecnologia da Informação e Comunicação*. 6. Disponível em: [10.12721/2237-5112/rtic.v6n1p15-20](https://doi.org/10.12721/2237-5112/rtic.v6n1p15-20).

COSTA, W.; COSTA, C.; REGIS, C. Detecção do Complexo QRS Utilizando o Algoritmo de Pan & Tompkins Modificado. *Anais de XXXIII Simpósio Brasileiro de Telecomunicações*. Em: XXXIII SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES. Sociedade Brasileira de Telecomunicações, 2015. Disponível em: <http://dx.doi.org/10.14209/sbrt.2015.155>.

CS231N. CS231n Convolutional Neural Networks for Visual Recognition. 2017. Disponível em: <http://cs231n.github.io/convolutional-networks>. Acesso em 20 jan 2019.

CUNHA, Paulo César do Nascimento. **Um modelo de eletrocardiógrafo portátil de baixo consumo**. Dissertação - (Mestrado em Modelagem Computacional de Conhecimento). Universidade Federal de Alagoas, Maceió, 2012.

CUREM. Taquicardia Supraventricular na emergência pediátrica: Diagnóstico e manejo. In: *Taquicardia Supraventricular na emergência pediátrica: Diagnóstico e manejo*. [S. l.], 8 abr. 2022. Disponível em: <https://blog.curem.com.br/topicos/pediatria/taquicardia-supraventricular-na-emergencia-pediatica-diagnostico-e-manejo/>. Acesso em: 8 nov 2022.

DATA Science Academy. *Deep Learning Book*, 2022. Disponível em: <https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>. Acesso em: 07 ju. 2022.

ELGENDI, M. TERMA Framework for Biomedical Signal Analysis: An Economic-Inspired Approach. *BiosensorsMDPI AG*, 2 Nov. 2016. Disponível em: <http://dx.doi.org/10.3390/bios6040055>.

ESCALONA-MORAN, M.; SORIANO, M.; FISCHER, I.; MIRASSO, C. Electrocardiogram classification using reservoir computing with logistic regression. *IEEE J. Biomed. Health Inform.* 19 (3), p.892–898. 2015.

FACELI, K. et al. *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. Rio de Janeiro: LTC, 2011.

FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006.

FAZELI, Shayan. ECG Heartbeat Categorization Dataset. Kaggle. 2017. Disponível em: <https://www.kaggle.com/datasets/shayanfazeli/heartbeat?resource=download>. Acesso em: 30 jun 2022.

FERRARA, E. R.; WIDRAW, B. Fetal Electrocardiogram Enhancement by Time-Sequenced Adaptive Filtering. *IEEE Transactions on Biomedical Engineering* Institute of Electrical and Electronics Engineers (IEEE), Jun. 1982. Disponível em: <http://dx.doi.org/10.1109/TBME.1982.324973>.

FIORIN, Daniel V.; MARTINS, Fernando R.; SCHUCH, Nelson J.; PEREIRA, Enio B. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. *Revista Brasileira de Ensino de Física*, FapUNIFESP (SciELO), v. 33, n. 1, p. 01–20, mar. 2011.

FONSECA, A. **Princípios de Aquisição de Sinais Bioelétrico**. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica), 2003.

FREITAS, D. et al. Reconhecimento da ceratoconjuntivite infecciosa bovina utilizando imagens termográficas e redes neurais convolucionais. *Revista Brasileira de Computação Aplicada*, v. 11, n. 3, p. 133-145, 16 out. 2019.

FRIESEN, G. M. et al. A comparison of the noise sensitivity of nine QRS detection algorithms. *IEEE Transactions on Biomedical Engineering* Institute of Electrical and Electronics Engineers (IEEE). 1990. Disponível em: <http://dx.doi.org/10.1109/10.43620>.

GARCIA, G. et al. Inter-Patient ECG Heartbeat Classification with Temporal VCG Optimized by PSO. *Scientific Reports* Springer Science and Business Media LLC, 5 set. 2017. Disponível em: <http://dx.doi.org/10.1038/s41598-017-09837-3>.

GAUTHIER, D. *Reservoir Computing: Harnessing a Universal Dynamical System*. 2018. Disponível em: <https://sinews.siam.org/Details-Page/reservoir-computing-harnessing-a-universal-dynamical-system>. Acesso em 20 jan 2019.

GELMEK HEALTHCARE. *Anatomia Coração*. 2021. Disponível em: <https://www.gelmekhealth.com/index.phpwxgjlackwittedlytdmeccil214971>. Acesso em 18 jul 2022.

GELMEK HEALTHCARE. *Anatomia Coração*. 2021. Disponível em: <https://www.gelmekhealth.com/index.phpwxgjlackwittedlytdmeccil214971>. Acesso em 07 jul. 2022.

GOMES, David Silva. **Formação em noções básicas de interpretação de ECG: análise comparativa dos métodos e-learning e tradicional na aprendizagem e desempenho dos estudantes de medicina**. 2019. Dissertação para obtenção do Grau de Mestre (Mestrado) - Universidade da Beira Interior, Covilhã, 2019. Disponível em: https://ubibliorum.ubi.pt/bitstream/10400.6/8783/1/6948_14758.pdf. Acesso em: 11 mar 2023.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. GUO, Y. et al. Deep learning for visual understanding: A review. *Neurocomputing* Elsevier BV, abr. 2016. Disponível em: <http://dx.doi.org/10.1016/j.neucom.2015.09.116>.

HAYKIN, Simon S. *Neural networks: a comprehensive foundation*. 2. ed. atual. Upper Saddle River, NJ, USA: Prentice Hall, 1999.

HOMAEINEZHAD, M. R. et al. Ecg arrhythmia recognition via a neuro-SVM-KNN hybrid classifier with virtual qrs image-based geometrical features. *Expert Systems with Applications*, v. 39, p. 2047–2058, 2012.

HUA, K. L. et al. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. OncoTargets and Therapy Informa UK Limited, ago. 2015. Disponível em: <http://dx.doi.org/10.2147/OTT.S80733>.

ISIN, A.; OZDALILI, S. Cardiac arrhythmia detection using deep learning. 2017. In: 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, ICSCCW. Budapeste, Hungria.

JABBAR, A.; LI, X.; OMAR, B. A Survey on Generative Adversarial Networks: Variants, Applications, and Training. arXiv, 2020. Disponível em: <https://arxiv.org/abs/2006.05132>.

JEYARANI, A. D.; JAYA SINGH, T. Analysis of noise reduction techniques on QRS ECG waveform - by applying different filters. Recent Advances in Space Technology Services and Climate Change 2010 (RSTS & CC-2010). Em: 2010 RECENT ADVANCES IN SPACE TECHNOLOGY SERVICES AND CLIMATE CHANGE (RSTSCC). IEEE. Nov. 2010. Disponível em: <http://dx.doi.org/10.1109/RSTSCC.2010.5712835>.

KACHUEE, M.; FAZELI, S.; SARRAFZADEH, M. ECG Heartbeat Classification: A Deep Transferable Representation. 2018 IEEE International Conference on Healthcare Informatics (ICHI). Em: 2018 IEEE INTERNATIONAL CONFERENCE ON HEALTHCARE INFORMATICS (ICHI). IEEE, jun. 2018. Disponível em: <http://dx.doi.org/10.1109/ICHI.2018.00092>.

KERAS. Keras: The Python Aprendizado Profundo Library. 2018. Disponível em: <https://keras.io/>. Acesso em 20 jun 2022.

KHAN, M. U. et al. Biometric Authentication System Based on Electrocardiogram (ECG). 2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS). Em: 2019 13TH INTERNATIONAL CONFERENCE ON MATHEMATICS, ACTUARIAL SCIENCE, COMPUTER SCIENCE AND STATISTICS (MACS). IEEE, Dez. 2019. Disponível em: <http://dx.doi.org/10.1109/MACS48846.2019.9024820>.

KNOWLEDGE TRANSFER. Explain Pooling layers: Max Pooling, Average Pooling, Global Average Pooling, and Global Max pooling. 2021. Disponível em: <https://androidkt.com/explain-pooling-layers-max-pooling-average-pooling-global-average-pooling-and-global-max-pooling/>. Acesso em: 09 jan 2023.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. NatureSpringer Science and Business Media LLC, 27 maio 2015. Disponível em: <http://dx.doi.org/10.1038/nature14539>.

LI, R. et al. Interpretability Analysis of Heartbeat Classification Based on Heartbeat Activity's Global Sequence Features and BiLSTM-Attention Neural Network. IEEE Access Institute of Electrical and Electronics Engineers (IEEE), 2019. Disponível em: <http://dx.doi.org/10.1109/ACCESS.2019.2933473>.

LIMA, Jaimilton dos Santos. **Modelo para detecção de arritmias cardíacas baseados em coeficientes de predição linear e rede neural convolucional 1D**. Dissertação (Mestrado Profissional em Engenharia de Sistemas e Produtos) – Instituto Federal de Educação, Ciência e Tecnologia da Bahia, Salvador, 2022.

LIN, C.-C. YANG, C.-M. Heartbeat classification using normalized RR intervals and morphological features, *Math. Problem Eng.* 2014. 2014. 1–11. DOI: <https://doi.org/10.1155/2014/712474>.

LLAMEDO, M.; MARTÍNEZ, J.P. Heartbeat classification using feature selection driven by database generalization criteria. *IEEE Transactions on Biomedical Engineering*. Volume 58, Issue 3 PART 1, 2011, Pages 616-625. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20729162/>. Acesso em: 07 de fev. de 2023.

LOPEZ, Martin Andreoni; MATTOS, Diogo M. F. Resumo de Grandes Volumes de Dados com Filtro de Bloom: Uma Abordagem Eficiente para Aprendizado Profundo com Redes Neurais Convolucionais em Fluxos de Rede. In: SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES E SISTEMAS DISTRIBUÍDOS (SBRC), 39. 2021, Uberlândia. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 532-545. ISSN 2177-9384. DOI: <https://doi.org/10.5753/sbrc.2021.16745>.

LU, Y. et al. Automated arrhythmia classification using depthwise separable convolutional neural network with focal loss. *Biomedical Signal Processing and Control* Elsevier BV, Ago. 2021. Disponível em: <http://dx.doi.org/10.1016/j.bspc.2021.102843>.

LU, Y. et al. Automated arrhythmia classification using depthwise separable convolutional neural network with focal loss. *Biomedical Signal Processing and Control* Elsevier BV, ago. 2021. Disponível em: <http://dx.doi.org/10.1016/j.bspc.2021.102843>.

LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados Fap UNIFESP (SciELO)*, Abr. 2021. Disponível em: <http://dx.doi.org/10.1590/s0103-4014.2021.35101.007>.

LUZ, E. et al. ECG-based heartbeat classification for arrhythmia detection: A survey. 2015. Elsevier.

LUZ, E. J. da S. **Classificação Automática De Arritmias: Um Novo Método Usando Classificação Hierárquica**. Orientador: David Menotti Gomes. 2012. 70 f. Dissertação (Mestrado em Ciência da Computação) - Instituto de Ciências Exatas e Biológicas, Universidade Federal de Ouro Preto, Ouro Preto, 2012. Disponível em: https://www.repositorio.ufop.br/bitstream/123456789/3055/1/DISSERTA%C3%87%C3%80_Classifica%C3%A7%C3%A3oAutom%C3%A1ticaArritmias.PDF. Acesso em: 07 jul 2022.

LUZ, E. J., Schwartz, W. R., Cámara-Chávez, G., & Menotti, D. (2016). ECG-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, vol. 127, 144–164. <https://doi.org/10.1016/j.cmpb.2015.12.008>.

LYNN, P. A. Recursive digital filters for biological signals. *Medical & Biological Engineering* Springer Science and Business Media LLC. Jan. 1971. Disponível em: <http://dx.doi.org/10.1007/BF02474403>.

MADEIRO, J. P. V. Detecção e segmentação automática de batimentos cardíacos do eletrocardiograma por modelagem matemática e combinação das transformadas Wavelet e de

Hilbert. 2013. 130 f. Tese (Doutorado em Engenharia de Teleinformática)-Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013.

MAGALHÃES, L. Coração: anatomia, estrutura e função. **Toda Matéria**. 2011. Disponível em: <https://www.todamateria.com.br/coracao/>. Acesso em 20 jan 2019.

MANZAN, W. A. The utilization of Wavelets transforms in the extraction of characteristics and patterns recognition in ECG signals. 2006. 105 f. Dissertação (Mestrado em Ciências Exatas e da Terra) - Universidade Federal de Uberlândia, Uberlândia, 2006.

MARTIS, R. J. et al. Application of principal component analysis to ECG signals for automated diagnosis of cardiac health. *Expert Systems with Applications* Elsevier BV. Out. 2012. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2012.04.072>.

MEDICALEXPO. Que eletrocardiógrafo escolher. Disponível em: < <http://guide.medicaexpo.com/pt/que-eletrocardiografo-escolher/> >. Publicado em 2014. Acesso em: 13 abr 2020.

MESSIAS, Bruno Cayres. **Rede neural convolucional com dois canais para classificação automática de arritmias em sinais de ecg**. 2022. Trabalho de Conclusão de Curso. (Graduação em Engenharia Eletrônica) - Universidade Federal de Santa Catarina, Florianópolis, Santa Catarina, 2022.

MITRA, R. N. et al. A robust technique for delineation and features extraction of ECG signal from mobile-phone photography. 2012 International Conference on Communications, Devices and Intelligent Systems (CODIS). Em: 2012 INTERNATIONAL CONFERENCE ON COMMUNICATIONS, DEVICES AND INTELLIGENT SYSTEMS (CODIS). IEEE, Dez. 2012. Disponível em: <http://dx.doi.org/10.1109/CODIS.2012.6422151>.

MITTELMAN, R. Time-series modeling with undecimated fully convolutional neural networks. arXiv, 2015. Disponível em: <https://arxiv.org/abs/1508.00317>.

MORSCH, José. O que são as ondas do eletrocardiograma e como interpretar?, 2018. Disponível em: <https://telemedicinamorsch.com.br/blog/ondas-do-eletrocardiograma>. Acesso em: 08 jul 2022.

MORSCH, José. Fatores que interferem na qualidade do ECG, 2019. Disponível em: <https://telemedicinamorsch.com.br/blog/qualidade-do-eletrocardiograma>. Acesso em: 15 mai 2023.

MOUSAVI, S.; AFGHAH, F. Inter- and Intra- Patient ECG Heartbeat Classification for Arrhythmia Detection: A Sequence to Sequence Deep Learning Approach. ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Em: ICASSP 2019 - 2019 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNAL PROCESSING (ICASSP). IEEE, maio 2019. Disponível em: <http://dx.doi.org/10.1109/ICASSP.2019.8683140>.

MY EKG. Arritmias Ventriculares. 2018. Disponível em: <http://pt.my-ekg.com/arritmiascardiacas/arritmias-ventriculares.html>. Acesso em 10 jan 2023.

NAGATA, Natália; CANDIDO, Renato; SILVA, Magno. O efeito da divisão de dados na classificação de arritmias usando redes neurais convolucionais. XXXIX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS, Fortaleza, Ceará, p. 1-2, 29 set. 2021. Disponível em: 10.14209/sbrt.2021.1570728813. Acesso em: 7 fev 2023.

NARDELLI, P.; JIMENEZ-CARRETERO, D.; BERMEJO-PELAEZ, D.; WASHKO, G.; RAHAGHI, F.; LEDESMA-CARBAYO, M.; ESTÉPAR, R. Pulmonary Artery-Vein Classification in CT Images Using Aprendizado Profundo. 2018. DOI 10.1109/TMI.2018.2833385. IEEE Transactions on Medical Imaging.

NORDQVIST, C. Arrhythmia: Causes, symptoms, types, and treatment. Disponível em: <https://www.medicalnewstoday.com/articles/8887.php>. Acesso em 10 jan 2023.

Nvidia. (2022). CUDA Zone. Disponível em: <https://developer.nvidia.com/cuda-zone>. Acesso em: 26 abr 2023.

OH, S.L; NG E.Y.K; TAN R.S; ACHARYA, U.R. Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats, Computers in Biology and Medicine, 2018, Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0010482518301446>. Acesso em: 15 jul 2022.

OLIVEIRA, F. I. de. **Transformada de Hilbert sobre bases de wavelets: detecção de complexos QRS**. 2007. 210 f. Dissertação (Mestrado em Teleinformática)-Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2007.

PADILLA, José Manuel Hernández. Arritmias Cardíacas. SOPORTE VITAL BÁSICO Y AVANZADO, pp.93-100, Chapter: Capítulo 13. Universidad de Almería. 2016.

PAN, J.; TOMPKINS, W. A Real-Time QRS Detection Algorithm. 1985. IEEE Transactions on biomedical engineering 3 (32), p.230-236. 1985.

PASSO, S. J. G.; OLIVEIRA, H. S. de; PINTO, R. A.; QUISPE, K. G. M.; GUSTI, R.; SOUTO, E. J. P. Classificação de Arritmias com Paradigma Inter e Intra Paciente utilizando Aprendizagem Profunda. Journal of Health Informatics, Brasil, v. 12, 2021. Disponível em: <https://jhi.sbis.org.br/index.php/jhi-sbis/article/view/838>. Acesso em: 20 dez 2022.

PASTORE, C. A. et al. **III Diretrizes da Sociedade Brasileira de Cardiologia Sobre Análise e Emissão de Laudos Eletrocardiográficos**. Rio de Janeiro: Arq. Bras. Cardiol 2016.

PENHA, D.; CASTRO, A. Convolutional Neural Network Applied to the Identification of Residential Equipment in Nonintrusive Load Monitoring Systems. Computer Science & Information Technology. Em: 3RD INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND APPLICATIONS. Academy & Industry Research Collaboration Center (AIRCC), 30 dez. 2017. Disponível em: <http://dx.doi.org/10.5121/csit.2017.71802>.

PERERA, Ayeshmantha. What is Padding in Convolutional Neural Network's(CNN's) padding. [S. l.], 2 set. 2018. Disponível em: <https://ayeshmanthaperera.medium.com/what-is-padding-in-cnns-71b21fb0dd7>. Acesso em: 18 mar 2023.

PETMEZAS, G. et al. State-of-the-Art Deep Learning Methods on Electrocardiogram Data: Systematic Review. JMIR Medical Informatics JMIR Publications Inc., 15 ago. 2022. Disponível em: <http://dx.doi.org/10.2196/38454>.

Physionet. (2016). European ST-T Database. Disponível em: <https://archive.physionet.org/physiobank/database/edb/>. Acesso em: 31 mar 2023.

Physionet. (2016). The MIT-BIH Noise Stress Test Database. Disponível em: <https://archive.physionet.org/physiobank/database/nsttdb/>. Acesso em: 31 mar 2023.

Physionet. (2018). Creighton University Ventricular Tachyarrhythmia Database. Disponível em: <https://archive.physionet.org/physiobank/database/cudb/>. Acesso em: 31 mar 2023.

Physionet. (2018). MIT-BIH Arrhythmia Database. Disponível em: <https://archive.physionet.org/physiobank/database/mitdb/>. Acesso em: 31 mar 2023.

PIHLGREN, G. G.; SANDIN, F.; LIWICKI, M. Improving Image Autoencoder Embeddings with Perceptual Loss. 2020 International Joint Conference on Neural Networks (IJCNN). Em: 2020 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN). IEEE, jul. 2020. Disponível em: <http://dx.doi.org/10.1109/IJCNN48605.2020.920743>.

Python. (2022, August 08). Python 3.10.7. Disponível em: <https://www.python.org/downloads/release/python-3107/>. Acesso em: 22 fev 2023.

RASCHKA, S. Linear Discriminant Analysis. 2014. Disponível em: https://sebastianraschka.com/Articles/2014_python_lda.html. Acesso em 20 jan 2019.

RAWI, A. A.; ELBASHIR, M. K.; AHMED, A. M. ECG Heartbeat Classification Using CONVXGB Model. Electronics, v. 11, n. 15, p. 2280, 22 jul. 2022.

REGIS, Carlos Danilo Miranda; CALDEIRA, Luiz Guedes; GURJÃO, Edmar Candeia. Avaliação da amostragem compressiva em sinais de ECG e imagens digitais. Revista Principia - Divulgação Científica e Tecnológica do IFPB N ° 29, 2016. Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – Campus João Pessoa, Universidade Federal de Campina Grande. DOI: 10.18265/1517-03062015v1n29p95-104.

Release dia mundial do coração e a necessidade de atenção paras as arritmias cardíacas. SOBRAC. disponível em: <https://sobrac.org/home/release-dia-mundial-do-coracao-e-a-necessidade-de-atencao-paras-as-arritmias-cardiacas>. Acesso em: 13 fev 2023.

REXY, J. VELMANI, P. RAJAKUMAR, T. C. Heart beat classification in mit-bih arrhythmia ecg dataset using double layer bi- lstm model. International Journal of Mechanical Engineering. 6. 2021. Disponível em: https://kalaharijournals.com/resources/SP-Vol.6_53.pdf. Acesso em: 19 de jul. de 2022.

ROHMANTRI, Robby. SURANTHA, Nico. Arrhythmia Classification using 2D Convolutional Neural Network. International Journal of Advanced Computer Science and Applications. 11. 2020. DOI: 10.14569/IJACSA.2020.0110427.

SANNINO, G.; DE PIETRO, G. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. Future Generation Computer Systems Elsevier BV, set. 2018. Disponível em: <http://dx.doi.org/10.1016/j.future.2018.03.057>.

SANTANA, João Roberto Gomes. **Classificação de arritmias cardíacas em sinais de ECG utilizando redes neurais profundas**. 2022. 80 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas, Manaus (AM), 2021.

SAYADI, O; SHAMSOLLAHI, MB. A model-based Bayesian framework for ECG beat segmentation. *Physiol Meas.* 2009 Mar;30(3):335-52. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/19242046/>. Acesso em: 07 jul 2022.

SCHWARZ, L. Artigo de Revisão: Eletrocardiograma. *Ilha Digital*, Vol.1. 2009.

SEELEY, R. et al. *Anatomy & Physiology*. Portugal: Lusociência, 2016.

SEITANIDIS, P.; GIALELIS, J.; PAPACONSTANTINO, G. Identifying heart arrhythmias through multi-level algorithmic processing of ECG on edge devices. *Procedia Computer Science Elsevier BV*. 2022. Disponível em: <http://dx.doi.org/10.1016/j.procs.2022.07.104>.

SHAKER, A. M. et al. Generalization of Convolutional Neural Networks for ECG Classification Using Generative Adversarial Networks. *IEEE Access Institute of Electrical and Electronics Engineers (IEEE)*. 2020. Disponível em: <http://dx.doi.org/10.1109/ACCESS.2020.2974712>.

Silva L, Peres S, Boscarioli C. *Introdução à mineração de dados com aplicações em R*. Rio de Janeiro: Elsevier; 2016.

SILVA, César Nogueira; MATOS, Jefferson Almeida; LOPES, Fernanda Ferrezi. **Aquisição de eletrocardiograma e classificação de arritmias por machine learning**. 2022. Trabalho de Conclusão de Curso. (Bacharel em Engenharia Elétrica) - Centro Universitário FEI, São Bernardo do Campo, 2022.

SILVA, H. et al. Off-the-person electrocardiography: performance assessment and clinical correlation, *Health Technol.* 4 (4), p.309–318. 2015.

SILVA, Márcio Cândido da. **Sistema para Avaliação da Conformidade de Eletrocardiógrafos**. Dissertação - (Mestrado em Metrologia para a Qualidade e Inovação) - Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, 2008.

SINGH, B. N.; TIWARI, A. K. Optimal selection of wavelet basis function applied to ECG signal denoising. *Digital Signal Processing Elsevier BV*. Maio 2006. Disponível em: <http://dx.doi.org/10.1016/j.dsp.2005.12.003>.

SORIA, M.; MARTÍNEZ, J. Analysis of multidomain features for ECG classification. *Comput. Cardiol.*, p.561–564. 2009.

SUTTON, R. S.; BARTO, A. G. et al. *Reinforcement learning: An introduction*. [S.l.]: MIT press, 1998.

SZNAJDER, M.; ŁUKOWSKA, M. Python Online and Offline ECG QRS Detector based on the Pan-Tomkins algorithm. 2017. Disponível em: <https://zenodo.org/record/826614>. Acesso em 20 jan 2019.

Tensorflow. (2022). TensorFlow. Disponível em: <https://www.tensorflow.org/resources/learn-ml>. Acesso em: 23 jan 2023.

WANG, J.-S. et al. ECG arrhythmia classification using a probabilistic neural network with a feature reduction method. *Neurocomputing*, v. 116, p. 38–45, 2013.

WANG, P. et al. ECG Arrhythmias Detection Using Auxiliary Classifier Generative Adversarial Network and Residual Network. *IEEE Access*Institute of Electrical and Electronics Engineers (IEEE), 2019. Disponível em: <http://dx.doi.org/10.1109/ACCESS.2019.2930882>.

WOLF, A. S. O CORAÇÃO E A ATIVIDADE ELÉTRICA CARDÍACA. Divisão de Bibliotecas e Documentação PUC-Rio, 2004. Disponível em: http://www2.dbd.puc-rio.br/pergamum/tesesabertas/0210429_04_cap_02.pdf. Acesso em 11 jan 2023.

YAMASHITA, R.; NISHIO, M.; DO, R.K.G. et al. Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9, 611–629, 2018. Disponível em: <https://doi.org/10.1007/s13244-018-0639-9>. Acesso em 07 jul 2022.

YE, C. COIMBRA, M.T. KUMAR, B.V.K.V. Arrhythmia detection and classification using morphological and dynamic features of ECG signals, in: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2010, pp. 1918–1921. DOI: 10.1109/IEMBS.2010.5627645.

YE, Kun. Inter-Patient Electrocardiogram Heartbeat Classification with 2-D Convolutional Neural Network. 2018. University of Victoria. Disponível em: <https://dspace.library.uvic.ca/handle/1828/12586>. Acesso em: 19 mar 2023.

YOCHUM, M.; RENAUD, C.; JACQUIR, S. Automatic detection of P, QRS and T patterns in 12 leads ECG signal based on CWT. *Biomedical Signal Processing and Control* Elsevier BV, Mar. 2016. Disponível em: <http://dx.doi.org/10.1016/j.bspc.2015.10.011>.

YU, X. An ECG arrhythmia image classification system based on convolutional neural network. *Journal of Physics: Conference Series* IOP Publishing, 1 maio 2020. Disponível em: <http://dx.doi.org/10.1088/1742-6596/1544/1/012109>.

YUSUF, S. A.; HIDAYAT, R. MFCC Feature Extraction and KNN Classification in ECG Signals. 2019 6th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE). Em: 2019 6TH INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY, COMPUTER AND ELECTRICAL ENGINEERING (ICITACEE). IEEE, Set. 2019. Disponível em: <http://dx.doi.org/10.1109/ICITACEE.2019.8904285>.

ZHAI, X.; TIN, C. Automated ECG Classification using Dual Heartbeat Coupling based on Convolutional Neural Network. *IEEE Access*. DOI: 10.1109/ACCESS.2018.2833841. 2018.

ZHANG, D. et al. An ECG Heartbeat Classification Method Based on Deep Convolutional Neural Network. (G. Xiaoqing, Ed.) *Journal of Healthcare Engineering* Hindawi Limited, , 27 set. 2021. Disponível em: <http://dx.doi.org/10.1155/2021/7167891>.

ZHANG, Z. et al. Heartbeat classification using disease-specific feature selection, *Computers in Biology and Medicine*, Volume 46. 2014. Pages 79-89, ISSN 0010-4825. DOI: <https://doi.org/10.1016/j.combiomed.2013.11.01>.

