



UNIVERSIDADE FEDERAL DO PARÁ

INSTITUTO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ESTRUTURA COMPETITIVA DE REDES NEURAIS CONVOLUCIONAIS AUTO-
ASSOCIATIVAS PARA CLASSIFICAÇÃO DE ARRITMIAS**

ALEXANDRE FARIAS BAIA

DM: 14/2019

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém – Pará – Brasil
2019

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

ALEXANDRE FARIAS BAIA

**ESTRUTURA COMPETITIVA DE REDES NEURAIIS CONVOLUCIONAIS AUTO-
ASSOCIATIVAS PARA CLASSIFICAÇÃO DE ARRITMIAS**

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 – Pará – Brasil

2019

Dados Internacionais de Catalogação - na – Publicação (CIP) Sistema de Bibliotecas da UFPA

B152e Baia, Alexandre Farias, 1986-

Estrutura competitiva de redes neurais convolucionais auto-associativas para classificação de arritmias / Alexandre Farias Baia.-2019.

Orientadora: Adriana Rosa Garcez Castro
Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2019.

1.Redes neurais (computação). 2. Arritmia- Processamento de dados. 3. Eletrocardiografia – Interpretação – Testes. I. Título.

CDD 23. ed. 006.32

Elaborada por Lucicléa S. de Oliveira – CRB -2/648

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

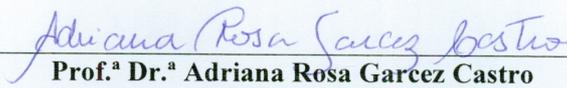
**“ESTRUTURA COMPETITIVA DE REDES NEURAIAS CONVOLUCIONAIS AUTO-
ASSOCIATIVAS PARA CLASSIFICAÇÃO DE ARRITMIAS”**

AUTOR: ALEXANDRE FARIAS BAIA

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.

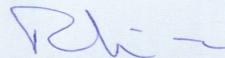
APROVADA EM: 17/04/2019

BANCA EXAMINADORA:



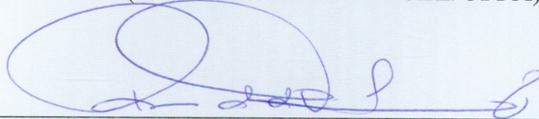
Prof.^a Dr.^a Adriana Rosa Garcez Castro

(Orientadora – PPGEE/UFPA)



Prof. Dr. Roberto Celio Limão de Oliveira

(Avaliador Interno – PPGEE/UFPA)



Prof. Dr. Ronaldo de Freitas Zampolo

(Avaliador Externo ao Programa – FCT/UFPA)

VISTO:



(Coordenadora do PPGEE/ITEC/UFPA)

RESUMO

Este trabalho apresenta a proposta de dois sistemas automáticos para auxílio à detecção de anomalias em batimentos cardíacos e apoio à decisão médica. Os sistemas foram desenvolvidos para a identificação de arritmia rítmica e arritmias morfológicas a partir de sinais obtidos de um Eletrocardiograma (ECG). Ambos os sistemas são baseados em uma estrutura competitiva de Redes Neurais Convolucionais (CNN) Auto-associativas, sendo que cada rede foi treinada para reconstrução dos sinais apresentados na sua entrada. Para o caso do classificador rítmico, o sistema foi desenvolvido a partir do uso dos sinais do ECG, sem passar por um processo de extração de características, e para o caso do classificador morfológico o sistema se baseou no complexo QRS extraído do sinal de ECG. Para desenvolvimento e teste dos sistemas foi utilizada a base de dados *MIT-BIH Arrhythmia* de sinais ECG. Uma acurácia de 88,9% foi alcançada para o Classificador Rítmico e de 81,73% para o Classificador Morfológico, no caso em que se considera a base de testes para avaliação. Os resultados obtidos demonstram a aplicabilidade das estruturas competitivas propostas para o problema de classificação de arritmias.

Palavras-chaves: Rede Neural Convolucional. ECG. Arritmias. Rede Auto-associativa.

ABSTRACT

This work presents the proposal of two automatic systems to aid in the detection of anomalies in heart beats and medical decision support. The systems were developed for the identification of rhythmic arrhythmia and morphological arrhythmias from signals obtained from an electrocardiogram (ECG). Both systems are based on a competitive structure of Convolutional Autoencoders (CAE), and each network was trained to reconstruct the signals presented at its entrance. For the case of the rhythmic classifier, the system was developed from the use of the ECG signals, without undergoing a feature extraction process, and for the case of the morphological classifier, the system was based on the QRS complex extracted from the ECG signal. For the development and testing of the systems, the database MIT-BIH Arrhythmia of ECG signals was used. An accuracy of 88.9% was achieved for the Rhythmic Classifier and 81.73% for the Morphological Classifier, in the case in which the evaluation basis is considered. The results obtained demonstrate the applicability of the proposed competitive structures to the arrhythmia classification problem.

Keywords: Convolutional Neural Network. ECG. Arrhythmias. Autoencoder Network.

LISTA DE ILUSTRAÇÕES

Figura 1 – Paciente com eletrodos em pontos específicos do corpo	15
Figura 2 – Atividade elétrica de um sinal cardíaco normal: onda P (despolarização do átrio), complexo QRS (despolarização dos ventrículos) e onda T (repolarização dos ventrículos)	16
Figura 3 – Exemplo de ECG com arritmia	16
Figura 4 – A arquitetura de uma RNN	20
Figura 5 – Arquitetura de uma LSTM. Em destaque ao centro, a sua célula de memória	20
Figura 6 – Arquitetura de uma CNN	21
Figura 7 – Exemplificação do Mapa de Parâmetro. Da esquerda para direita: Imagem original, Mapa de Parâmetros e a resposta mais significativa do mapa	22
Figura 8 – Funcionamento do <i>Pooling</i> Médio (à esquerda) e Máximo (à direita), com <i>Pool Size</i> = 4	23
Figura 9 – Representação de uma rede Auto-associativa	24
Figura 10 – Representação de uma CNN Auto-associativa	25
Figura 11 – Localização do Coração Humano	26
Figura 12 – A estrutura do coração humano	27
Figura 13 – Componentes do batimento cardíaco	28
Figura 14 – Eletrocardiógrafo	28
Figura 15 – Leitura de sinais elétricos <i>on the person</i>	30
Figura 16 – Pontos de coleta de frequências cardíacas em um ECG	30
Figura 17 – Tipos de Leituras de um ECG	31
Figura 18 – Arritmia Rítmica	31
Figura 19 – Arritmia Morfológica	32
Figura 20 – Taquicardia Ventricular	33
Figura 21 – Taquicardia Supraventricular	33

Figura 22 – Bradicardia atrioventricular	33
Figura 23 – Pausa Sinusal	34
Figura 24 – Diagrama de Blocos com as etapas de um sistema automático para a classificação de arritmias	34
Figura 25 – Segmentação por meio da detecção do Complexo QRS. Os pontos marcados representam a segmentação tendo como base a onda S	36
Figura 26 – Intervalo RR	37
Figura 27 – Outras características para segmentação do ECG	38
Figura 28 – Estrutura do sistema de Classificação de Arritmias Rítmicas	47
Figura 29 – Estrutura do sistema de Classificação de Arritmias Morfológicas	48
Figura 30 – ECG de um paciente com ritmo cardíaco normal	50
Figura 31 – ECG de um paciente com ritmo cardíaco com arritmia	50
Figura 32 – ECG original e reconstruído de um paciente com ritmo cardíaco normal	51
Figura 33 – ECG original e reconstruído de um paciente com arritmia	51
Figura 34 – Matriz de Confusão gerada para dados de teste (Classificador Rítmico)	52
Figura 35 – Exemplo de Sinal classificado pelo Classificador Rítmico	53
Figura 36 – Complexo QRS para as Classes N, S e V	55
Figura 37 – Matriz de Confusão gerada para dados de teste (Classificador Morfológico)	58
Figura 38 – Exemplo de Sinal N classificado pelo Classificador Morfológico	58
Figura 39 – Exemplo de Sinal S classificado pelo Classificador Morfológico	59
Figura 40 – Exemplo de Sinal V classificado pelo Classificador Morfológico	59

LISTA DE TABELAS

Tabela 1 – Aplicações das arquiteturas de Aprendizado Profundo	19
Tabela 2 – Medida em mV de cada componente do batimento cardíaco em uma frequência cardíaca de 60 bpm de um adulto saudável	29
Tabela 3 – Classes do MIT-BIH mapeadas para o AAMI	41
Tabela 4 – Conjuntos DS1 e DS2 propostos por (DE CHAZAL et al., 2004)	42
Tabela 5 – Resultados apresentados na literatura para inter-paciente	44
Tabela 6 – Resultados apresentados na literatura para intra-paciente	45
Tabela 7 – Parâmetros de Treinamento da Rede (Classificador Rítmico)	51
Tabela 8 – Resultados da Literatura para a classificação de arritmias rítmicas	53
Tabela 9 – Total de amostras por classe para DS1 (Classificador Morfológico)	56
Tabela 10 – Total de amostras por classe para o DS2 (Classificador Morfológico)	56
Tabela 11 – Parâmetros de Treinamento da Rede (Classificador Morfológico)	57
Tabela 12 – Resultados do Classificador Morfológico por Classe	57
Tabela 13 – Resultados de Classificadores Morfológicos	60

LISTA DE ABREVIATURAS SIGLAS

AAMI – *Association for the Advancement of Medical Instrumentation*

AG – Algoritmo Genético

BII – Bloqueio Cardíaco

BW – ECG com *baseline Wander*

CAE – *Convolutional Autoencoder*

CNN – Rede Neural Convolutacional

DBN – Rede de Crença Profunda

DWT – *Discrete Wavelet Transform*

ECG – Eletrocardiograma

ECOC – *Error-correcting output coding*

ELM – *Extreme Machine Learning*

FIR – Filtro de resposta ao impulso finita

FFS – *Floating Feature Selection*

GDA – Análise Discriminante Generalizada

HMM – Cadeia de Markov

HSOC – *High order statistics cummulants*

ICA – Análise de Componentes Independentes

KNN – k-Vizinho mais Próximo

LD – Discriminante Linear

LSTM – Redes de Memória de Longo Prazo

MIT – *Massachusetts Institute of Technology*

MLP – Rede Neural Perceptron de múltiplas camadas

MultiHMM – Cadeia de Markov Múltipla

OMS – Organização Mundial de Saúde

PCA – Análise de Componentes Principais

PLI – ECG com sinal PLI

PNN – Rede Neural Probabilística

PSO – Otimização por Enxame de Partículas

PVC – Contração Ventricular Prematura

RC – Computação por Reservatório

RCE – *Recursive Cluster Elimination*

RDDL – Aprendizado por dicionário profundo robusto

RNAA – Rede Neural Auto-associativa

RNA – Rede Neural Artificial

RNN – Rede Neural Recorrente

SFFS – *Sequential forward floating search*

SVM – Máquina de Vetores de Suporte

SOM – Mapas Auto-Organizáveis

VCG – Vetorcardiografia

VF – Fibrilação Ventricular

SUMÁRIO

1 Introdução	15
1.1 Descrição Geral do Problema	15
1.2 Objetivo Geral	17
1.3 Estrutura da Dissertação	17
2 Redes Neurais Convolucionais	19
2.1 Introdução	19
2.2 Rede Neural Convolucional	21
2.2.1 Treinamento de uma Rede Neural Convolucional.....	23
2.2.2 Rede Neural Convolucional Auto-associativa	24
3 Arritmias Cardíacas e Sistemas Automáticos para Classificação de Arritmias	26
3.1 Introdução	26
3.2 Estrutura do Coração Humano	26
3.3 Sinal Cardíaco	27
3.4 Eletrocardiograma	28
3.5 Arritmia Cardíaca	31
3.6 Sistema Automático para classificação de Arritmias	34
3.6.1 Pré-processamento do sinal	35
3.6.2 Segmentação do Batimento	35
3.6.3 Extração de características	37
3.6.4 Classificação	39
3.6.5 Bancos de dados para desenvolvimento de sistemas automáticos e o padrão AAMI	40
3.6.5.1 Medidas para Evolução do sistema de classificação	42
3.7 Estado da arte em sistemas automáticos para Detecção de Arritmias	45
4 Sistema Automático para detecção de Arritmias baseado em Redes Neurais Convolucionais Auto-associativas	47
4.1 Introdução	47
4.2 Redes Convolucionais Auto-associativas Paralelas para classificação de arritmias Rítmicas	49
4.2.1 Base de dados para treino e teste	49
4.2.2 Treinamento e validação das CNNs.....	50
4.2.3 Resultados do sistema de classificação	52
4.2.4 Comparação com sistemas apresentados na literatura	53

4.3 Redes Convolucionais Auto-associativas Paralelas para classificação de arritmias Morfológicas	54
4.3.1 Base de dados para treino e teste	55
4.3.2 Treinamento e validação das CNNs	56
4.3.3 Resultados do sistema de classificação	57
4.3.4 Comparação com sistemas apresentados na literatura	60
5 Conclusão e Trabalhos Futuros	62
Referências Bibliográficas	63

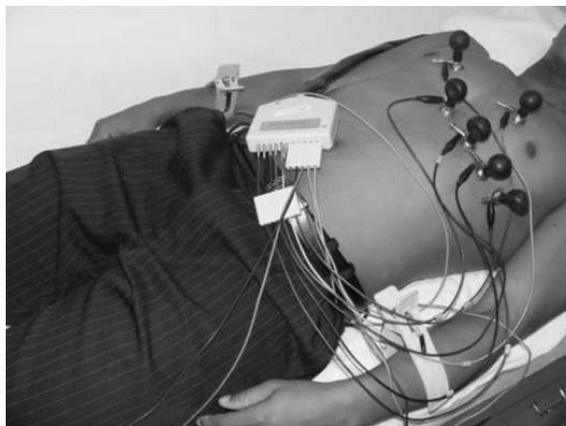
1 Introdução

1.1 Descrição Geral do Problema

As doenças cardiovasculares são consideradas, segundo a Organização Mundial de Saúde (OMS), como as doenças mais fatais em todo o mundo. Cerca de 17 milhões de pessoas por ano sofrem eventos associados a patologias cardíacas (OPAS, 2017). Estas doenças podem ser detectadas a tempo por um especialista através da análise de alterações nos padrões dos sinais cardíacos que podem ser monitorados através do uso de um Eletrocardiograma (ECG).

O Eletrocardiograma é um método de diagnóstico não-invasivo que permite a obtenção de informações a respeito do ritmo cardíaco de um paciente. Através do ECG, as anomalias no aparelho cardíaco podem ser detectadas através da análise de variações da corrente cardíaca em função do tempo. Para a coleta dos sinais cardíacos, aparelhos de medição (eletrodos) são colocados no corpo do paciente, onde para cada ponto de coleta pode-se obter um diagnóstico específico. A Figura 1 apresenta um paciente com eletrodos em pontos de coleta específicos para um diagnóstico.

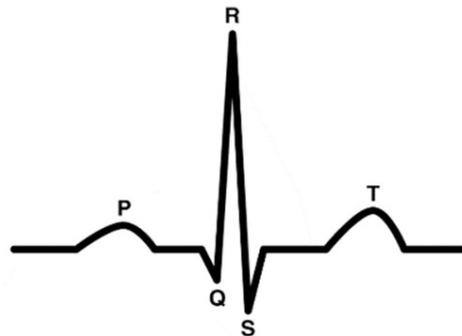
Figura 1 – Paciente com eletrodos em pontos específicos do corpo.



Fonte: (ARAGÃO, 2015)

A Figura 2 apresenta as diferentes ondas ao longo da atividade elétrica do coração que podem ser obtidas através de um ECG para um paciente com batimento cardíaco com frequência normal.

Figura 2 – Atividade elétrica de um sinal cardíaco normal: onda P (despolarização do átrio), complexo QRS (despolarização dos ventrículos) e onda T (repolarização dos ventrículos).



Fonte: (ISIN e OZDALILI, 2017).

Arritmia cardíaca é o nome dado para as diversas perturbações que podem modificar a frequência e/ou o ritmo dos batimentos cardíacos. As arritmias podem ser classificadas em duas categorias principais, sendo que uma categoria está relacionada aos batimentos cardíacos com ritmo irregular, chamada de Arritmia Rítmica, e a outra está relacionada às arritmias onde um único batimento cardíaco possui irregularidade, classificada como Arritmia Morfológica (LUZ et al., 2015). A Figura 3 apresenta exemplo de um sinal ECG de um paciente com arritmia.

Figura 3 – Exemplo de ECG com arritmia.



Fonte: Fonte: (PHYSIONET, 2018).

A identificação e classificação das arritmias pode ser realizada através da simples visualização dos sinais obtidos através do ECG, porém, esta análise se torna difícil devido ao tamanho destes sinais ao longo do tempo, dificultando desta forma o diagnóstico por parte do cardiologista.

Para auxílio à detecção de anomalias em batimentos cardíacos e apoio à decisão médica, alguns estudos têm sido realizados e apresentados na literatura utilizando sinais ECG aliados as técnicas de Aprendizado de Máquina, tais como Redes Neurais Artificiais (RNA) (LASSOUED e KETATA, 2018) (SAPNA et al., 2012) (KELWADE e SALANKAR, 2015),

Lógica Difusa (NAIK e REDDY, 2016) (TANDALE et al., 2017) e Máquina de Vetores de Suporte (SVM) (YE et al., 2012).

Atualmente as Redes Neurais Artificiais baseadas em Aprendizado Profundo (*Deep Learning*) vêm se destacando cada vez mais na literatura, em diversas áreas de aplicação, principalmente nas áreas voltadas para reconhecimento e classificação de imagens. O aprendizado profundo permite que modelos computacionais aprendam representações de dados com múltiplos níveis de abstração (LECUN et al., 2015). Além dos resultados promissores já alcançados para problemas envolvendo a aplicação voltada para reconhecimento de imagem representadas através de dados 2-D (NARDELLI et al., 2018), algumas pesquisas vêm sendo desenvolvidas com aplicações em problemas de classificação com o uso de dados 1-D (PENHA e CASTRO, 2017), tais como dados de séries temporais. Dentre as redes neurais profundas destacam-se as Redes de memória a longo prazo (*Long Short Term Memory*), as Redes Neurais Auto-associativas (*Autoencoders*), as Redes Auto-associativas Empilhadas (*Stacked autoencoder*) e as Redes Neurais Convolucionais (*Convolutional Neural Network*).

1.2 Objetivo Geral

Considerando os resultados promissores já apresentados na literatura da aplicação de redes neurais profundas para problemas utilizando dados 1-D, este trabalho tem como objetivo geral apresentar os resultados obtidos da pesquisa de aplicação de Redes Neurais Profundas ao problema de identificação de arritmias em sinais cardíacos. Duas estruturas competitivas de Redes Neurais Convolucionais Auto-associativas foram testadas e validadas para o problema de classificação de arritmias em sinais cardíacos, sendo uma estrutura desenvolvida para classificação de arritmia rítmica e outra para arritmia morfológica. Para desenvolvimento dos sistemas foi utilizada a base de dados *MIT-BIH Arrhythmia Database* (PHYSIONET, 2018), que apresenta medidas de sinais ECG de 48 pacientes.

1.3 Estrutura da Dissertação

No Capítulo 2 é apresentada a Rede Neural Convolucional (CNN), com sua arquitetura e o seu atual Estado da Arte.

No Capítulo 3 é apresentada uma breve teoria para um bom entendimento sobre sinais cardíacos e os problemas que podem ser detectados a partir de sua leitura através de ECG.

No Capítulo 4 é apresentado o sistema proposto para auxílio ao diagnóstico de anomalias através das estruturas competitivas de redes neurais convolucionais, além dos

resultados provenientes da pesquisa aqui apresentada e comparações com outros trabalhos existentes na literatura aplicados a classificação de ECGs.

No Capítulo 5 são apresentadas as conclusões obtidas a partir dos resultados relatados no Capítulo 4, assim como sugestões para trabalhos futuros.

2 Redes Neurais Convolucionais

2.1 Introdução

Uma Rede Neural Artificial baseada em Aprendizado Profundo apresenta múltiplas camadas de processamento com a capacidade de aprender representações de dados em múltiplos níveis de abstração (LECUN et al., 2015). Estas camadas transformam os dados brutos em um nível de representação maior a cada camada, permitindo com que funções mais complexas possam ser aprendidas.

Os modelos de Aprendizado Profundo possuem dois módulos de trabalho: o módulo onde é realizado um processamento em particular, como por exemplo, extração de características, e outro módulo onde é realizada a tarefa, podendo ser por exemplo uma tarefa de classificação ou regressão.

Dentre as arquiteturas de aprendizado profundo destacam-se as Redes Neurais Recorrentes (RNN), as Redes de Memória de Longo Prazo (LSTM), as Redes Neurais Convolucionais (CNN), as Redes Neurais Auto-associativas (*Autoencoders*) e as Redes Auto-associativas Empilhadas (*Stacked autoencoder*). Cada arquitetura de Aprendizado profundo é utilizada, geralmente, em determinado domínio de aplicação, como mostrado na Tabela 1.

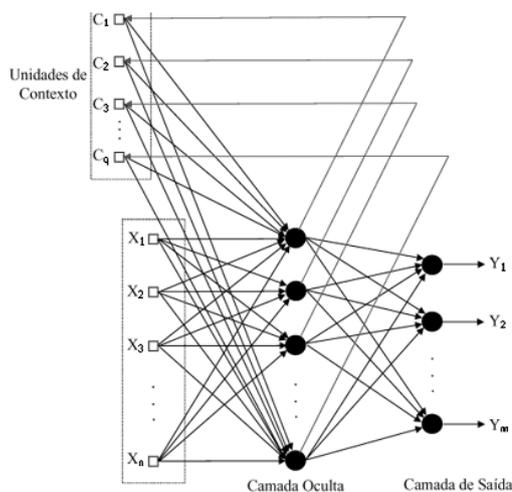
Tabela 1 – Aplicações das arquiteturas de Aprendizado Profundo.

Arquitetura	Exemplo de Aplicação
Redes Neurais Recorrentes	Reconhecimento de escrita manual
Redes de memória a longo prazo	Reconhecimento de fala
Rede Neural Convolucional	Reconhecimento de imagens
Rede Neural Auto-associativa	Processamento de Linguagem Natural
Rede Neural Auto-associativa Empilhada	Análise de Sentimento

Fonte: (JONES, 2017)

A RNN é uma das mais antigas arquiteturas de Aprendizado Profundo e se assemelha a uma rede *Perceptron feedforward*, porém possui conexões que realimentam a camada atual ou anteriores, ou seja, a rede possui memória, como mostrado na Figura 4.

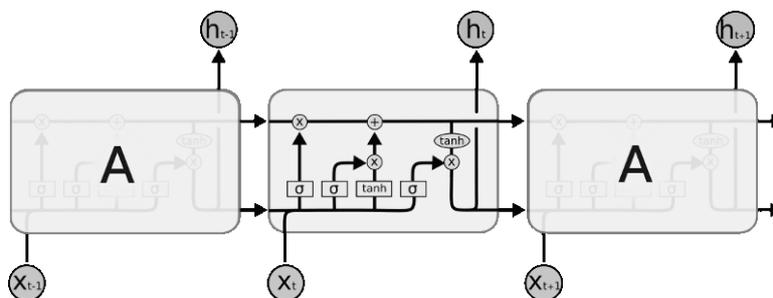
Figura 4 – A arquitetura de uma RNN.



Fonte: (SEGATTO e COURY, 2006).

A LSTM foi originada a partir das RNNs, mas com o diferencial de ser capaz de relembrar as suas entradas a longo prazo através de determinados componentes de sua arquitetura. Uma unidade especial chamada célula de memória atua como um acumulador, guardando o valor dos pesos originados da conexão anterior. A Figura 5 demonstra essa arquitetura.

Figura 5 – Arquitetura de uma LSTM. Em destaque ao centro, a sua célula de memória.



Fonte: (COLAH, 2015).

As Redes Neurais Auto-associativas e as Auto-associativas Empilhadas reproduzem em sua saída a entrada apresentada. Elas são compostas por codificadores, para a redução de características, e decodificadores, para a reconstrução das características. As Redes Auto-associativas Empilhadas possuem vários codificadores e decodificadores empilhados.

A CNN é uma arquitetura de Aprendizado Profundo que utiliza filtros convolucionais e camadas de *pooling* para o auxílio na extração de características dos dados de entrada. No geral, a CNN tenta reproduzir o comportamento de certos neurônios biológicos que respondem a algumas orientações de bordas identificadas pelo olho humano.

As Redes Neurais Convolucionais vêm recebendo cada vez mais atenção por parte da comunidade científica. Este renovado interesse se deve principalmente pelos excelentes resultados já alcançados na área de visão computacional, reconhecimento de imagens e processamento de sinais. Além dos resultados promissores para problemas envolvendo a aplicação de dados 2-D, alguns autores vêm desenvolvendo pesquisas na área de aplicação das CNNs em problemas com dados 1-D, tais como dados de séries temporais (BOROVYKH et al., 2018) e processamento de linguagem natural (YOUNG et al., 2018).

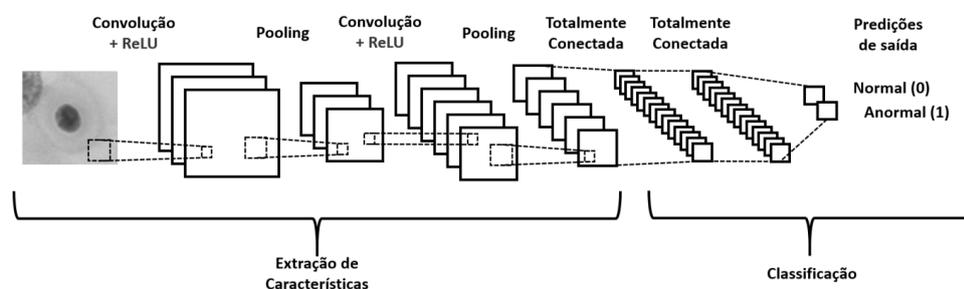
Considerando aplicações envolvendo tarefas de classificação, esta área tem se beneficiado significativamente com o advento das CNNs. No geral, os métodos apresentados na literatura para problemas de classificação de sinais baseiam-se no uso de recursos específicos para extração de características dos sinais a serem classificados para que estas sirvam de entrada para o sistema classificador. A grande vantagem da rede CNN para o problema de classificação diz respeito à capacidade que esta possui de aprender estas características por ela mesma, eliminando assim a necessidade de uma fase anterior de extração.

2.2 Rede Neural Convolucional

A CNN é uma arquitetura de Aprendizado Profundo criada por Yann LeCun em 1998 que visa simular o comportamento de determinados neurônios que se ativam quando a visão humana detecta certos aspectos presentes em uma imagem, como por exemplo as bordas, o que torna muito útil o seu uso em problemas de reconhecimento de imagens (JONES, 2017).

Uma CNN é composta por diversas camadas, cada qual com sua função. A Figura 6 apresenta uma possível estrutura de uma rede CNN.

Figura 6 – Arquitetura de uma CNN.



Fonte: (ARAÚJO et al., 2017)

Uma CNN possui a Camada Convolucional ou de Convolução que utiliza filtros para obter as características mais expressivas dos dados de entradas da CNN. Os filtros são compostos por janelas deslizantes que se movimentam através do campo receptivo para a

extração de características. A característica a ser identificada é definida através do tipo de filtro (*kernel*) a ser utilizado, como por exemplo, o filtro de identificação de bordas. Este filtro percorre a imagem toda, realizando operações de convolução sobre a região chamada de campo receptivo e guardando os resultados obtidos no mapa de ativações ou, como também é chamado, mapa de parâmetros (DESHPANDE, 2017). A Figura 7 exemplifica esse processo.

Figura 7 – Exemplificação do Mapa de Parâmetros. Da esquerda para direita: Imagem original, Mapa de Parâmetros e a resposta mais significativa do mapa.



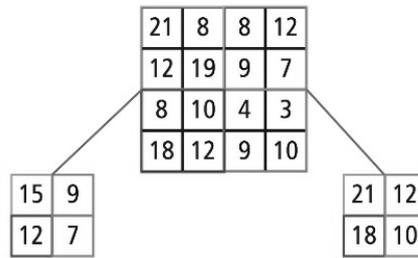
Fonte: (HE, 2015).

O tamanho do filtro de convolução varia de aplicação para aplicação, por exemplo, em uma tarefa de reconhecimento de imagens o tamanho pode variar em função do número de pixels da janela deslizante, enquanto em um processamento de linguagem natural tem-se a quantidade de palavras para se definir o tamanho da janela deslizante.

Logo após a camada de convolução tem-se a função de ativação Retificação Linear (ReLU), que é comumente usada para a introdução de não-linearidade ao modelo (NAIR e HINTON, 2010). A ReLU ajusta um limiar para a saída da camada de convolução, como $\max(0, x)$, e ela mantém o volume de dados intacto, além da vantagem de que esta acelera o treinamento da rede (ILANGO, 2018).

A camada de *Pooling* é responsável pela redução no número de parâmetros provenientes da camada de convolução, deixando assim esses parâmetros mais robustos contra ruídos e distorções (VISION, 2017). A matriz proveniente da camada de convolução é dividida em várias partes, e a partir destas, os parâmetros podem ser obtidos através de *Max Pooling*, quando se extrai o valor mais alto entre os índices da matriz particionada, ou por *Average Pooling*, quando se calcula o valor médio de todos os índices desta. A Figura 8 mostra o funcionamento do *Pooling*.

Figura 8 – Funcionamento do *Pooling* Médio (à esquerda) e Máximo (à direita), com *Pool Size* = 4.



Fonte: (VISION, 2017).

Uma CNN possui após suas camadas de processamento (Convolução e *Pooling*) uma camada completamente conectada (camada densa) que segue o padrão visto em diversas arquiteturas de redes, como por exemplo a Rede Neural *Perceptron* de múltiplas camadas (MLP) (MLP, 2018). É nesta camada que ocorre a tarefa para a qual a CNN foi designada, podendo ser tarefa de classificação, regressão, etc.

A camada de entrada da camada completamente conectada recebe os parâmetros oriundos da camada de *pooling*, com um número de neurônios de entrada igual ao número de parâmetros filtrados. A camada de saída possui um número de neurônios que depende da tarefa para qual a CNN foi designada. A camada de saída geralmente trabalha com a função de ativação *softmax* (CS231N, 2017) para o caso da tarefa de classificação. A função *softmax* transforma um vetor não normalizado em um normalizado dentro de uma distribuição de probabilidade, onde cada elemento está no intervalo $[0,1]$.

2.2.1 Treinamento de uma Rede Neural Convolutional

Uma CNN é treinada de forma que ela obtenha as características mais latentes dos dados de entrada através do processamento realizado em sua camada convolutional. Os dados de entrada que alimentam uma CNN podem ser apresentados de forma bruta ou pré-processados com o uso de filtros ou outras transformações.

Em sua camada convolutional, podem ser realizadas tanto convoluções espaciais como convoluções temporais. Na camada de convolução pode-se ajustar o tamanho da janela de convolução e o passo desta para a busca de um melhor resultado (DESHPANDE, 2017).

Na camadas de *Pooling*, o projetista do sistema deve decidir qual tipo de *pooling* (mínimo, médio ou máximo) se adequa para seus dados de entrada sendo os *poolings* mínimos e máximos os mais utilizados na literatura (DESHPANDE, 2017).

Na camada completamente conectada, tem-se a liberdade de escolha de uma *Perceptron* de Múltiplas Camadas, onde pode-se utilizar algoritmos como o *Backpropagation* (SATHYANARAYANA, 2014) para ajustes dos pesos da camada.

Para o treinamento geral da CNN, os pesos das camadas convolucionais e o pesos da camada completamente conectada são inicializados de forma aleatória, e a cada época, o algoritmo de treinamento utilizado, como por exemplo, o *Backpropagation*, realiza o ajuste desses pesos para uma melhor acurácia do modelo. Quanto ao método de condição de parada do treino, o projetista pode escolher entre vários já conhecidos no campo de aprendizado de máquina, como por exemplo escolher um determinado número de épocas, limiar do erro, média do erro, entre outras (ARAÚJO et al., 2017). Também é possível utilizar validação cruzada em uma CNN para melhoria de seu resultado de treinamento (MUCHAHARY, 2018).

2.2.2 Rede Neural Convolucional Auto-associativa

Uma Rede Neural Auto-associativa (RNAA) é uma arquitetura de rede focada na reconstrução na sua saída dos sinais apresentados em sua entrada. Em uma RNAA ocorre a compressão dos dados de entrada da rede na camada intermediária, onde então as características dos dados de entrada são aprendidas de forma específica. Uma RNAA possui duas camadas de processamento: a camada codificadora (*encoder*) para a compressão dos dados e uma decodificadora (*decoder*) para a descompressão deles. A Figura 9 apresenta a estrutura de uma rede RNAA.

Figura 9 – Representação de uma Rede Auto-associativa.



Fonte: Autor.

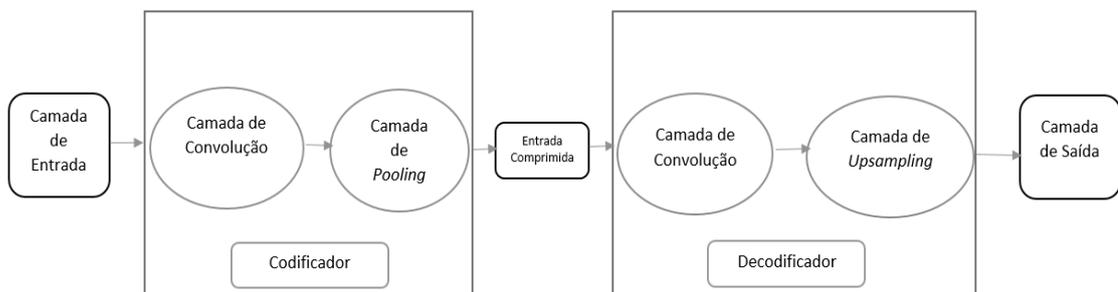
As redes MLPs vêm sendo bastante utilizadas como redes auto-associativas, para aplicação em diversos problemas de classificação (CASTRO et al., 2012).

Assim como as redes MLPs, as CNNs também podem ser utilizadas para representação típica de uma RNAA, sendo que a mesma apresentará as camadas de codificação e decodificação em múltiplos níveis de processamento para o processo da

extração de características. A Figura 10 apresenta a estrutura de uma rede CNN Auto-associativa.

No caso da camada de codificação, esta pode ser formada por diversas camadas de convolução e *pooling*, para que o sinal seja comprimido com suas principais características filtradas. No caso da camada decodificadora as camadas de convolução e *pooling* também podem estar presentes, mas realizando operações de forma contrária, para a reconstrução dos dados de entrada.

Figura 10 – Representação de uma CNN Auto-associativa.



Fonte: Autor.

3 Arritmias Cardíacas e Sistemas Automáticos para Classificação de Arritmias

3.1 Introdução

Os Sinais cardíacos são provenientes da contração do músculo conhecido como coração, o qual bombeia sangue para o resto do corpo humano em ritmo contínuo, gerando assim um sinal elétrico a cada batida. Quando existe alguma anormalidade nestas batidas ocorre uma arritmia (LUZ et al., 2015).

Um sistema para a classificação automática de arritmias é de grande importância para auxílio ao diagnóstico de doenças provenientes da alteração do ritmo cardíaco, pois a análise direta dos sinais cardíacos obtidos através do ECG, que tendem a ter uma longa duração, pode ser custoso para o especialista e em algumas situações, levar a um diagnóstico errado.

Para um bom entendimento da proposta desta dissertação, serão apresentados neste capítulo os conceitos fundamentais relacionados ao coração humano, sinais cardíacos, e arritmia cardíaca. Serão apresentadas também todas as fases necessárias para o desenvolvimento de um sistema automático de classificação de arritmias.

3.2 Estrutura do Coração Humano

O coração humano é um órgão muscular oco que representa a parte central do sistema circulatório e possui dimensão aproximada de 12 cm de comprimento e 9 cm de largura. A massa do coração de uma pessoa adulta varia entre 200g e 300g. O coração localiza-se na parte central da caixa torácica, um pouco inclinado para a esquerda, entre os pulmões (MAGALHÃES, 2018). A Figura 11 ilustra a localização do coração no corpo humano.

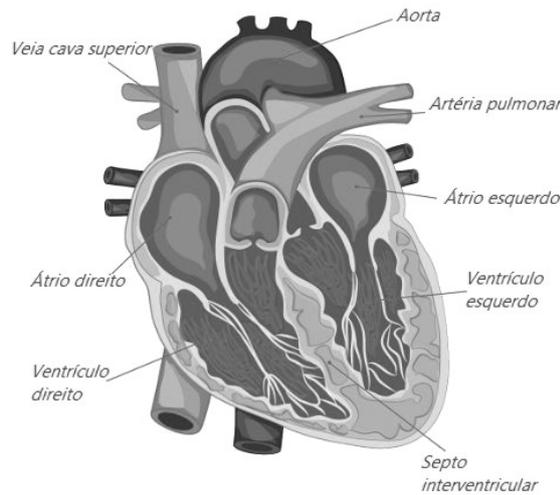
Figura 11 – Localização do Coração Humano.



Fonte: (SCIENCE PHOTO LIBRARY, 2018).

O coração divide-se em quatro cavidades: dois átrios (esquerdo e direito) e dois ventrículos (esquerdo e direito). Os átrios recebem o sangue das veias e os ventrículos enviam sangue para as artérias. A Figura 12 apresenta com maiores detalhes a estrutura do coração humano.

Figura 12 – A estrutura do coração humano.



Fonte: (SANTOS, 2019).

3.3 Sinal Cardíaco

Os sinais provenientes da batida do coração iniciam-se com a contração dos átrios, movimento conhecido como sístole. Em seguida as válvulas abrem-se e o sangue é bombeado para os ventrículos que estão relaxados, sendo este movimento conhecido como diástole. Todos esses movimentos compõem o ciclo cardíaco, gerando assim um sinal elétrico com determinado padrão (MAGALHÃES, 2018). O sinal elétrico 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).

Uma Sinal de ECG é composto por diversos componentes que podem ser visualizados na Figura 13. A onda P, a qual corresponde à despolarização atrial, tem sua primeira componente relativa à aurícula direita e a segunda relativa à aurícula esquerda. O complexo QRS, representa a despolarização ventricular, maior que a onda P, pois a massa muscular dos ventrículos é maior que a dos átrios, gerando assim sinais de despolarização ventricular mais fortes do que os da repolarização atrial. Por fim tem-se a onda T, a qual corresponde a

polarização atrial. O trecho entre cada segmento é representado por PR, da onda P até o pico R, o segmento ST, do vale S até a onda T, e o segmento QT, do vale Q até a onda T.

Figura 13 – Componentes do batimento cardíaco.



Fonte: (MY EKG ONDAS, 2018).

3.4 Eletrocardiograma

Os sinais cardíacos podem ser medidos através de um aparelho chamado Eletrocardiógrafo que reproduz o sinal elétrico medido em forma gráfica (Eletrocardiograma-ECG). O eletrocardiógrafo utiliza, para a medida dos sinais elétricos, sensores (eletrodos) no tórax, punhos e tornozelos, sendo possível também realizar a medição com os sensores apenas no tórax. A Figura 14 apresenta um exemplo de um Eletrocardiógrafo.

Figura 14 – Eletrocardiógrafo.



Fonte: (CENTER MEDICAL, 2018).

A unidade de medida dos sinais elétricos é o milivolt (mV). O total de batidas é expresso em batidas por minuto (bpm). A Tabela 2 exibe os valores típicos de cada componente do batimento cardíaco.

Tabela 2 – Medida em mV de cada componente do batimento cardíaco em uma frequência cardíaca de 60 bpm de um adulto saudável.

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)

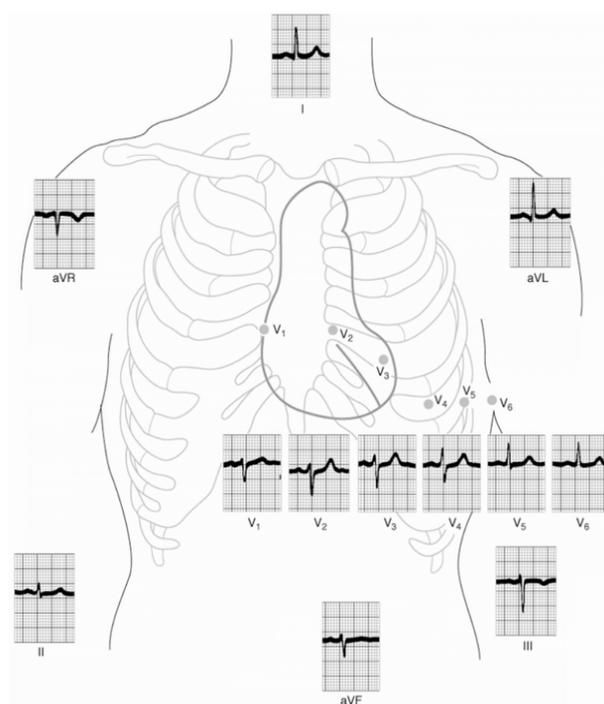
Existem três maneiras para se realizar a medição de um sinal cardíaco: dentro do paciente (*in-the-person*), no paciente (*on-the-person*) e fora do paciente (*off-the-person*). Na abordagem *in-the-person* utilizam-se equipamentos colocados dentro do corpo humano, que podem ser implantados cirurgicamente ou ingeridos por meio de pílulas. Em *on-the-person* têm-se aparelhos conectados no corpo do paciente, como é o caso dos eletrodos, exibido na Figura 15, realizando-se a leitura dos sinais elétricos na pele. Por fim tem-se a abordagem *off-the-person*, uma categoria onde existe um mínimo contato com o corpo humano 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). A maior parte dos aparelhos realiza a medição *on-the-person*.

Figura 15 – Leitura de sinais elétricos *on the person*.

Fonte: (CARDIORITMO, 2018).

Quanto ao uso de eletrodos para a abordagem *on-the-person*, existem diversas configurações para conectá-los ao corpo do paciente para realizar a medição do ritmo cardíaco. Existem cinco localizações utilizadas para o posicionamento dos eletrodos: Braço Esquerdo (LA), Braço Direito (RA), Perna Esquerda (LL), Perna Direita (RL) e a direita do Esterno (V ou V1). Também é possível encontrar o uso de 10 eletrodos para a medição, que além das 5 posições citadas anteriormente, outros cinco eletrodos são posicionados no tórax do paciente (V2 a V6). A Figura 16 ilustra o posicionamento dos eletrodos no corpo.

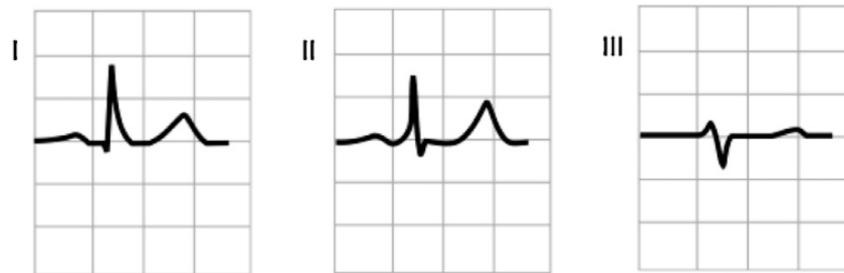
Figura 16 – Pontos de coleta de frequências cardíacas em um ECG.



Fonte: (SCHWARZ, 2009).

A partir dos pontos posicionados mede-se a diferença de potencial entre eles e assim obtém-se o ECG com a batida do coração do paciente ao longo do tempo. Cada combinação de pontos leva a um tipo de leitura, como ilustrado na Figura 17, onde I é formado pela diferença de potencial entre LA e RA, II pela diferença de potencial entre LL e RA e III pela diferença de potencial entre LL e LA.

Figura 17 – Tipos de Leituras de um ECG.



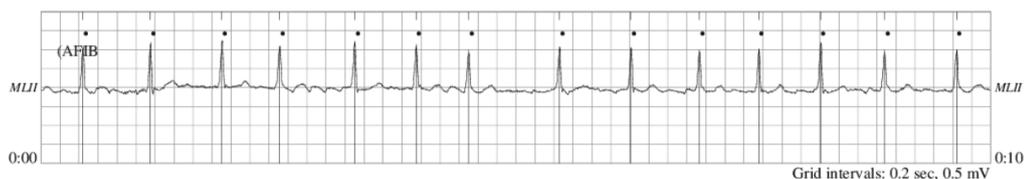
Fonte: (LUZ et al, 2015).

Para o diagnóstico de doenças cardíacas a leitura do tipo II é a mais utilizada pois ilustra os diversos segmentos que compõem um batimento cardíaco, como o complexo QRS e a Onda P, e qualquer mudança no padrão desses componentes pode levar a identificação de uma arritmia cardíaca (LUZ et al., 2015).

3.5 Arritmia Cardíaca

As Arritmias Cardíacas são alterações no ritmo cardíaco (Arritmia Rítmica) ou alterações na morfologia do batimento cardíaco (Arritmia Morfológica), sendo que as mesmas podem ser identificadas através de um ECG. A Figura 18 apresenta um exemplo de arritmia rítmica e a Figura 19 exhibe um exemplo de arritmia morfológica.

Figura 18 – Arritmia Rítmica



Fonte: (PHYSIONET, 2018)

Figura 19 – Arritmia Morfológica



Fonte: (PHYSIONET, 2018)

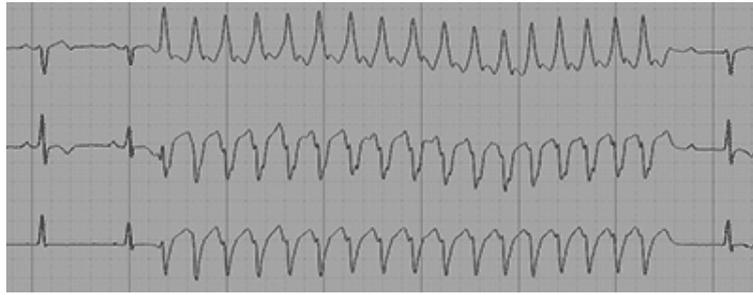
A arritmia cardíaca gera sintomas tais como tonteiras e palpitações e suas principais causas são stress e diabetes. Arritmias podem levar a um acidente vascular ou insuficiência cardíaca. Apesar dos sintomas e causas bastante visíveis, podem existir casos onde os sintomas não apareçam, assim como pode acontecer casos em que um ritmo fraco de batidas do coração não seja sinal de arritmia (NORDQVIST, 2017).

Existem duas formas básicas de se classificar as arritmias: quanto ao local de origem no coração, podendo ser Ventricular e Supraventricular e quanto a velocidade dos batimentos, podendo ser Taquicardia e Bradicardia. As arritmias ventriculares originam-se na parte inferior do coração, enquanto a supraventricular originam-se na parte superior. Quanto às arritmias baseadas na velocidade do batimento cardíaco, ou seja, no aumento ou diminuição da frequência cardíaca, tem-se a Taquicardia, caracterizada pelo batimento rápido, e a Bradicardia, caracterizada pelo batimento lento (ARRHYTHMIA ALLIANCE, 2018). A combinação entre local de origem e velocidade do batimento gera a classe de uma arritmia, e dentro dessas existem diversos subgrupos.

Podem existir combinações de velocidade de batimentos com doenças específicas, como por exemplo a Pausa Sinusal (MY EKG, 2018), a qual é classificada dentro da bradicardia.

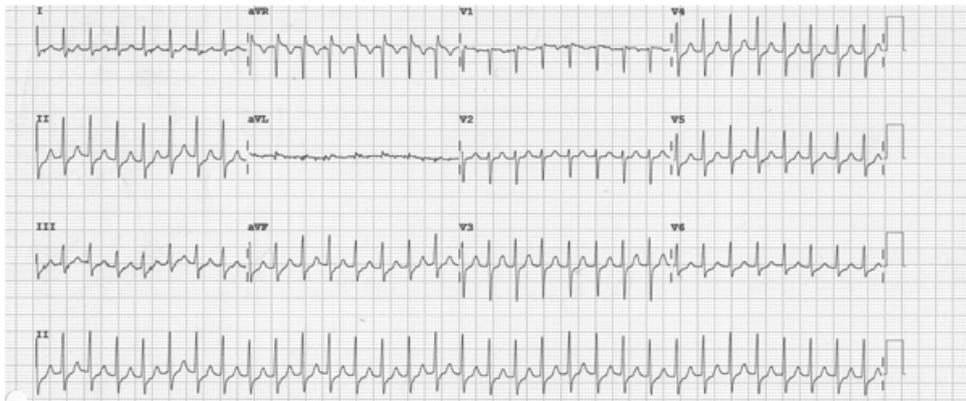
A Figura 20 exibe um ECG de um paciente com taquicardia ventricular, enquanto a Figura 21 exibe um ECG de um paciente com taquicardia supraventricular.

Figura 20 – Taquicardia Ventricular.



Fonte: (MY EKG, 2018).

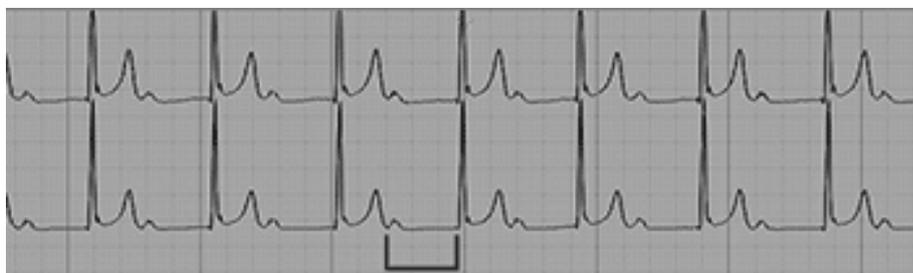
Figura 21 – Taquicardia Supraventricular.



Fonte: (MY EKG, 2018).

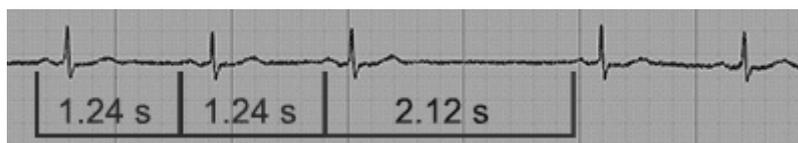
Considerando casos de bradicardias, a Figura 22 ilustra um ECG de um paciente com bradicardia atrioventricular, enquanto a Figura 23 exibe um ECG de paciente com bradicardia do Pausa Sinusal.

Figura 22 – Bradicardia atrioventricular.



Fonte: (MY EKG, 2018).

Figura 23 – Pausa Sinusal.



Fonte: (MY EKG, 2018)

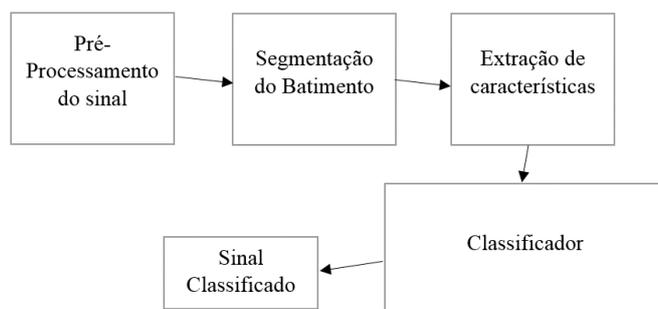
3.6 Sistemas Automáticos para classificação de Arritmias

O processo para identificação e diagnóstico de arritmias pode ser muito penoso para um ser humano visto que pode necessitar, por exemplo, de uma análise do sinal cardíaco obtido por horas ou até mesmo dias, capturados, por exemplo por um *holter* cardíaco.

Para auxílio ao diagnóstico de arritmias alguns sistemas automáticos vêm sendo propostos e apresentados na literatura. Os sistemas automáticos vêm se mostrando bastante eficientes, principalmente em casos em que a arritmia a ser diagnosticada apresenta determinada particularidade, difícil de ser observada pelo especialista. Um outro fator importante em relação aos sistemas automáticos diz respeito ao tempo reduzido para análise do sinal ECG, o que torna possível o monitoramento e diagnóstico do paciente em tempo real.

Um sistema automático para a classificação de arritmias é composto por quatro etapas: pré-processamento do sinal, segmentação, extração de características e classificação. A Figura 24 ilustra um diagrama de blocos apresentando como essas etapas estão conectadas.

Figura 24 – Diagrama de Blocos com as etapas de um sistema automático para a classificação de arritmias.



Fonte: Autor.

3.6.1 Pré-processamento do sinal

Um sinal ECG é passível a ruídos e outros tipos de interferência e diante destes problemas faz-se necessário realizar um pré-processamento do sinal obtido (LUZ et al., 2015). Existem diversas metodologias propostas para a redução ou eliminação destes ruídos sendo que uma das propostas mais utilizadas para redução de ruídos se baseia no uso de um filtro de resposta ao impulso finita (FIR) (LYNN, 1979). O Filtro FIR funciona muito bem nas frequências de bandas de ruídos da rede. Um problema é que nem sempre a frequência do ruído 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 causar uma distorção na morfologia do sinal, o que pode afetar muito na análise das arritmias morfológicas, podendo levar a diagnósticos incorretos. Para tentar resolver este problema em (FERRARA e WIDROW, 1982) é proposto o uso de filtros adaptativos, entretanto foi também demonstrado que este tipo de filtro apresenta limitações e desvantagens em relação ao FIR.

A Transformada *Wavelet* também tem sido empregada para o combate aos 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 eliminando os ruídos oriundos da obtenção deles. Uma outra grande vantagem da Transformada *Wavelet* é que esta não necessita de muito recurso computacional (SINGH e TIWARI, 2006).

É possível também utilizar um filtro passa-alta para a redução de ruídos do tipo *baseline* em ECG, que podem ser provocados pelos meios externos, como a respiração e movimentação do paciente (JEYARANI e SINGH, 2010).

Ainda dentro das aplicações de filtros, aplica-se o filtro FIR de terceira ordem para reduzir ruídos provenientes da interferência causa pela linha de energia do próprio instrumento para a coleta do ECG (JEYARANI e SINGH, 2010).

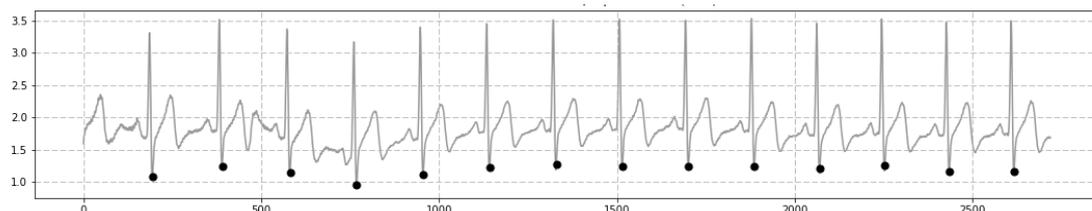
Por fim, uma terceira metodologia ainda ligada a filtros utiliza o filtro passa-baixa para reduzir ruídos eletromiográficos, que podem ser provenientes de outras contrações musculares do próprio paciente (JEYARANI e SINGH, 2010).

3.6.2 Segmentação do batimento

A segmentação do batimento consiste em isolar o batimento cardíaco das demais partes do sinal medido, podendo a segmentação ser realizada de várias formas, como a

segmentação para detecção do Complexo QRS ou segmentação para detecção do Pico R. Diversos algoritmos vêm sendo desenvolvidos para a segmentação, sendo o algoritmo de Pan-Tompkins (PAN e TOMPKINS, 1985) o mais utilizado para detecção do complexo QRS. A Figura 25 exibe a segmentação por meio da detecção do Complexo QRS.

Figura 25 – Segmentação por meio da detecção do Complexo QRS. Os pontos marcados representam a segmentação tendo como base a onda S.



Fonte: (SZNAJDER e ŁUKOWSKA, 2017).

Para a avaliação da segmentação e comparação entre os diversos métodos propostos, a *Association for the Advancement of Medical Instrumentation (AAMI)* recomenda a utilização do *MIT-BIH Arrhythmia Database*, devido esta ser a base de dados padrão para a avaliação de equipamentos médicos (LUZ et al., 2015).

Existem diversos outros métodos para a realização da segmentação, como por exemplo através de Redes Neurais Artificiais (HU et al., 1990) ou Transformada *Wavelet* (JUNG e TOMPKINS, 2003), além de outros algoritmos com o objetivo de detectar outras partes que compõem o batimento cardíaco para assim realizar sua segmentação, como a detecção da onda P e da onda T (KIM et al., 2010).

A abordagem *Bottom-Top* (YADAV e RAY, 2016) considera a divisão do ECG em séries temporais de comprimento n que divide o sinal em muitos segmentos de igual tamanho, a partir disso, os segmentos consecutivos são comparados e os pares com a menor comparação de diferença entre si nos erros são agrupados em um segmento maior, até alcançar o critério de parada estabelecido, como um número total de segmentos previamente definido.

Em (GACEK e PEDRYCZ, 2003) é implementada uma técnica onde cada segmento é capturado a partir de uma construção geométrica, a qual pode ser representada por uma função quadrática ou linear e cada segmento recebe uma compressão otimizada através de um algoritmo genético.

Na metodologia proposta em (AKHBARI et al., 2016) utiliza-se uma Cadeia de Markov Múltipla (MultiHMM) na qual cada segmento do ECG é representado por uma Cadeia de Markov (HMM) em separado de densidade ergódica contínua, onde cada cadeia de um diferente número de estado e é treinada em separadamente das demais. Na etapa de teste, duas HMMs consecutivas são comparadas através de uma distribuição log-normal e as que tiveram a maior probabilidade são tratadas como correspondentes.

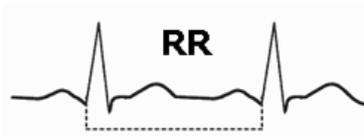
A etapa de segmentação é de extrema importância para um bom funcionamento de um sistema automático para classificação de arritmias.

3.6.3 Extração de características

A fase de extração de característica pode ser considerada a mais importante para o desenvolvimento do sistema automático de classificação de arritmias. Nesta fase obtém-se as informações mais importantes em um sinal ECG para que este seja classificado ou não como arritmia.

As características de um sinal ECG podem ser extraídas tanto com o sinal no domínio do tempo como no domínio da frequência. Uma das características mais simples que pode ser extraída do sinal ECG é a distância entre duas ondas R sucessivas chamada de Intervalo RR (LUZ et al, 2015). As variações no intervalo RR 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 26 exhibe um Intervalo RR em um sinal ECG.

Figura 26 – Intervalo RR.

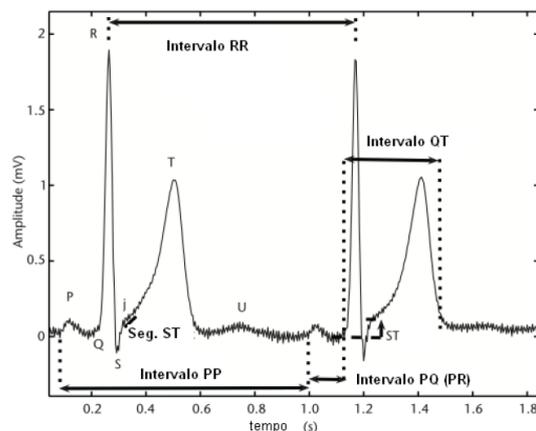


Fonte: (MY EKG, 2018).

O intervalo RR é um exemplo de característica que pode ser vista com facilidade por um especialista humano, porém devido ao longo registro de um sinal ECG este processo pode se tornar trabalhoso e difícil.

Além do intervalo RR, outras características podem ser extraídas tais como as características extraídas da segmentação do Complexo QRS, como visto em (DE CHAZAL et al., 2004). A Figura 27 apresenta outras características que podem ser extraídas além do intervalo RR e do complexo QRS.

Figura 27 – Outras características para segmentação do ECG.



Fonte: (YANG et al., 2010). Adaptada.

Uma vez que o segmento do ECG é definido (Intervalo RR, Complexo QRS, etc.) é necessário utilizar alguma técnica para a extração de características. Na literatura aparecem metodologias como a Análise Discriminante Generalizada (GDA) para a redução de características extraídas, como visto em (ASL, SETAREHDAN e MOHEBBI, 2008), onde existem quinze características e o GDA reduz para cinco. Utiliza-se também a interpolação, como visto em (DE CHAZAL et al., 2004) para extrair as características presentes nos Intervalos RR, na Morfologia do ECG e no Intervalo das batidas. A análise de agrupamento de dados, abordada em (HAM e HAN, 1996) é utilizada para a extração de características do complexo QRS.

Técnicas para redução das características extraídas podem também ser utilizadas, sendo possível utilizar técnicas de redução de espaço vetorial, como as técnicas a partir da Análise de Componentes Principais (PCA), como visto em (KIM, SHIN e LEE, 2009), e também pela Análise de Componentes Independentes (ICA), como mostrado em (SARFRAZ, KHAN e LI, 2014). Outra forma de seleção das características é utilizando-se rede neurais profundas, como é o caso das Redes Neurais Convolucionais Auto-associativas, como visto em (BAIA e CASTRO, 2018), pois estas possibilitam extrair as características mais latentes do ECG devido a presença das camadas de convolução presentes nos codificadores e decodificadores da Rede.

É possível também utilizar-se algoritmos de otimização para a extração de características, como o Algoritmo Genético (AG) e a Otimização por Enxame de Partículas (PSO) para que seja otimizada a base de dados para que apenas os atributos mais relevantes de cada amostra alimentem o sistema de classificação (LUZ et al, 2015).

3.6.4 Classificação

Após a etapa de extração de características, com os atributos mais relevantes extraídos das amostras, inicia-se a etapa de classificação das arritmias. Existem na literatura diversos algoritmos para esta tarefa, dos quais pode-se citar quatro dos mais amplamente utilizados, que são: as Redes Neurais Artificiais (RNAs), as Máquinas de Vetores de Suporte (SMVs), o Discriminante Linear (LD) (RASCHKA, 2014) e a Computação por Reservatório (RC) (GAUTHIER, 2018), como visto em (LUZ et al, 2015).

As arquiteturas de RNAs utilizadas na maior parte dos sistemas automáticos para a classificação de arritmias são as redes *Perceptron* de múltiplas camadas (MLPs) como visto em (SAVALIA e EMAMIAN, 2018) e (KELWADE e SALANKAR, 2015) e as Redes Neurais Probabilísticas (PNN) (LUZ et al, 2015). As redes PNN tem mais ampla utilização em relação as MLPs devido a sua robustez computacional e eficiência, como mostrado em (YU e CHEN, 2007). Alguns estudos têm sido realizados quanto à combinação de RNAs como classificadores, porém ainda são poucos explorados, apesar de mostrarem resultados com pouca taxa de erro, como apontado em (OSOWSKI, MARKIEWICZ e HOAI, 2008).

As SVMs têm sido uma opção bastante popular nesta abordagem, pois ela não requer um sistema complexo e possui uma implementação simples. Em contrapartida, as SVMs acabam por ter a problemática de baixo desempenho na classificação de base de dados com classes desbalanceadas, como é o caso da *MIT-BIH Arrhythmia Database*, a qual é recomendada pelo AAMI para a avaliação dos sistemas automáticos para a classificação de arritmias (LUZ et al, 2015). Para solucionar este problema, algumas abordagens têm combinado a SVM com outras técnicas, como a combinação dela com *ensembles* (HUANG et al., 2014).

O LD tem sido implementado em abordagens que utilizam a divisão da base de dados *MIT-BIH Arrhythmia Database* proposta por (DE CHAZAL et al., 2004), a qual segue os padrões do AAMI. O LD consegue contornar mais facilmente o problema de classes desbalanceadas, além de possuir um tempo menor para treinamento (LUZ et al, 2015).

A RC é uma arquitetura voltada para trabalhar com séries temporais, o que torna possível sua implementação em sistemas que operam com ECGs. Como mostrado em (ESCALONA-MORAN et al., 2015), as RCs para estes sistemas mostram-se como um processo de aprendizado similar a uma regressão logística, tendo a capacidade de lidar com o

problema de classes desbalanceadas, capacidade de trabalhar utilizando pouco poder computacional, facilitando assim seu uso para sistemas que classificam em tempo real.

Existem outras técnicas usadas para o classificador do sistema automático de arritmias, como as árvores de decisão (MAHESH et al, 2009), Cadeias de Markov (COAST et al., 1990) e kNN (*k-Nearest Neighborhood*) (MISHRA e RAGHAV, 2010).

3.6.5 Bancos de dados para desenvolvimento de sistemas automáticos e o Padrão AAMI

Considerando que existem disponíveis para desenvolvimento de sistemas automáticos diversos banco de dados compostos de sinais de batimento cardíaco, a *Association for the Advancement of Medical Instrumentation* (AAMI) criou uma padronização que deve ser seguida para avaliação destes métodos. A norma AAMI EC57 (AAMI, 2012) define o protocolo para realizar as avaliações dos métodos de tal forma a tornar os sistemas propostos reproduzíveis e comparáveis.

A AAMI também traz recomendações a respeito dos tipos de arritmias que devem ser classificadas pelos sistemas automáticos, que devem ser classificadas em 5 superclasses: Normal (N), Batimentos Ectópicos Supraventriculares (S), Batimentos Ectópicos Ventriculares (V), Batimentos de Fusão (F) e Batimentos Desconhecidos (Q).

A norma recomenda para desenvolvimento de sistemas automáticos o uso da base de dados MIT-BIH , que é a base que vem sendo mais utilizada nos trabalhos apresentados na literatura e isto se deve ao fato desta base ser a mais representativa de sinais de arritmias, possuindo sinais de 15 classes, as quais podem ser mapeadas para as superclasses recomendadas pela AAMI. A Tabela 3 apresenta as 15 classes presentes no *MIT-BIH* e o seu mapeamento para o AAMI.

Tabela 3 – Classes do MIT-BIH mapeadas para o AAMI.

Referência	Classes				
AAMI	N	S	V	F	Q
MIT-BIH	Batimento Normal	Prematura Atrial	Contração Ventricular Prematura	Fusão entre Ventricular e Normal	Batimento Ritmado
	Bloqueio do ramo esquerdo do feixe de His	Prematura Atrial Aberrante	Batimento de Escape Ventricular		Fusão entre Ritmado e Normal
	Bloqueio do ramo direito do feixe de His	Nodal (Juncional)			
	Escape atrial				
	Nodal (Juncional)				
	Batimento de Escape				

Fonte: (DE CHAZAL et al., 2004).

O MIT-BIH é uma base de dados originada de um trabalho em conjunto entre *Massachusetts Institute of Technology* (MIT) e o *Beth Israel Deaconess Medical Center*, que contém a gravação de ECGs de 47 pacientes com 30 min de duração. Os dados são digitalizados a 360 amostras por segundo com resolução de 11 bits e uma faixa de 10mv. Ao todo existem 48 gravações de ECG no banco de dados, devido ao fato de se ter duas gravações para um mesmo paciente.

Para se analisar a capacidade dos sistemas de classificação de arritmias, é proposto em (DE CHAZAL et al., 2004) uma divisão da base de dados MIT-BIH de tal forma que se tenha uma base de dados para desenvolvimento do sistema automático (com amostras de determinados pacientes) e outra base de dados para avaliação/teste do sistema (com amostras de pacientes diferentes dos usados para base de treino). Esta proposta de divisão é conhecida na literatura como esquema inter-paciente e vem sendo utilizada por muitos autores. A divisão proposta facilita o estudo comparativo entre os diversos sistemas apresentados na literatura e permite, por ser um esquema inter-paciente, que os sistemas sejam desenvolvidos e avaliados de uma maneira mais realística, não permitindo que os mesmos pacientes sejam utilizados tanto para desenvolvimento como para avaliação (teste).

No esquema inter-paciente proposto por (DE CHAZAL et al., 2004), foram utilizadas 44 amostras de sinal (44 pacientes) que foram divididas igualmente em dois conjuntos: DS1, o qual deve ser usado para o treinamento do sistema classificador automático, e DS2, o qual deve ser utilizado para a avaliação/teste do sistema.

Inicialmente, as gravações do MIT-BIH foram divididas em dois conjuntos (DS1 e DS2), onde existe em uma delas as gravações identificados com números pares e em outra com números ímpares. Para que fosse alcançado um equilíbrio entre o número total de classes entre os conjuntos, realizou-se uma troca de gravações entre cada conjunto. Existem duas gravações, a 201 e 202, que são do mesmo paciente, mas estão em diferentes conjuntos (LUZ et al., 2015). A Tabela 4 apresenta o número de amostras por classe em DS1 e DS2.

Tabela 4 – Conjuntos DS1 e DS2 propostos por (DE CHAZAL et al., 2004).

Conjunto	N	S	V	F	Q	Total
DS1	45866	944	3788	415	8	51021
DS2	44259	1837	3221	388	7	49712
DS1+DS2	90125	2781	7009	803	15	100733

Fonte: (LUZ et al., 2015).

3.6.5.1 Medidas para Evolução do sistema automático

O AAMI recomenda as seguintes métricas para a avaliação dos sistemas automáticos para a classificação de arritmias: Acurácia (Acc), Sensibilidade (Sen), Precisão (+P) e Taxa de Falso Positivo (FPR). As métricas de Acurácia, Sensibilidade e Precisão são recomendadas para base de dados desbalanceadas, como é o caso do MIT-BIH, onde existem muitas amostras para classe Normal (LUZ et al., 2015).

A Acurácia mede o viés estatístico, o quanto determinado número de amostras foram corretamente classificadas, Positivas ou Negativas, e é definida como:

$$Acc = \frac{tp + tn}{tp + tn + fp + fn} \quad (1)$$

Onde tp representa os Verdadeiros Positivos, tn os Verdadeiros Negativos, fp os Falsos Positivos e fn os Falsos Negativos.

A sensibilidade mede a taxa de elementos Verdadeiros Positivos que foram classificados, e é definida como:

$$Sen = \frac{tp}{tp + fn} \quad (2)$$

A precisão mede a taxa dentre os elementos que foram classificados, quais são realmente Verdadeiros Positivos, e é definida como:

$$+P = \frac{tp}{tp + fp} \quad (3)$$

Nos sistemas de classificação automática, a Sensibilidade e Precisão são muito 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 dos sistemas automáticos. A Tabela 5 apresenta alguns resultados de sistemas já apresentados na literatura usando o esquema inter-paciente proposto por (DE CHAZAL et al., 2004) e a Tabela 6 apresenta alguns resultados de sistemas que não utilizaram o esquema inter-paciente, sendo que para estes casos (intra-paciente) tem-se que a base de dados usada para desenvolvimento e teste do sistema possuem amostras geradas a partir dos mesmos pacientes. Para o caso intra-paciente, obtém-se melhores resultados de acurácia, pois segundo diversos autores vistos em (LUZ et al., 2015), existe uma melhor taxa de acerto para as classes S e V, porém esse cenário intra-paciente é menos realista que o inter-paciente.

Tabela 5 – Resultados apresentados na literatura para inter-paciente.

Referência	Conjunto de características	Classificador	Resultados
(DE CHAZAL et al. 2004)	Intervalos de ECG, Morfológico	<i>Weighted LD</i>	Acc = 83% Sen(N) = 87%, +P(N) = 99%, Sen(S) = 76%, +P(S) = 38%, Sen(V) = 77%, +P(V) = 82%
(SORIA e MARTINEZ, 2009)	Intervalos RR, VCG, Morfológico, +FFS	<i>Weighted LD</i>	Acc = 90% Sen(N) = 92%, +P(N) = 85%, Sen(S) = 88%, +P(S) = 93%, Sen(V) = 90%, +P(V) = 92%
(YE et al., 2012)	Morfológico, <i>Wavelet</i> , Intervalo RR, ICA, PCA	<i>SVM</i>	Acc = 86,4% Sen(N) = 88%, +P(N) = 97%, Sen(S) = 60%, +P(S) = 53%, Sen(V) = 81%, +P(V) = 63%
(MAR et al., 2011)	Características Temporais, Morfológico, Características estatísticas, +SFFS	<i>Weighted LD, MLP</i>	Acc = 89% Sen(N) = 89%, +P(N) = 99%, Sen(S) = 83%, +P(S) = 33%, Sen(V) = 86%, +P(V) = 75%
(ZHANG et al., 2014)	Intervalo RR, Características Morfológicas, Intervalos de ECG, Segmentos	SVM Combinado	Acc = 86% Sen(N) = 89%, +P(N) = 99%, Sen(S) = 79%, +P(S) = 35%, Sen(V) = 85%, +P(V) = 92%
(LIN e YANG, 2014)	Intervalo RR Normalizado	<i>Weighted LD</i>	Acc = 93% Sen(N) = 91%, +P(N) = 99%, Sen(S) = 81%, +P(S) = 31%, Sen(V) = 86%, +P(V) = 73%
(GUO et al., 2018)	Complexo QRS	CNN	Sen(S) = 62,7%, +P(S) = 61,2%, Sen(V) = 91,2%, +P(V) = 88,30%

Fonte: (LUZ et al., 2015).

Tabela 6 – Resultados apresentados na literatura para intra-paciente.

Referência	Conjunto de características	Classificador	Resultados
(CHEN et al. 2004)	Intervalo RR	Conjunto de Regras	Acc = 95%
(LAGERHOLM, 2009)	HBF, SOM	Agrupamento	Acc = 98%
(DOKUR e ÖLMEZ, 2012)	Fourier, <i>Wavelet</i> , +FSDP	MLP, RCE, RNA Híbrida	Acc = 96%
(TSIPOURAS et al., 2011)	Intervalo RR	Automata determinística	Acc = 96%
(MEHMET, 2004)	HOSC, <i>Wavelet</i>	Min Dist, kNN, Bayes	Acc = 98%
(UBEYLI, 2007)	DWT	SVM, ECOC	Acc = 99%
(KIM et al., 2009)	Intervalo RR, PCA	ELM	Acc = 98%

Fonte: (LUZ et al., 2015).

3.7 Estado da arte em sistemas automáticos para Detecção de Arritmias

Para auxílio à detecção de anomalias em batimentos cardíacos e apoio à decisão médica, alguns sistemas automáticos têm sido desenvolvidos e apresentados na literatura utilizando sinais ECG.

Em (KUMAR, 2018) é apresentada uma Rede Neural ativada por uma *spline* (REAMAT, 2018) modificada para classificar os batimentos cardíaco irregulares. O autor treina sua rede utilizando o algoritmo *Backpropagation* (SATHYANARAYANA, 2014) e obtém uma acurácia de 88,23% com sua MLP para a base de dados *MIT-BIH arrhythmia*, e divide os sinais em quatro classes: Normal, Contração Ventricular Prematura (PVC), Fibrilação Ventricular (VF) e Bloqueio Cardíaco (BII).

Na pesquisa apresentada em (SATIJA et al, 2017) é utilizada uma abordagem bem diferente do que é visto frequentemente na literatura, nela os autores ao invés de analisarem os sinais a partir dos batimentos, analisam o ruído presente nos sinais de ECG para assim classificar anomalias através de um sistema não supervisionado. É obtido neste trabalho uma acurácia de 98,93% para a *MIT-BIH arrhythmia* como a base de dados utilizada, classificando o sinal nas seguintes categorias de ruído: ECG Livre de ruído, ECG com *baseline wander* (BW), ECG com Artefato Muscular (MA), ECG com sinal PLI (PLI), ECG+BW+PLI, e ECG+BW+MA.

O trabalho visto em (BÜLBÜL et al, 2017) apresenta um comparativo entre a classificação de ECGs usando uma MLP e uma SVM, realizando uma análise com diversas métricas. No estudo, os autores afirmam que a MLP possui um melhor desempenho do que a

SVM, o qual utiliza a *MIT-BIH arrhythmia* como base de dados e classifica os sinais em normal e anormal.

O sistema implementado em (NAIK e REDDY, 2016) parte da premissa de classificar sinais de ECG em duas classes, normal e anormal, a partir da base de dados *MIT-BIH arrhythmia*, analisando as arritmias do tipo rítmica, as quais se caracterizam em grande parte por alterações no Intervalo RR. Nele são utilizados duas metodologias para a classificação, uma com um algoritmo de *Neuro-Fuzzy* adaptativo, o qual obteve uma acurácia de 81,25%, e usando decisão multimodal, obtendo uma acurácia de 87,5%.

Em (CELIN e VASANTH, 2018) é apresentado um classificador que utiliza uma rede *Naive Bayes* para classificar os sinais da base de dados *MIT-BIH arrhythmia* nas classes normal e anormal. Os autores obtêm neste trabalho uma acurácia de 99,7%.

No trabalho apresentado em (VENKATESAN, KARTHIGAIKUMAR e VARATHARAJAN, 2018) é utilizado o algoritmo do k vizinho mais próximo (kNN) para a classificação dos sinais da base de dados *MIT-BIH arrhythmia* para duas classes: normal e anormal. Obteve-se uma acurácia de 97,5%.

No campo do Aprendizado Profundo, tem-se o trabalho apresentado em (WU et al., 2016) onde utiliza-se uma Rede de Crença Profunda (DBN) para a classificação de sinais de ECGs da base de dados *MIT-BIH arrhythmia*. Neste estudo são classificados cinco tipos de arritmia e obteve-se uma acurácia de 99,5%.

Redes Neurais Convolucionais são abordadas em (KACHUEE et al., 2018), onde os autores utilizam o padrão AAMI EC57 (AAMI EC57, 2012) para a avaliação do seu sistema, classificando as cinco classes sugeridas por este padrão, a partir da base de dados *MIT-BIH arrhythmia*. O sistema obteve acurácia de 95,9%.

Uma outra de aplicação de aprendizado profundo pode ser visto em (MAJUMDAR e WARD, 2017) a qual é chamada de Aprendizado por dicionário profundo robusto (RDDDL). Este sistema, segundo o trabalho, é capaz de lidar com sinas corrompidos e com alto grau de ruídos, estes presentes na base de dados *MIT-BIH arrhythmia*, classificando-os em cinco classes vistas em (DE CHAZAL et al. 2004). Os autores apontam uma acurácia de 90,2% deste sistema quando alimentado com sinais brutos.

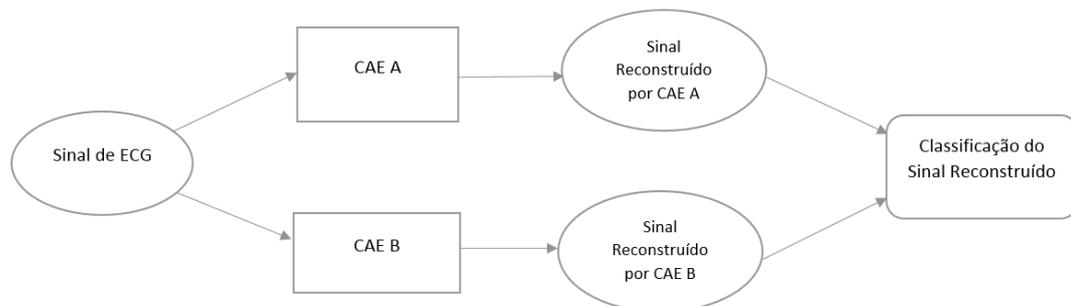
4 Sistemas Automáticos para detecção de Arritmias baseado em Redes Neurais Convolucionais Auto-associativas

4.1 Introdução

Considerando as características auto-associadoras das Redes Neurais Convolucionais Auto-associativas, este capítulo tem como objetivo apresentar os sistemas propostos desenvolvidos para classificação automática de arritmias, sendo que será apresentado o sistema desenvolvido para classificação de arritmias rítmicas (Classificador Rítmico) e o sistema para classificação de arritmias morfológicas (Classificador Morfológico). Ambos os sistemas foram desenvolvidos seguindo o protocolo AAMI e o esquema inter-pacientes.

O sistema Classificador Rítmico é composto por duas redes CNN auto-associativas (CAE A e CAE B), cada uma treinada para um tipo de classe, no caso Normal e com Arritmia Rítmica, e arranjadas em uma estrutura paralela competitiva. Como sinal de entrada/saída de cada CNN auto-associativa foi utilizado o sinal ECG puro, sem passar por um processo de extração de características. A Figura 28 apresenta a estrutura do sistema classificador rítmico proposto.

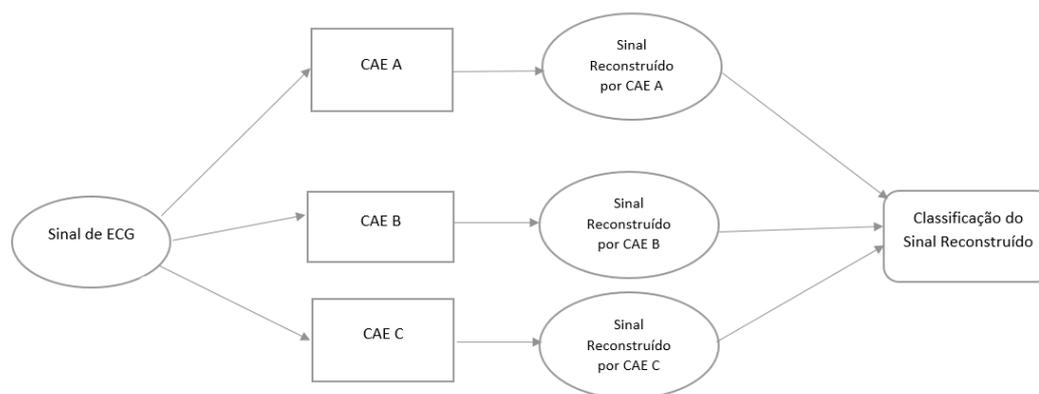
Figura 28 – Estrutura do sistema de Classificação de Arritmias Rítmicas.



Fonte: Autor.

O sistema Classificador Morfológico é composto por três redes CNN auto-associativas (CAE A, CAE B, CAE C), cada uma treinada para um tipo de classe, no caso Batimentos Normais (N), Batimentos Ectópicos Supraventriculares (S) e Batimentos Ectópicos Ventriculares (V), arranjadas em uma estrutura paralela competitiva. Como sinal de entrada/saída de cada CNN auto-associativa foi utilizado o complexo QRS de cada batimento cardíaco. A Figura 29 apresenta a estrutura do sistema proposto.

Figura 29 – Estrutura do sistema de Classificação de Arritmias Morfológicas.



Fonte: Autor.

Para cada uma das estruturas propostas nas Figuras 28 e 29, cada CAE, de acordo com a classe em questão, foi treinada para reconstruir na sua saída o sinal de entrada. Após treinamento de cada CAE, os mesmos foram arranjados na estrutura paralela competitiva proposta e o sistema classificador foi avaliado utilizando-se os dados de teste. Considerando a estrutura competitiva final, já com todos os CAEs treinados, a cada padrão de entrada apresentado para classificação, cada CAE tenta reconstruir simultaneamente o sinal na sua saída, sendo que um dos CAEs apresentará um menor erro médio quadrático entre entrada e saída reconstruída (por ter sido treinado com padrões próximos ao padrão que está sendo apresentado na entrada da estrutura), sendo então este CAE, com menor erro médio quadrático, considerado o CAE vencedor e o sinal de entrada classificado de acordo com a classe deste CAE.

Para cada CAE, para os dois sistemas classificadores, o treinamento foi realizado através da linguagem de programação *Python 3.5.3* (PYTHON, 2018) utilizando o módulo *Keras*, que permite trabalhar com os sinais em formato de uma dimensão através da função *conv1d* (KERAS, 2018). Cada janela de convolução possui tamanho 20 e aplica *padding* do tipo *same* (KERAS, 2018). Essa configuração se repete também para o *decoder* do CAE.

Devido à grande quantidade de amostras nos dados de entrada e a complexidade das operações na camada de *encoder* e *decoder*, as redes foram treinadas com o auxílio de uma GPU GTX 765m com suporte à tecnologia CUDA (NVIDIA, 2018), sendo que o módulo *Keras* possui como *backend* outro módulo chamado *TensorFlow* (TENSORFLOW, 2018) que permite esse processo.

4.2 Redes Convolucionais Auto-associativas Paralelas para classificação de Arritmias Rítmicas

Para construção da estrutura classificadora rítmica apresentada na Figura 28, inicialmente, cada CAE foi treinado para reconstrução do sinal ECG apresentado na sua entrada, sendo que o CAE A foi treinado apenas com sinais ECG de pacientes com batimentos cardíacos normais e o CAE B for treinado com sinais ECG de pacientes com arritmia.

Cada CAE, durante o processo de aprendizado, aprendeu as características dos sinais utilizados para treinamento, sendo que após treinamento, quando se apresenta para cada CAE novos sinais/padrões não utilizados no treino, mas que fazem parte da mesma distribuição dos dados usados para treinamento, cada CAE consegue reconstruir o sinal, com um erro médio quadrático entre a entrada/saída com valor pequeno.

Os sinais de entrada ECG que alimentam cada CAE foram apresentados na forma bruta, sem necessidade de pré-processamento, como filtragem ou detecção de complexo QRS (ISIN e OZDALILI, 2017).

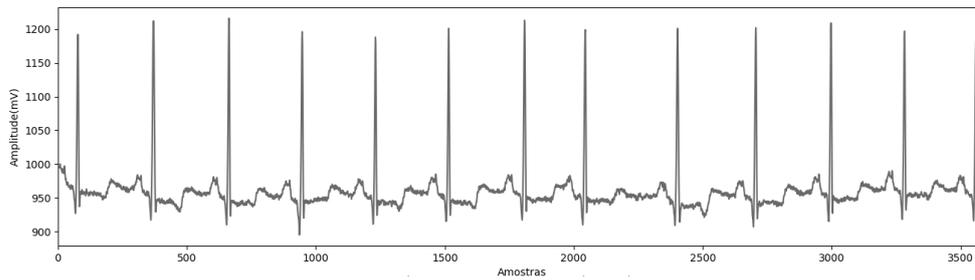
4.2.1 Base de dados para treino e teste

Os sinais ECG utilizados para desenvolvimento do sistema foi obtido do banco de dados *MIT-BIH Arrhythmia Database* (PHYSIONET, 2018). Esta base é a base de dados mais representativa de sinais de arritmia disponível para desenvolvimento de métodos de classificação automática e por isso vem sendo largamente utilizada nas pesquisas já publicadas na literatura.

Dos 48 sinais ECG, optou-se por excluir dois deles para a implementação do sistema, para uma abordagem inter-paciente. Os 46 sinais selecionados foram divididos em duas classes: ritmo cardíaco normal e ritmo cardíaco com arritmia, totalizando 23 amostras para cada classe.

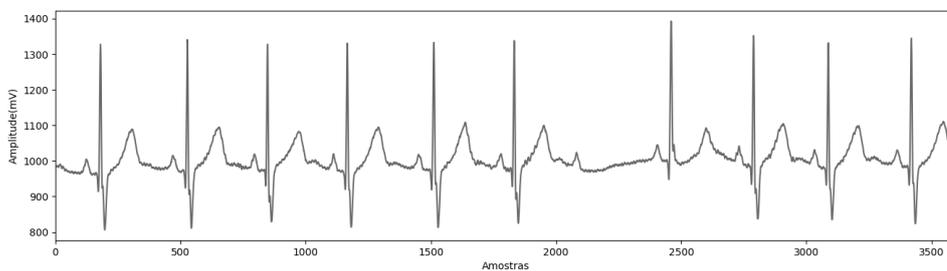
Para cada sinal de um determinado paciente foram selecionados os primeiros 10 segundos dentre os 30 minutos medidos, o que gerou 3600 amostras para cada padrão que foi utilizado como entrada para treinamento e teste do sistema. A Figura 30 apresenta um exemplo de sinal ECG para um paciente com ritmo cardíaco normal, enquanto a Figura 31 apresenta um exemplo de sinal ECG para um paciente com arritmia.

Figura 30 – ECG de um paciente com ritmo cardíaco normal.



Fonte: Autor.

Figura 31 – ECG de um paciente com ritmo cardíaco com arritmia.



Fonte: Autor.

A base de dados foi dividida em base de dados para treino e teste do sistema, sendo utilizada 14 amostras para treino e 9 amostras para teste, de cada classe, totalizando 28 amostras de treino e 18 amostras para teste do sistema. Todos os dados foram normalizados na escala entre 0 e 1, e o erro médio quadrático foi utilizado pra avaliar o desempenho da rede durante o treino.

4.2.2 Treinamento e testes das CNNs

Duas CNNs foram treinadas para reconstrução do sinal ECG: CAE A para o caso Normal e CAE 2 para o caso de Arritmia. Cada rede CAE treinada apresenta 3600 entradas e 3600 saídas relacionadas as 3600 amostras do sinal ECG de cada padrão. A rede CAE A foi treinada apenas com os padrões pertencentes a classe Normal e a rede CAE B foi treinada com padrões pertencentes a classe Arritmia. Ambos os CAEs possuem a mesma estrutura: um *encoder* composto por três camadas de convolução e três camadas de *pooling*, uma intercalando a outra, e um *decoder* com quatro camadas de convolução e três camadas de *upsampling*.

As camadas de *Maxpooling*, as quais estão presentes no *encoder*, e *Upsampling*, presente no *decoder*, também utilizam de sua versão para dados de séries temporais, *MaxPooling1D* e *UpSampling1D* (KERAS, 2018) respectivamente, onde o *MaxPooling1D*

tem *pool size* de tamanho 2, o qual divide pela metade o tamanho dos dados de entrada para cada camada de *pooling* pela qual eles são processados, comprimindo o total de amostras de cada sinal de 3600 para 450, mantendo o valor máximo encontrado em cada janela de sinal filtrado. O *UpSampling1D* restaura os valores máximos comprimidos, utilizando-se também *pool size* de tamanho 2, e com o auxílio das camadas de convolução, reconstrói o sinal original. A Tabela 7 exhibe os parâmetros e resultados de treinamento para as duas CAEs treinadas.

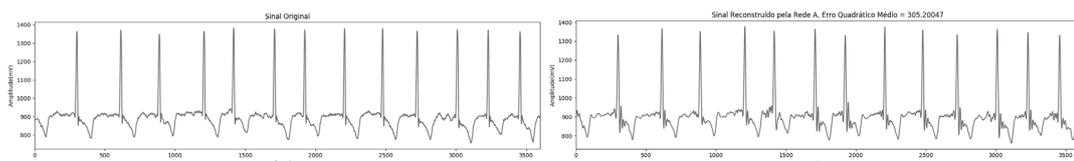
Tabela 7 – Parâmetros de Treinamento da Rede (Classificador Rítmico)

Rede	Épocas	Erro Médio Quadrático
CAE A (Normal)	7550	$2,916283 \times 10^{-4}$
CAE B (Arritmia)	7550	$2,143963 \times 10^{-4}$

Fonte: Autor.

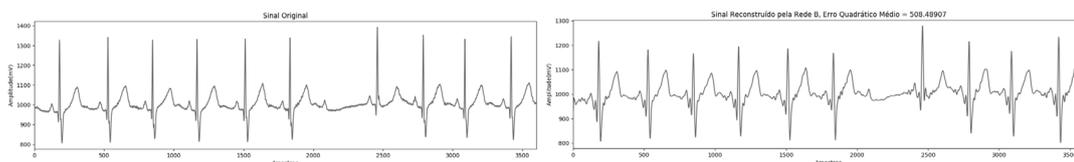
Quanto a reconstrução do sinal, a Figura 32 apresenta um exemplo de reconstrução do sinal fornecido pela CAE A para o caso do paciente com ritmo cardíaco normal, enquanto a Figura 33 apresenta um exemplo de reconstrução do sinal fornecido pela CAE B para o caso do paciente com arritmia.

Figura 32 – ECG original e reconstruído de um paciente com ritmo cardíaco normal.



Fonte: Autor.

Figura 33 – ECG original e reconstruído de um paciente com arritmia.



Fonte: Autor.

A plataforma usada para o treinamento conta com um processador i5-4200m e 8GBs de RAM. Cada rede foi treinada com 7500 épocas, utilizando-se como função de treinamento o *adamax*, que possui uma taxa de treinamento adaptável, a qual se atualiza de forma inversamente proporcional ao seu gradiente (RUDER, 2016).

4.2.3 Resultados do sistema de classificação

Após o treinamento das 2 redes CNN auto-associativas, as mesmas foram organizadas na estrutura competitiva apresentada na Figura 28 e então o sistema Classificador Rítmico foi testado utilizando a base de teste (18 amostras) sendo que o mesmo obteve uma acurácia de 88,9% e sensibilidade de 88,9%. As 2 amostras classificadas de forma incorreta foram referentes a um paciente pertencente a classe normal e outro pertencente a classe com arritmia. A Figura 34 exibe a matriz de confusão do sistema, onde na última coluna é representada a Sensibilidade de cada classe e na última linha o +P de cada classe

Figura 34 – Matriz de Confusão gerada para dados de teste (Classificador Rítmico).

Matriz de Confusão

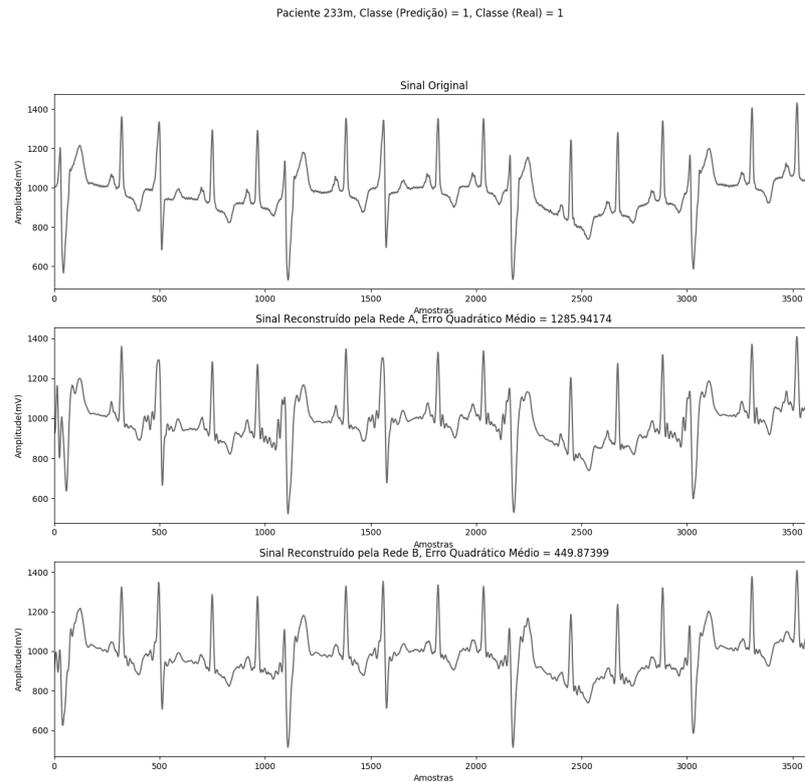
Classe Predita	Normal	8 44.4%	1 5.6%	88.9% 11.1%
	Arritmia	1 5.6%	8 44.4%	88.9% 11.1%
		88.9% 11.1%	88.9% 11.1%	88.9% 11.1%
		Normal	Arritmia	
		Classe Desejada		

Fonte: Autor.

A partir dos resultados apresentados, avalia-se que o sistema teve um bom desempenho ao classificar as duas classes, pois obteve uma alta sensibilidade e acurácia, e apenas duas amostras foram classificadas incorretamente. Por classe, obteve-se 88,9% de sensibilidade e precisão para cada uma delas.

As Figura 35 exibe um sinal classificado corretamente segundo o sistema proposto, onde o valor “0” representa a classe normal e “1” a classe com arritmia.

Figura 35 – Exemplo de Sinal classificado pelo Classificador Rítmico.



Fonte: Autor.

4.2.4 Comparação com sistemas apresentados na literatura

Para fins de avaliação da qualidade do Classificador Rítmico proposto neste trabalho, a Tabela 8 exibe alguns resultados presentes na literatura para a classificação de arritmias rítmicas. Uma comparação direta deve ser realizada com cuidado visto que os sistemas foram avaliados com bases de teste diferentes.

Tabela 8 – Resultados da Literatura para a classificação de arritmias rítmicas.

Referência	Método	Acurácia	Sensibilidade
(NAIK e REDDY, 2016)	<i>Neuro-Fuzzy</i>	81,25%	35,71%
	Decisão Multimodal	87,5%	78,57%
(CELIN e VASANTH, 2018)	SVM	87,5%	75%
	RNA	94%	94%

Fonte: Autor.

Em (NAIK e REDDY, 2016) são apresentados os resultados dos dois métodos, presentes na Tabela 7, onde se utiliza o *MIT-BIH* como base de dados. Como dados de entrada dos sistemas, os autores utilizaram 33 características que foram extraídas dos primeiros 10 segundos de cada gravação da base de dados. No trabalho, os autores não especificam quais são os conjuntos de treino e teste utilizados e se seguem o paradigma inter-paciente ou intra-paciente. Os autores conseguem bons resultados de acurácia, porém com baixa sensibilidade, o que tem um peso maior no resultado do sistema.

Em (CELIN e VASANTH, 2018), diversas técnicas são descritas para a classificação de ECGs, com destaque para o uso de uma RNA e um SVM (tabela 7). Os autores utilizam vários trechos do sinal ECG, com duração de 30 segundos para cada amostra e identificam as mudanças no ritmo cardíaco a partir da detecção de picos do Complexo QRS e das características extraídas baseadas no pico detectado. O sistema usa 152 amostras de treino e 32 para teste. Quanto aos resultados, os autores obtêm um bom balanceamento entre acurácia e sensibilidade, chegando a 94% em ambos para o caso do uso da RNA. O trabalho utiliza o paradigma intra-paciente, pois usa faixas do ECG do mesmo paciente para treino e teste, e como já anteriormente explicado este pode ser um cenário menos realista do que o cenário inter-paciente.

4.3 Redes Convolucionais Auto-associativas Paralelas para classificação de Arritmias Morfológicas

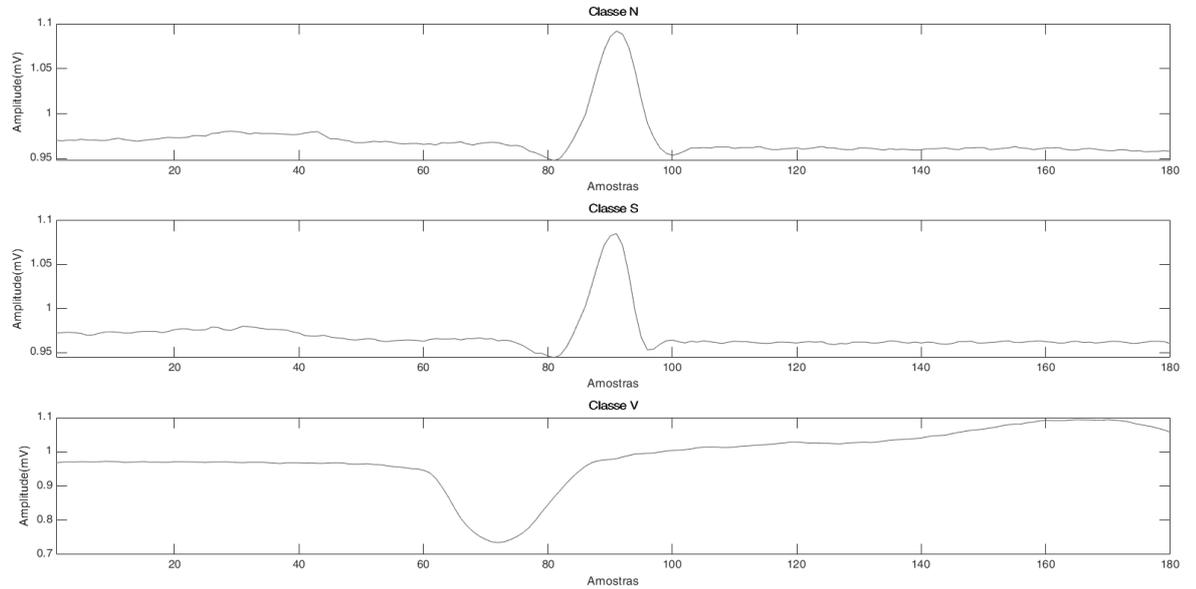
Para construção da estrutura classificadora de arritmia morfológica apresentada na figura 29, inicialmente cada CAE foi treinado para reconstrução do sinal (complexo QRS) apresentado na sua entrada, sendo que o CAE A foi treinado apenas com sinais de pacientes para a Classe N, o CAE B for treinado com sinais de pacientes com a Classe S e o CAE C para os pacientes com a Classe V.

Cada CAE, durante o processo de aprendizado, aprendeu as características dos sinais utilizados para treinamento, sendo que após treinamento, quando se apresenta para cada CAE novos sinais/padrões não utilizados no treino, mas que fazem parte da mesma distribuição dos dados usados para treinamento, cada CAE consegue reconstruir o sinal, com um erro médio quadrático entre a entrada/saída com valor pequeno.

A extração dos complexos QRS utilizados como entrada para as CAEs foi realizada através do algoritmo de Pan-Tomkins (PAN e TOMPKINS, 1985) através das funções desenvolvidas em *Matlab* presentes em (SZNAJDER e ŁUKOWSKA, 2017), a qual também

rotula as classes de cada complexo QRS. A Figura 36 apresenta exemplos de Complexos QRS para cada classe.

Figura 36 – Complexo QRS para as Classes N, S e V.



Fonte: Autor.

4.3.1 Base de dados para treino e teste

Os sinais ECG utilizados para desenvolvimento do sistema foi obtido do banco de dados *MIT-BIH Arrhythmia Database* (PHYSIONET, 2018). Dos 48 sinais ECG, optou-se por excluir quatro deles para a implementação do sistema, para uma abordagem inter-paciente, seguindo o protocolo proposto em (DE CHAZAL et al. 2004), porém, ao invés de utilizar as cinco classes morfológicas, o Classificador aqui apresentado utiliza três classes: Batimentos Normais (N), Batimentos Ectópicos Supraventriculares (S) e Batimentos Ectópicos Ventriculares (V).

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 9 exhibe o total por classes para o treino e Tabela 10 para o teste.

Tabela 9 – Total de amostras por classe para DS1 (Classificador Morfológico)

Classe	Amostras
N	45824
S	976
V	3788

Fonte: Autor

Tabela 10 – Total de amostras por classe para o DS2 (Classificador Morfológico)

Classe	Amostras
N	44033
S	2050
V	3220

Fonte: Autor

4.3.2 Treinamento e testes das CNNs

Três CNNs foram treinadas para reconstrução do sinal (complexo QRS): CAE A para classe N, CAE B para classe para classe S e CAE C para classe V. Cada rede CAE treinada apresenta 180 entradas e 180 saídas, o que corresponde ao tamanho em número de amostras de cada complexo QRS extraído. Para treinamento foram utilizadas as amostras do conjunto DS1. Todas as CAEs possuem a mesma estrutura: um *encoder* composto por três camadas de convolução e três camadas de *pooling*, uma intercalando a outra, e um *decoder* com quatro camadas de convolução e três camadas de *upsampling*.

As camadas de *Maxpooling*, as quais estão presentes no *encoder*, e *Upsampling*, presente no *decoder*, também utilizam de sua versão para dados de séries temporais, *MaxPooling1D* e *UpSampling1D* (KERAS, 2018) respectivamente, onde o *MaxPooling1D* tem *pool size* de tamanho dois nas duas primeiras camadas e três para a última. O *UpSampling1D* restaura os valores máximos comprimidos, utilizando-se também *pool size* de tamanho três para a primeira camada e dois para as duas últimas camadas, e com o auxílio das camadas de convolução, reconstrói o sinal original. A Tabela 11 exhibe os parâmetros e resultados de treinamento em relação ao erro médio quadrático obtido.

Tabela 11 – Parâmetros de Treinamento da Rede (Classificador Morfológico)

Rede	Épocas	Erro Médio Quadrático
CAE A (N)	300	$1,24 \times 10^{-4}$
CAE B (S)	7900	$1,21 \times 10^{-4}$
CAE C (V)	450	$1,44 \times 10^{-4}$

Fonte: Autor.

Esta implementação foi executada na ferramenta *Google Colab* (COLAB, 2019) devido ao seu alto custo computacional. A ferramenta conta com uma GPU Tesla K80 para uso em scripts construídos em *Python*.

4.3.3 Resultados do sistema de classificação

Após o treinamento das 3 redes CNN auto-associativas, as mesmas foram organizadas na estrutura competitiva apresentada na Figura 29 e então o sistema Classificador Morfológico foi testado utilizando a base de teste DS2 sendo que o mesmo obteve uma acurácia de 81,73% e sensibilidade de 78,42%. A Tabela 12 apresenta os resultados de sensibilidade e precisão por classe obtidos.

Tabela 12 – Resultados do Classificador Morfológico por Classe.

Classe	Sen	+P
N	82,01%	97,18%
S	64,04%	14,98%
V	89,22%	84,89%

Fonte: Autor.

A Figura 37 exibe a matriz de confusão do Classificador Morfológico, onde na última coluna é representada a Sensibilidade de cada classe e na última linha o +P de cada classe.

Figura 37 – Matriz de Confusão gerada para dados de teste DS2 (Classificador Morfológico).

Matriz de Confusão

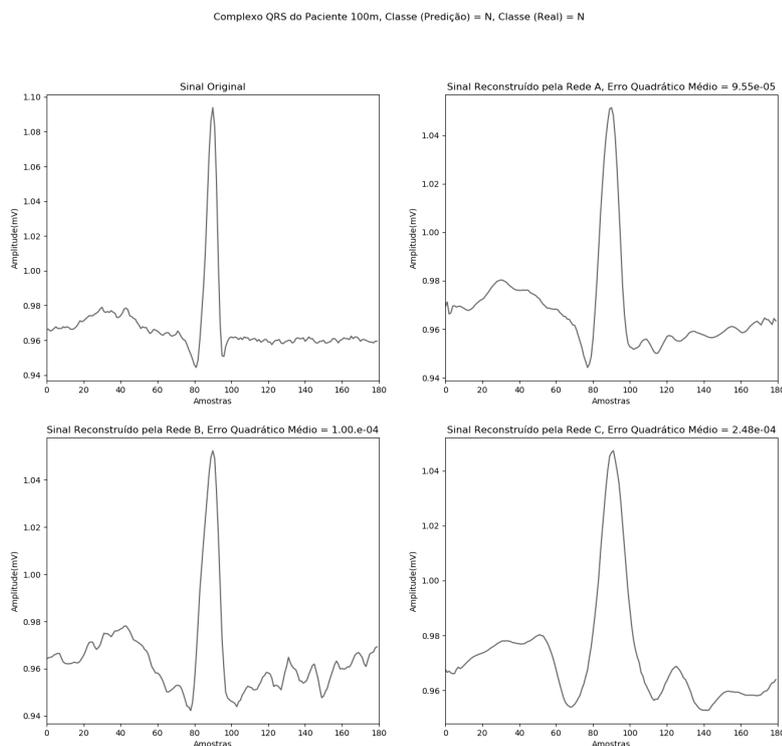
Classe Predita	N	36113 73.2%	7418 15.0%	502 1.0%	82.0%
	S	728 1.5%	1313 2.7%	9 0.0%	64.0%
	V	318 0.6%	29 0.1%	2873 5.8%	89.2%
		97.2%	15.0%	84.9%	81.7%
		2.8%	85.0%	15.1%	18.3%
		↖	↔	↘	
		Classe Desejada			

Fonte: Autor.

Os resultados apresentados na Tabela 11 demonstram que o sistema apresentou valores de sensibilidade e precisão não muito bons para o caso da classe S. Isso ocorre devido a semelhança entre o complexo QRS das Classes N e S, o que acaba confundindo o sistema, que então para certos casos classifica de forma incorreta N como S ou S como N.

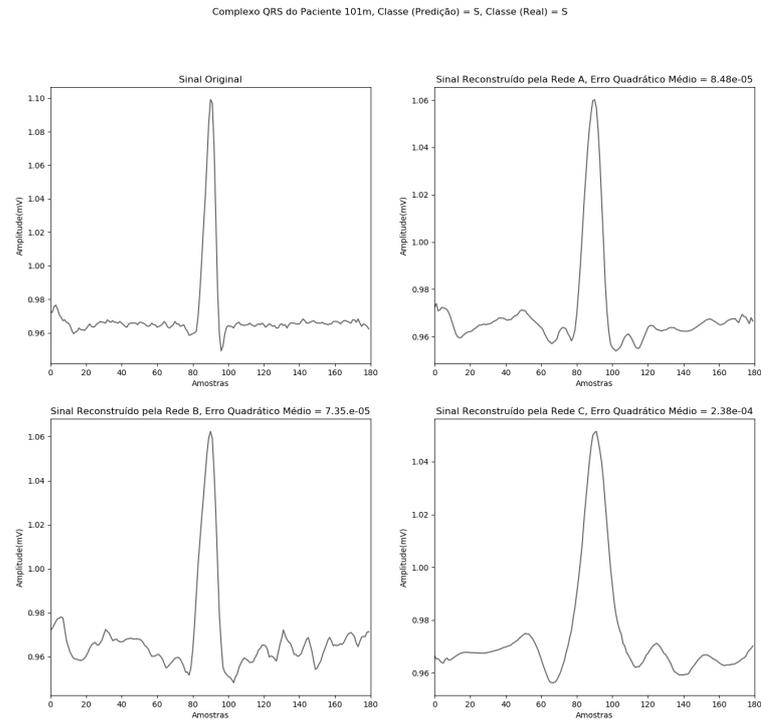
As Figuras 38, 39 e 40 exibem sinais classificados corretamente segundo o sistema proposto para as Classe N, S e V, respectivamente.

Figura 38 – Exemplo de Sinal N classificado pelo Classificador Morfológico.



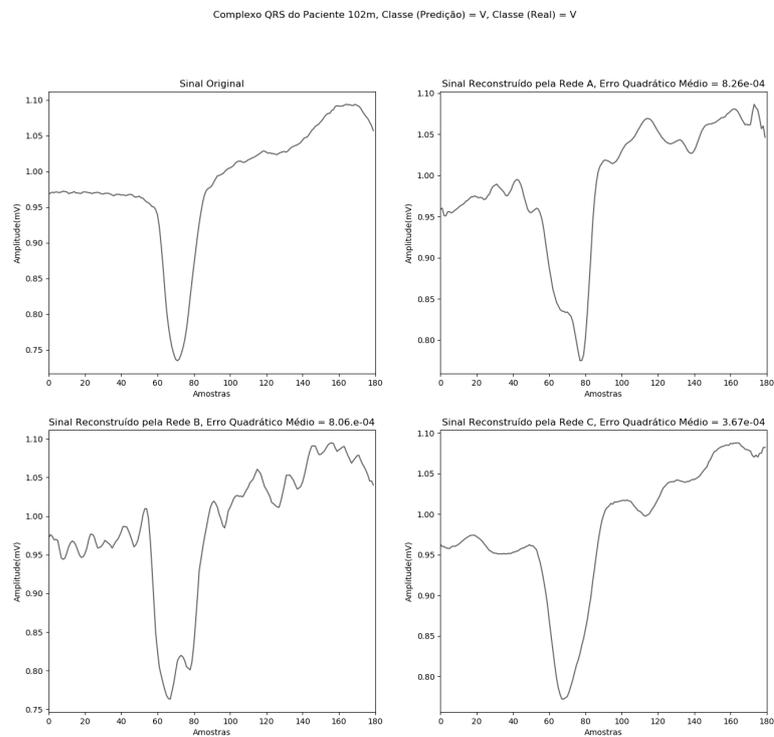
Fonte: Autor.

Figura 39 – Exemplo de Sinal S classificado pelo Classificador Morfológico.



Fonte: Autor.

Figura 40 – Exemplo de Sinal V classificado pelo Classificador Morfológico.



Fonte: Autor.

4.3.4 Comparação com sistemas apresentados na literatura

Para a avaliação da qualidade do Classificador Morfológico, a Tabela 13 resume os resultados de alguns classificadores já apresentados na literatura e anteriormente listados na Tabela 3, que se basearam no esquema inter-paciente para divisão da base de dados em DS1 e DS2 (DE CHAZAL et. al, 2004).

Tabela 13 – Resultados de Classificadores Morfológicos.

Referência	Acc	Sen(N)	+P(N)	Sen(S)	+P(S)	Sen(V)	+P(V)
Sistema morfológico proposto	81,73%	82,01%	97,18%	64,04%	14,98%	89,22%	84,89%
(DE CHAZAL et. al, 2004)	83%	87%	99%	76%	38%	77%	82%
(MAR et al, 2011)	89%	89%	99%	83%	33%	86%	75%
(YE et al., 2012)	86,4%	88%	97%	60%	53%	81%	63%
(ZHANG et al., 2014)	86%	89%	99%	79%	35%	85%	92%
(ZHANG e LUO, 2014)	87%	88%	98%	74%	59%	88%	82%
(GUO et al., 2018)	N/D	N/D	N/D	62,70%	61,21%	91,25%	88,30%
(ZHAI e TIN, 2018)	N/D	N/D	N/D	76,8%	74%	93,8%	92,4%
(LIN e YANG, 2014)	93%	91%	99%	81%	31%	86%	73%
(SORIA e MARTINEZ, 2009)	90%	92%	85%	88%	93%	90%	92%

Fonte: Autor.

Nos resultados expostos na Tabela 13, nota-se que o sistema proposto neste trabalho consegue ser melhor apenas em alguns casos se comparado com específicos trabalhos apresentados na literatura. Em linhas gerais, o sistema proposto fica abaixo dos outros trabalhos quanto a acurácia total e sensibilidade da Classe N. Considerando precisão da classe N o resultado já se mostra mais próximo dos demais. Quanto a Classe S, em ambas as métricas os valores ficam abaixo da maior parte dos resultados da literatura, porém na Classe V há bons resultados, onde a sensibilidade e precisão excedem a maior parte dos resultados apresentados.

Todos os sistemas apresentados na Tabela 13 possuem dificuldade para a classificação correta para a Classe S, suas taxas de Sensibilidade e +P sempre ficam abaixo das taxas de N e V, e esta dificuldade se estende mesmo para sistemas que usam diferentes características de entrada no sistema, como por exemplo o Intervalo RR.

É importante salientar que se apresenta na Tabela 13 somente os resultados para as três classes (S, V e N), como apresentado em (LUZ et al., 2015), entretanto a maior parte dos trabalhos classifica o padrão do AAMI de cinco classes, exceto em (LIN e YANG, 2014), onde o resultado é otimizado para três classes, e em (GUO et al., 2018) e (ZHAI e TIN, 2018), que otimizam para duas classes.

A metodologia aplicada neste trabalho, seguiu a abordagem vista em (LIN e YANG, 2014) para a otimização em três classes, devido ao grande desbalanceamento entre classes que existe na base de dados MIT-BIH. As classes excluídas (F e Q) possuem poucas amostras, como pode ser visto na Tabela 4 e pouco contribuem para uma melhoria nos resultados.

5 Conclusão e Trabalhos Futuros

Este trabalho apresentou os resultados obtidos da pesquisa de aplicação de Redes Neurais Convolucionais Auto-associativas para o problema de classificação de arritmias em sinais ECG. O sistema pode ser utilizado como sistema de apoio à tomada de decisão por especialistas da área de Cardiologia, sendo uma importante ferramenta para auxílio ao diagnóstico. O sistema de classificação de arritmias rítmicas apresentou uma acurácia de 88,9%, valor próximo ao encontrado em pesquisas recentes documentadas na literatura, e sensibilidade de 88,9%, sendo que esta medida representa a eficácia do diagnóstico em pacientes que possuam de fato alguma anormalidade no ritmo cardíaco.

Considerando o Classificador Morfológico, obteve-se 81,73% de acurácia e 78,42% de Sensibilidade, sendo que para as medidas mais importantes para a avaliação do classificador, as medidas de Sensibilidade e +P para cada classe, o sistema apresentou um bom desempenho para as classes N e V, mas desempenho menor para o caso da classe S, problema este comum em outros trabalhos já apresentados na literatura. Como mencionado, este problema se deve ao fato dos sinais para os casos N e S serem bem próximos, possuindo pequena diferença apenas na onda P, onde existe uma anormalidade em S.

Cita-se como vantagem do sistema proposto para o caso de arritmia rítmica o uso direto do sinal ECG medido, sem a necessidade de uma fase de extração de ruídos ou extração de características, o que diminui o custo computacional do sistema.

Considerando os resultados obtidos para as CNNs treinadas como reconstrutoras de sinais, podemos concluir que a mesma se mostrou adequada, com bons resultados, o que mostra a sua aplicabilidade para problemas onde se deseja reconstruir o sinal ECG. Estas redes podem ser utilizadas, por exemplo, em aplicações onde se deseja a transmissão do sinal de ECG para posterior avaliação por especialista que não esteja in loco. O sinal comprimido (com número menor de amostras que o sinal ECG original) pelas camadas internas da CNN pode ser transmitido via algum meio de comunicação para então ser reconstruído e avaliado. Para este caso apenas uma CNN poderia se treinada para reconstrução, a partir de todos os dados, de todas as classes.

Para trabalhos futuros pretende-se um melhor estudo e pesquisa para a redução dos erros de classificação referentes a Classe S no Classificador Morfológico, sendo uma sugestão o uso de outros sinais de entrada além do complexo QRS.

Referências Bibliográficas

- 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 20 jan 2019.
- AKHBARI, M.; SHAMSOLLAHI, M.; SAYADI, O.; ARMOUNDAS, A.; JUTTEN, C. ECG segmentation and fiducial point extraction using multi hidden Markov model. *Computers in Biology and Medicine*, Elsevier, 79, p.21–29. 2016.
- ALMEIDA, T. Uma metodologia de reconhecimento de caracteres manuscritos utilizando redes neurais embarcadas. 2014. FA7. Faculdade 7 de Setembro.
- ARAGÃO, H. Enfermagem Bio, Eletrocardiograma. 2015. Disponível em:
<https://enfermagembio.blogspot.com/2015/03/eletrocardiograma.html>. Acesso em 20 jan 2019.
- ARAÚJO, F.; CARNEIRO, A.; SILVA, R; MEDEIROS, F; USHIZIMA, D. Redes Neurais Convolucionais com Tensorflow: Teoria e Prática. III Escola Regional de Informática do Piauí. Livro Anais - Artigos e Minicursos, v. 1, n. 1, p. 382-406. 2017.
- ARRHYTHMIA ALLIANCE. Types of arrhythmia. 2018. Disponível em:
<http://www.heartrhythmalliance.org/aa/uk/types-of-arrhythmia>. Acesso em 20 jan 2019.
- ASL, B.M.; SETAREHDAN, S.K.; MOHEBBI, M. Mohebbi, Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal. *Artif. Intell. Med.* 44(1), P.51–64. 2008.
- BAIA, A.; CASTRO, A.R. A Competitive Structure of Convolutional Autoencoder Networks for Electrocardiogram Signals Classification. 2018. In: Encontro Nacional de Inteligência Artificial e Computacional (ENIAC). São Paulo, Brasil.
- BÜLBÜL, H.I.; USTA, N; YILDIZ, M. Classification of ECG arrhythmia with machine learning techniques. 2017. 16th IEEE International Conference on Machine Learning and Applications.
- BOROVYKH, A.; BOHTE, S.; OOSTERLEE, C. Conditional time series forecasting with convolutional neural Networks. 2018.
- CARDIORITMO. Exames. 2018. Disponível em: <http://cardioritmojales.com.br/exames>. Acesso em 20 jan 2019.

CASTRO, A.; MIRANDA, V.; LIMA, S. Diagnosing Faults in Power Transformers With Autoassociative Neural Networks and Mean Shift IEEE Transactions on Power delivery, Vol. 27, N° 3. 2012.

CELIN, S.; VASANTH, K. ECG Signal Classification Using Various Machine Learning Techniques. Journal of Medical Systems. 2018.

CENTER MEDICAL. Eletrocardiógrafo. 2018. Disponível:

<https://www.centermedical.com.br/eletrocardiografo-03-canais-12-derivacoes-ecafix-ecg-12s/p>. Acesso em 20 jan 2019.

CHEN, M.; HAO, Y.; HWANG, K.; WANG, L.; WANG, L. Disease Prediction by Machine Learning Over Big Data From Healthcare Communities. 2017. IEEE Access.

CHEN, S.-W.; CLARKSON, P.M.; FAN, Q. A robust sequential detection algorithm for cardiac arrhythmia classification, IEEETrans. Biomed. Eng. 43 (11) (1996) 1120–1124.

COAST, D.A.; STERN, R.M.; CANO, G.G.; BRILLER, S.A. An approach to cardiac arrhythmia analysis using hidden markov models, IEEE Trans. Biomed. Eng. 37 (9), p.826–836. 1990.

COLAB. Google Colab. Disponível em: <https://colab.research.google.com/>. Acesso em 14 mar 2019.

COLAH. Understanding LSTM Networks. 2015. Disponível em:

<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Acesso em 20 jan 2019.

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

DE CHAZAL, P. M.; O'DWYER, M.; REILLY, R. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. IEEE Trans. Biomed. Eng. 51 (7), p.1196–1206. 2004.

DESHPANDE, A. A Beginner's Guide to Understanding Convolutional Neural Networks.

2018. Disponível em: <https://adeshpande3.github.io/adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>. 20 jan 2019.

DOKUR, Z.; ÖLMEZ, T. ECG beat classification by a novel hybrid neural network, Comput. Method Program Biomed.66 (2-3) (2001) 167–181.

- 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.
- FERRARA, E.R.; WIDROW, B. Fetal electrocardiogram enhancement by time-sequenced adaptive filtering, *IEEE Trans. Biomed. Eng.* 29 (6), p.458–460. 1982.
- GACEK; A.; PEDRYCZ, W. A genetic segmentation of ECG signals. *IEEE Transactions on Biomedical Engineering* Vol. 50, N 10. 2003.
- 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.
- GUO, L.; SIM, G.; MATUSZEWSK, B. Inter-Patient ECG Classification with Convolutional and Recurrent Neural Networks. 2018.
- HAM, F.M.; HAN, S. Classification of cardiac arrhythmias using fuzzy ARTMAP. *IEEE Trans. Biomed. Eng.* 43 (4), p.425–429. 1996.
- HE, K. Convolutional Feature Maps: Elements of efficient (and accurate) CNN-based object detection. 2015. Disponível em: http://kaiminghe.com/iccv15tutorial/iccv2015_tutorial_convolutional_feature_maps_kaiminghe.pdf. Acesso em 20 jan 2019.
- HU, Y.H.; TOMPKINS, W.J.; URRUSTI, J.L.; AFONSO, V.X. Application of artificial neural networks for ECG signal detection and classification. *J. Eletrocardiol.* 26 (Suppl.), p.66–73. 1990.
- HUANG, H.; LIU, J.; ZHU, Q.; WANG, R.; HU, G. A new hierarchical method for inter-patient heartbeat classification using random projections and RR intervals. *Biomed. Eng. Online* 13, p.1–26. 2014.
- ILANGO, R. Batch Normalization—Speed up Neural Network Training. 2018. Disponível em: <https://medium.com/@ilango100/batch-normalization-speed-up-neural-network-training-245e39a62f85>. Acesso em 20 jan 2019.
- 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.

- JEYARANI, A.D.; 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). 2010. Chennai, Índia.
- JONES, M. Deep learning architectures: The rise of artificial intelligence. 2017. Disponível em: <https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/>. Acesso em 20 jan 2019.
- JUNG, Y.; TOMPKINS, W.J. Detecting and classifying life-threatening ECG ventricular arrhythmias using wavelet decomposition. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Vol. 3, pp. 2390–2393. 2003.
- KACHUEE, M.; FAZELI, S; SARRAFZADEH, M. ECG Heartbeat Classification: A Deep Transferable Representation. 2018. 2018 IEEE International Conference on Healthcare Informatics.
- KELWADE, J.; SALANKAR, S. Prediction of Cardiac Arrhythmia using Artificial Neural Network. International Journal of Applications, Vol. 115, nº 20. 2015.
- KERAS. Keras: The Python Aprendizado Profundo Library. 2018. Disponível em: <https://keras.io/>. Acesso em 20 jan 2019.
- KIM, H.; YAZICIOGLU, R.F.; MERKEN, P.; VAN HOOFF, C.; YOO, H.-J. ECG signal compression and classification algorithm with quad level vector for ECG holter system. IEEE Trans. Inf. Technol. Biomed. 14 (1), p.93–100. 2010.
- KIM, J.; SHIN, H.S.; SHIN, J.; LEE, M. Robust algorithm for arrhythmia classification in ECG using extreme learning machine. BioMed. Eng. OnLine 8 (1), p.1–12. 2009.
- KUMAR, R.G. A new trained ECG signal Classification method using Modified Spline Activated Neural Network. 2018. In: Proceedings of the Second International Conference on Computing Methodologies and Communication (ICCMC).
- LAGERHOLM, M.; PETERSON, C.; BRACCINI, G.; EDENBRANDT, L.; SORNMO, L. Clustering ECG complexes using hermite functions and self-organizing maps, IEEE Trans. Biomed. Eng. 47 (7) (2000) 838–848.
- LASSOUED, H.; KETATA, R. ECG multi-class classification using neural network as machine learning model. 2018. In: International Conference on Advanced Systems and Electric Technologies (IC_ASET), Hammamet, Tunisia.

- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning Review. Nature: Vol. 521, p. 436-444. 2015.
- LI, C.; ZHENG, C.; TAI, C. Detection of ECG characteristic points using wavelet transforms. IEEE Trans. Biomed. Eng. 42 (1), p.21–28. 1995.
- LIN, C.; YANG, C. Heartbeat classification using normalized RR intervals and morphological features. Math. Problem Eng., p.1–11. 2014.
- LYNN, P. Recursive digital filters for biological signals. Med. Biol. Eng. Comput. 9 (1), p37–43. 1979.
- LUZ, E.; SCHWARTZ, W.; CÁMARA-CHÁVEZ, G.; MENOTTI, D. ECG-based heartbeat classification for arrhythmia detection: A survey. 2015. Elsevier.
- MAGALHÃES, L. Coração Humano. 2018. Disponível em: <https://www.todamateria.com.br/coracao/>. Acesso em 20 jan 2019.
- MAHESH, V.; KANDASWAMY, A.; VIMAL, C.; SATHISH, B. ECG arrhythmia classification based on logistic model tree. J. Biomed. Sci. Eng. 2 (6), p.405–411. 2009.
- MAJUMDAR, A.; WARD, R.; Robust Greedy Deep Dictionary Learning for ECG Arrhythmia Classification. 2017. International Joint Conference on Neural Networks (IJCNN). Anchorage, EUA.
- MAR, T.; ZAUNSEDER, S.; MARTÍNEZ, J.; LLAMEDO, M., POLL, R. Optimization of ECG classification by means of feature selection. IEEE Trans. Biomed. Eng. 58 (8), p.2168–2177. 2011.
- MEHMET, E. ECG beat classification using neuro-fuzzy network. Pattern Recogn. Lett. 25 (15) p.1715–1722. 2004.
- MISHRA, A.K.; AGHAV, S. Local fractal dimension based ECG arrhythmia classification. Biomed. Signal Process. Control 5 (2), p.114–123. 2010.
- MLP. Multilayer Perceptron. DeepLearning 0.1 documentation”. 2018. Disponível em: <http://deeplearning.net/tutorial/mlp.html>. Acesso em 20 jan 2019.
- MUCHAHARY, F. Basic CNN Keras with cross validation. 2018. Disponível em: <https://www.kaggle.com/franklemuchahary/basic-cnn-keras-with-cross-validation>. Acesso em 20 jan 2019.

MY EKG. Arritmias Ventriculares. 2018. Disponível em: <http://pt.my-ekg.com/arritmias-cardiacas/arritmias-ventriculares.html>. Acesso em 20 jan 2019.

MY EKG ONDAS. Ondas do Eletrocardiograma. Disponível em: <http://pt.my-ekg.com/generalidades-ecg/ondas-eletrocardiograma.html>. Acesso em 20 jan 2019.

NAIK, G.; REDDY, K. Comparative Analysis of ECG Classification Using Neuro-Fuzzy Algorithm and Multimodal Decision Learning Algorithm. 2016. In: 3rd International Conference on Soft Computing & Machine Intelligence, Dubai, Emirados Arábes Unidos.

NAIR, V.; HINTON, G. Rectified Linear Units Improve Restricted Boltzmann Machines. 2010. In: Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel.

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 Aprendizizado 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 20 jan 2019.

NVIDIA. CUDA Zone. 2018. Disponível em: <https://developer.nvidia.com/cuda-zone>. 20 jan 2019.

OPAS BRASIL. Doenças Cardiovasculares. 2017. Disponível em: https://www.paho.org/bra/index.php?option=com_content&view=article&id=5253:doencas-cardiovasculares&Itemid=839. Acesso em 20 jan 2019.

OSOWSKI, S.; MARKIEWICZ, T.; HOAI, L.T. Recognition and classification system of arrhythmia using ensemble of neural networks, Measurement 41 (6), p.610–617. 2008.

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

PENHA, D.; CASTRO, A. Convolutional Neural Network Applied to the Identification of Residential Equipment in Nonintrusive Load Monitoring Systems. 2017. In: 3rd International Conference on Artificial Intelligence and Applications, Computer Science & Information Technology, p. 11.

- PHYSIONET. MIT-BIH Arrhythmia Database. 2018. Disponível em: <https://www.physionet.org/physiobank/database/mitdb/>. Disponível em: Acesso em 20 jan 2019.
- PYTHON. Python. 2018. Disponível em: <https://www.python.org/>. Acesso em 20 jan 2019.
- RASCHKA, S. Linear Discriminant Analysis. 2014. Disponível em: https://sebastianraschka.com/Articles/2014_python_lda.html. Acesso em 20 jan 2019.
- REAMAT. Interpolação cúbica segmentada – spline. 2018. Disponível em: https://www.ufrgs.br/reatmat/CalculoNumerico/livro-sci/i1_interpolacao_cubica_segmentada_-_spline.html. Acesso em 20 jan 2019.
- RUDER, S. An overview of gradient descent optimization algorithms. 2016. Disponível em: <http://ruder.io/optimizing-gradient-descent/index.html#adamax>. Acesso em 20 jan 2019.
- SANTOS, V. "Coração". Brasil Escola. Disponível em: <https://brasilescola.uol.com.br/biologia/coracao-humano.htm>. Acesso em 14 mar 2019.
- SAPNA, S.; TAMILARASI, A.; KUMAR, M. Backpropagation learning algorithm based on Levenberg Marquardt algorithm. 2012. Disponível em: <https://airccj.org/CSCP/vol2/csit2438.pdf>. Acesso em 20 jan 2019.
- SARFRAZ, M.; KHAN, A.A.; LI, F.F. Using independent component analysis to obtain feature space for reliable ECG arrhythmia classification, in: IEEE International Conference on Bioinformatics and Biomedicine (BIBM), p.62–67. 2014.
- SATIJA, U; RAMKUMAR, B.; MANIKANDAN, M.B. Automated ECG Noise Detection and Classification System for Unsupervised Healthcare Monitoring. IEEE Journal of Biomedical and Health Informatics. Vol.23, Nº3. 2017.
- SATHYANARAYANA, S. A Gentle Introduction to Backpropagation. 2014.
- SAVALIA, S.; EMAMIAN, V. Cardiac Arrhythmia Classification by Multi-Layer Perceptron and Convolution Neural Networks. Bioengineering (Basel) 5 (2). 2018.
- SCHWARZ, L. Artigo de Revisão: Eletrocardiograma. Ilha Digital, Vol.1. 2009.
- SCIENCE PHOTO LIBRARY. Heart and lungs, chest X-ray composite. 2018. Disponível em: <https://www.sciencephoto.com/media/438244/view>. Acesso em 20 jan 2019.
- SEGATTO, Ê. C.; COURY, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. 2006. Disponível em:

http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592006000400004#fig05. Acesso em 20 jan 2019.

SILVA, H; CARREIRAS, C.; LOURENÇO, A.; FRED, A; NEVES, R.C., FERREIRA, R. Off-the-person electrocardiography: performance assessment and clinical correlation, *Health Technol.* 4 (4), p.309–318. 2015.

SINGH, B.N.; TIWARI, A.K. Optimal selection of wavelet basis function applied to ECG signal denoising. *Digit. Signal Process.* 16 (3), p.275–287. 2006.

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

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.

TANDALE, S.; GHONGADE, R.; BARHATTE, A., DALE, M. Arrhythmia classification using neuro fuzzy approach. 2017. In: 3rd International Conference on Advances in Computing, Communication & Automation (ICACCA), Dehradun, Índia.

TENSORFLOW. TensorFlow. 2018. Disponível em: <https://www.tensorflow.org/>. Acesso em 20 jan 2019.

TSIPOURAS, M.G.; FOTIADIS, D.I.; SIDERIS, D. Arrhythmia classification using the RR-interval duration signal, in: *Comput. Cardiol.* pp. 485–488. 2002.

ÜBEYLI, E.D. ECG beats classification using multiclass support vector machines with error correcting output codes, *Digit. Signal Process.* 17 (3) p.675–684. 2007.

VENKATESAN, C.; KARTHIGAİKUMAR, P.; VARATHARAJAN, R. A novel LMS algorithm for ECG signal preprocessing and KNN classifier based abnormality detection. *R. Multimed. Tools Appl.* Vol. 77, N° 8. 2018.

VISION. Using Convolutional Neural Networks for Image Recognition. 2017. Disponível em: <https://www.embedded-vision.com/platinum-members/cadence/embedded-vision-training/documents/pages/neuralnetworksimagerecognition>. Acesso 20 jan 2019.

WU, Z.; DING, X; ZHANG, G.; XU, X.; WANG, X.; TAO, Y.; JU, C. A novel features learning method for ECG arrhythmias using deep belief networks. 2016. In: 6th International Conference on Digital Home.

- YADAV, O.; RAY, S. Smoothing and Segmentation of ECG Signals Using Total Variation Denoising –Minimization-Majorization and Bottom-Up Approach. *Procedia Computer Science* Vol. 85, p.483-489. 2016.
- YANG, J. ReLU and Softmax Activation Functions. 2017. Disponível em: <https://github.com/Kulbear/deep-learning-nano-foundation/wiki/ReLU-and-Softmax-Activation-Functions>. Acesso em 20 jan 2019.
- YANG, W.-H.; JIANG, B. An integrated statistical Process Control and Wavelet transformation Model for detecting QRS Complexes in ECG signals. *International Journal of Artificial Life Research*, 1(2), p.1-20. 2010.
- YE, C.; KUMAR, B.; COIMBRA, M. Combining general multi-class and specific two-class classifiers for improved customized ECG heartbeat classification. 2012. *International Conference on Pattern Recognition (ICPR)*, p.2428–2431.
- YOUNG, T.; HAZARIKA, D.; PORIA, S.; CAMBRIA, E. Recent Trends in Deep Learning Based Natural Language Processing. 2018.
- YU, S.-N.; CHEN, Y.-H. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network, *Pattern Recogn. Lett.* 28 (10), p.1142–1150. 2007.
- 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, Z.; DONG, J.; LUO, X.; CHOI, K.; WU, X. Heartbeat classification using disease-specific feature selection. *Comput. Biol. Med.* 46, p.79–89. 2014.
- ZHANG, Z.; LUO, X. Heartbeat classification using decision level fusion. *Biomed. Eng. Lett.* 4 (4), p.388–395. 2014