


UNIVERSIDADE FEDERAL DO PARANÁ

ROGER DE TARSO GUERRA

ABORDAGEM DE APRENDIZADO PROFUNDO PARA CLASSIFICAÇÃO DE
BATIMENTOS CARDÍACOS DE FORMA AUTOMÁTICA

CURITIBA PR

2023



ROGER DE TARSO GUERRA

ABORDAGEM DE APRENDIZADO PROFUNDO PARA CLASSIFICAÇÃO DE
BATIMENTOS CARDÍACOS DE FORMA AUTOMÁTICA

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, da Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: *Sistemas Eletrônicos*.

Orientador: Leandro dos Santos Coelho.

CURITIBA PR

2023

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA CIÊNCIA E TECNOLOGIA

Guerra, Roger de Tarso.

Abordagem de aprendizado profundo para classificação de batimentos cardíacos de forma automática. / Roger de Tarso Guerra. – Curitiba, 2023.

1 recurso on-line : PDF.

Dissertação (Mestrado) – Universidade Federal do Paraná, Setor de Tecnologia Programa de Pós-Graduação em Engenharia Elétrica.

Orientador: Prof. Dr. Leandro dos Santos Coelho.

1. Engenharia elétrica. 2. Eletrocardiograma. 3. Doenças cardiovasculares. 4. Arritmias cardíacas - Diagnóstico. I. Coelho, Leandro dos Santos. II. Universidade Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

Bibliotecário: Nilson Carlos Vieira Júnior CRB-9/1797

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **ROGER DE TARSO GUERRA** intitulada: **ABORDAGEM DE APRENDIZADO PROFUNDO PARA CLASSIFICAÇÃO DE BATIMENTOS CARDÍACOS DE FORMA AUTOMÁTICA**, sob orientação do Prof. Dr. LEANDRO DOS SANTOS COELHO, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 31 de Janeiro de 2023.

Assinatura Eletrônica

02/02/2023 09:08:26.0

LEANDRO DOS SANTOS COELHO

Presidente da Banca Examinadora

Assinatura Eletrônica

01/02/2023 20:32:31.0

GIDEON VILLAR LEANDRO

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

01/02/2023 16:50:36.0

LUIS HENRIQUE ASSUMPÇÃO LOLIS

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

02/02/2023 13:10:52.0

ROBERTO ZANETTI FREIRE

Avaliador Externo (PONTIFICA UNIVERSIDADE CATÓLICA DO PARANÁ)

Assinatura Eletrônica

02/02/2023 20:04:20.0

VIVIANA COCCO MARIANI

Avaliador Externo (PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ)

*O ontem é história, o amanhã é um
mistério, mas hoje é uma dádiva,
por isso chama-se presente. Mestre
Oogway*

AGRADECIMENTOS

Gostaria de começar meus agradecimentos expressando minha sincera gratidão à minha orientador/professor Leandro dos Santos Coelho pela sua orientação cuidadosa, paciência, conselhos valiosos e apoio constante durante todo o processo de escrita desta dissertação. Seu conhecimento e experiência foram fundamentais para o sucesso deste trabalho.

Gostaria de agradecer aos meus colegas de classe e amigos, em especial Lucas Takara, por compartilhar ideias, apoiar uns aos outros e tornar essa jornada mais agradável.

Não posso deixar de mencionar meus familiares, que sempre me apoiaram em todas as decisões que tomei e por me incentivar a seguir meus sonhos. Sua constante presença e apoio foram fundamentais para a conclusão deste trabalho.

Por fim, agradeço a todos aqueles que, de alguma forma, contribuíram para a realização deste trabalho, mesmo que não tenham sido mencionados aqui. Sem a ajuda de vocês, este trabalho não teria sido possível.

RESUMO

No ano de 2021 a Organização Mundial da Saúde (OMS) estimou que aproximadamente 17 milhões de pessoas morrem todos os anos devido a doenças cardiovasculares associadas ao coração humano dentre elas arritmias. A arritmia é a irregularidade e anormalidade do ritmo dos batimentos cardíacos e a principal forma de identificação destas anormalidades dos batimentos do coração pode ser realizada por meio do eletrocardiograma (do inglês *eletrocardiogram*, ECG), sendo uma das ferramentas de auxílio ao diagnóstico comumente usadas na medicina e na saúde para lidar com problemas relacionados ao coração. Entretanto as abordagens tradicionais de detecção de arritmia, incluindo a investigação manual dos registros de ECG, são geralmente demoradas e propensas a erros, além de serem, às vezes, subjetivas gerando uma dificuldade para os médicos e equipes médicas para distinguir os diferentes padrões de arritmias, demonstrando que existe a possibilidade de não se identificar qualquer doença cardíaca com 100% de precisão até o paciente ser submetido a outros exames. No entanto, para interpretar de forma apropriada os sinais de ECG, métodos de análise automatizada foram propostos na literatura na tentativa de alcançar a classificação automática dos tipos de arritmia. Na literatura, abordagens utilizando de aprendizado profundo, especialmente as Redes Neurais Convolucionais, tem sido usada com sucesso para a detecção e classificação de sinais de ECG de forma automática, com o fim de não dispor da necessidade de um pré-processamento antes do treinamento da rede, exceto para normalização do conjunto de dados. Para tanto, nessa dissertação de mestrado foi proposto um codificador automático (do inglês *autoencoder*, AE) com camadas de memória de curto e longo prazo (do inglês *long short term memory*, LSTM) para extração de características do sinal combinado a um classificador multi-classe, da qual esta estrutura pode cooperar com o processo de pré-processamento dos sinais para classificar de forma eficiente as arritmias. Um total de 97300 batimentos consistindo de 5 classes diferentes de arritmias foram extraídos, incluindo ritmo sinusal normal, batimento prematuro atrial, contração ventricular prematura, bloqueio do ramo esquerdo e bloqueio do ramo direito do banco de dados de arritmias e supraventricular, ambos da base de dados do Instituto de Tecnologia de Massachusetts e do Hospital Israelita de Boston (MIT-BIH). O modelo proposto nas tarefas de classificação alcançou uma taxa de acurácia de 98,57% na base de dados de arritmia e 97,59% na base de dados supraventricular do MIT-BIH, o que permite esperar resultados efetivos quando aplicados a paciente reais. Comparado com outras abordagens de aprendizado profundo de maior estrutura, como modelos baseados em Redes Neurais Convolucionais, foi possível identificar que a abordagem proposta descarta o problema do desaparecimento do gradiente em tarefas de classificação. Também foi possível constatar que a etapa de pré-processamento impactou significativamente os resultados demonstrando que os ruídos afetam na classificação do sinal.

Palavras-chave: Eletrocardiograma. Aprendizado profundo. Autoencoder.

ABSTRACT

In the year 2021, the World Health Organization (WHO) estimated that approximately 17 million people die every year due to cardiovascular diseases associated with the human heart, including arrhythmias. Arrhythmia is the irregularity and abnormality of the heartbeats' rhythm. The main way to identify these abnormalities of the heartbeats can be performed through an electrocardiogram (ECG), which is one of the commonly used diagnostic aids in medicine and healthcare to deal with heart-related problems. However, traditional approaches to arrhythmia detection, including manual investigation of ECG records, are generally time-consuming and prone to errors, and are sometimes subjective, making it difficult for doctors and medical teams to distinguish different patterns of arrhythmias, demonstrating that there is a possibility of not identifying any cardiac disease with 100% accuracy until the patient undergoes further tests. However, to properly interpret ECG signals, automated analysis methods have been proposed in the literature in an attempt to achieve the automatic classification of arrhythmia types. In the literature, approaches using deep learning, especially Convolutional Neural Networks, have been successfully used for the automatic detection and classification of ECG signals, to eliminate the need for pre-processing before network training, except for data normalization. Therefore, in this master's thesis, an autoencoder with long and short-term memory (LSTM) layers was proposed for feature extraction from the signal combined with a multi-class classifier, which can cooperate with the signal pre-processing process to efficiently classify arrhythmias. A total of 97,300 heartbeats consisting of 5 different classes of arrhythmias were extracted, including normal sinus rhythm, premature atrial beat, premature ventricular contraction, left bundle branch block, and right bundle branch block from the arrhythmia and supraventricular databases, both from the Massachusetts Institute of Technology and the Beth Israel Hospital (MIT-BIH) arrhythmia database. The proposed model achieved an accuracy rate of 98.57% in the arrhythmia database and 97.59% in the supraventricular database of the MIT-BIH, which allows for effective results when applied to real patients. Compared to other deep learning approaches with larger structures, such as models based on Convolutional Neural Networks, it was possible to identify that the proposed approach discards the problem of gradient disappearance in classification tasks. It was also possible to observe that the pre-processing step significantly impacted the results, demonstrating that noise affects signal classification.

Keywords: Electrocardiogram. Deep learning. Autoencoder.

LISTA DE FIGURAS

1.1	Diagrama de aprendizado.	16
1.2	Sequência metodológica da pesquisa	19
2.1	Ilustração dos Sistemas excitatório e condutor do coração (a) e morfologia típica dos "PA's" em cada tipo de estrutura (b).	22
2.2	Disposição das derivações I, II e III. O triângulo de Einthoven está sobreposto ao tórax (Hall e Guyton, 2011).	23
2.3	Exemplo de registro do eletrocardiograma nas derivações I, II e III (Hall e Guyton, 2011)	24
2.4	Derivações dos membros aumentada.. . . .	25
2.5	Derivações no peito	25
2.6	Diagrama do fluxo de tratativa dos dados e classificação.	30
2.7	Comparação entre métodos tradicionais e aprendizado profundo	30
2.8	Modelo de um neurônio artificial	31
2.9	Estrutura de uma MLP com uma única camada oculta	33
2.10	Arquitetura de uma rede convolucional.	35
2.11	Ilustração de uma operação de convolução	36
2.12	Tipos de agrupamento	37
2.13	Representação básica de modelos RNN usados por Jordan (esquerda) e Elman (direita)	38
2.14	Ilustração de Blocos LSTM e a unidade de célula memória	39
2.15	Estrutura básica da rede BLSTM. As redes LSTM na parte inferior indicam o recurso para a frente. As redes acima são usadas para trás. Ambas as redes se conectam a uma camada de ativação comum para produzir saídas.	40
2.16	Estrutura de um Autoencoder.	42
2.17	Diagrama de fluxo de identificação e inclusão de artigos.	44
2.18	Número de publicações por ano	46
2.19	Número de publicações por ano em conferência e revistas	46
2.20	Porcentagem de publicações por ano em revistas.	47
2.21	Porcentagem de publicações por ano em conferências	48
2.22	Resumo da análise dos artigos	48
2.23	Número de publicações por grupos e comunidades	49
2.24	a) intervalo RR; b) segmento ST	50
2.25	Duas redes LSTM (Saadatnejad et al., 2020).	52
2.26	Número de artigos por abordagens	53
2.27	Porcentagem de artigos por abordagens	53

3.1	Diagrama do algoritmo proposto..	55
3.2	Diagrama do filtro adaptativo.	58
3.3	Exemplo de um batimento sem passar pelo filtro.	59
3.4	Exemplo de um batimento após filtragem.	59
3.5	Detalhes da distribuição dos dados..	60
3.6	Diagrama da estrutura da camada de codificação.	61
3.7	Diagrama da estrutura da camada de decodificação.	61
4.1	Classificação dos tipos de batimentos cardíacos.	66

LISTA DE TABELAS

2.1	Derivações eletrocardiográficas.	26
2.2	Tipos de derivações e agrupamento de registros do banco de dados de arritmias do MIT-BIH.	28
2.3	Mapeamento das classes da base MIT-BIH para as classes AAMI.	29
2.4	Organização da base de dados segundo a AAMI.	29
3.1	Tipos de arritmias e a distribuição dos dados.	60
3.2	Detalhes e parâmetros de cada camada do AE	62
3.3	Parâmetros da LSTM do AE	62
3.4	Detalhes de camada e parâmetros usado para o modelo LSTM de classificação.	63
4.1	parâmetros de controle.	65
4.2	AE com rede LSTM com diferentes quantidades de camadas.	67
4.3	Matriz de confusão aplicado a base de dados de arritmia do MIT-BIH	67
4.4	Matriz de confusão aplicado a base de dados de arritmia supraventricular do MIT-BIH	68
4.5	Matriz de confusão aplicado a base de dados de arritmia do MIT-BIH sem pré-processamento	68
4.6	Estado da arte sobre a detecção automática das arritmias.	69
4.7	Estudos recentes sobre a detecção automática das arritmias.. . . .	70

LISTA DE ACRÔNIMOS

AAMI	Associação para o Avanço da Instrumentação Médica (do inglês <i>Association for the Advancement of Medical Instrumentation</i>)
AE	Codificadores automáticos (do inglês <i>Autoencoder</i>)
BLSTM	LSTM bidirecional
BRNN	RNN bidirecional
BRE	Bloqueio do ramo esquerdo
BRD	Bloqueio do ramo direito
CAE	Auto-codificador convolucional (do inglês <i>Convolutional Autoencoder</i>)
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CHF	Insuficiência cardíaca congestiva (do inglês <i>Congestive Heart Failure</i>)
CNN	Redes neurais convolucionais (do inglês <i>convolutional Neural Network</i>)
CRNN	Redes neurais convolucionais recorrentes (do inglês <i>Convolutional Recurrent Neural Network</i>)
DenseNet	Rede convolucional densa (do inglês <i>Dense Convolutional Network</i>)
DL	Aprendizado profundo (do inglês <i>deep learning</i>)
DWT	Transformada wavelet discreta (do inglês <i>Discrete Wavelet Transform</i>)
ECG/EKG	Eletrocardiograma (do inglês <i>Eletrocardiogram</i>)
EMG	Eletromiografia
EUA	Estados Unidos da América
FA	Fibrilação Atrial
GRU	Unidades recorrentes com portas fechadas (do inglês <i>Gated Recurrent Unit</i>)
HOS	Estatística de alta ordem (do inglês <i>High Order Statistics</i>)
ICA	Componentes de análise independente (do inglês <i>Independent Component Analysis</i>)
LA	Braço esquerdo (do inglês <i>left arm</i>)
LL	Perna esquerda (do inglês <i>left leg</i>)
LSTM	Memória de curto e longo prazo (do inglês <i>Long Short Term Memory</i>)
MAE	Erro Médio Absoluto (do inglês <i>Mean Absolute Error</i>)
MI	Infarto do miocárdio (do inglês <i>Myocardial Infarction</i>)
MLP	Rede perceptron multicamada (do inglês <i>Multilayer Perceptron</i>)

OMS	Organização Mundial da Saúde
PAC	Contração prematura dos átrios (do inglês <i>Premature Contractions of the Atria</i>)
PCA	Análise de componente principal (do inglês <i>Principal Component Analysis</i>)
PVC	Contração prematura dos ventrículos (do inglês <i>Premature contractions of the ventricles</i>)
RA	Braço direito (do inglês <i>right arm</i>)
RAM	Memória de acesso volátil (do inglês <i>random access memory</i>)
RBF	Função de base radial (do inglês <i>Radial Basis Function</i>)
RNA	Rede neural artificial
ReLU	Unidades lineares retificadas (do inglês <i>Rectified Linear Unit</i>)
ResNet	Rede neural residual (do inglês <i>Residual Neural Network</i>)
RNN	Redes neurais recorrente (do inglês <i>Recurrent Neural Network</i>)
RSL	Revisão sistemática da literatura
SAE	Codificador automático empilhado (do inglês <i>Stacked Autoencoder</i>)
SDAE	codificadores automáticos de remoção de ruído empilhado (do inglês <i>stacked denoising autoencoder</i>)
SVM	Máquinas de vetores de suporte (do inglês <i>Support Vector Machine</i>)
UTI	Unidade de terapia intensiva
TW	Terminal central de Wilson
XOR	OU exclusivo

LISTA DE SÍMBOLOS

N	ordem do filtro
n	número de amostras
α	alfa, primeira letra do alfabeto grego
β	beta, segunda letra do alfabeto grego
γ	taxa de aprendizagem
ω	pesos/Parametros
$\nabla H(\omega_i)$	derivadas parciais da função de custo
φ	função de ativação
σ	função sigmoide logística
$p(x)$	distribuição verdadeira
$q(x)$	distribuição prevista
x	variável aleatória

SUMÁRIO

1	INTRODUÇÃO	15
1.1	JUSTIFICATIVA	16
1.2	OBJETIVOS	17
1.2.1	Objetivo geral	17
1.2.2	Objetivos específicos	17
1.3	METODOLOGIA DE PESQUISA	18
1.4	ESTRUTURA DO DOCUMENTO	20
2	FUNDAMENTOS TEÓRICOS	21
2.1	O ELETROCARDIOGRAMA (ECG)	21
2.1.1	Atividade elétrica cardíaca	21
2.1.2	As derivações eletrocardiográficas	22
2.1.3	As características dos sinais de ECG	25
2.1.4	Arritmias cardíacas	27
2.1.5	Base de dados de ECG	28
2.2	APRENDIZADO DE MÁQUINA	28
2.3	REDES NEURAIS ARTIFICIAIS	31
2.3.1	Redes neurais multicamadas	32
2.4	APRENDIZADO PROFUNDO	34
2.4.1	Redes neurais convolucionais	35
2.4.2	Redes neurais recorrentes	37
2.4.3	Codificadores automáticos - <i>Autoencoder</i>	41
2.5	TRABALHOS RELACIONADOS	43
2.5.1	Revisão sistemática de literatura	44
2.5.2	Trabalhos relacionados ao tema da dissertação	49
2.6	CONSIDERAÇÕES DO CAPÍTULO	53
3	METODOLOGIA	55
3.1	PRÉ-PROCESSAMENTO	55
3.1.1	Filtragem do sinal	56
3.1.2	Segmentação	58
3.2	ARQUITETURA	61
3.3	MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO	63
3.4	CONSIDERAÇÕES DO CAPÍTULO	64

4	RESULTADOS E DISCUSSÃO	65
4.1	BASE DE DADOS	65
4.2	RESULTADOS DE CLASSIFICAÇÃO DO MODELO	65
4.3	DISCUSSÃO DOS RESULTADOS	67
4.4	CONSIDERAÇÕES DO CAPÍTULO	71
5	CONCLUSÃO	73
5.1	PESQUISA FUTURA	74
	REFERÊNCIAS	75

1 INTRODUÇÃO

Segundo a Organização Mundial de Saúde (OMS) as doenças cardiovasculares são a causa número um de mortes em todo o mundo (Organization, 2021) atingindo um número próximo de 17 milhões por ano, tudo isso aliado a palpitações cardíacas com a presença de algum padrão de anomalia. O principal exame para detecção dessas doenças é denominado eletrocardiograma (do inglês *electrocardiogram*, ECG), uma forma de diagnóstico não invasiva comumente usada para registrar as atividades fisiológicas do coração durante um período de tempo, proporcionando uma visão sobre a condição cardíaca (Hong et al., 2019b). Entretanto, os especialistas em cardiologia mesmo com anos de experiência estão sujeitos a falhas em distinguir entre batidas normais do coração ou arritmias, devido à natureza humana e estrutura muscular do coração. Para tanto, melhorias ligadas ao ECG para auxiliar o especialista tanto na coleta quanto na análise do sinal no diagnóstico(s) do(s) paciente(s). Isto explica o porquê de, na última década, vários trabalhos tenham sido desenvolvidos para produzir detecção automática e classificação de anomalias de batimentos cardíacos (Luz et al., 2016; Berkaya et al., 2018; Siontis et al., 2021; Hameed e Al-Tuwaijari, 2022).

Partindo da necessidade de detectar e classificar anomalias em batimentos cardíacos o aprendizado de máquina tem ganhado destaque da qual, segundo Mitchell (1999) é a habilidade de aprimorar o desempenho na execução de alguma tarefa por meio da experiência. Deste modo os computadores são programados para aprender com a experiência passada, utilizando um princípio de inferência denominado indução, na qual se obtém conclusões genéricas a partir de um conjunto particular de dados. Assim, os algoritmos de aprendizado de máquina aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir dos dados que representam a instância do problema a ser resolvido, em que esses dados formam um conjunto dados. Os algoritmos de aprendizado de máquina são empregados em várias tarefas como reconhecimento de padrões em imagens (Li, 2022), detecção de anomalias (Pang et al., 2021), processamento de linguagem natural (Khurana et al., 2022), visão computacional e reconhecimento de fala (LeCun et al., 2015; Alam et al., 2020), de tal modo que podem ser classificadas de acordo com diferentes parâmetros da qual, um deles está relacionado ao aprendizado a ser escolhido para lidar com uma certa tarefa. Segundo esses parâmetros as tarefas de aprendizagem podem ser divididas em preditivas e descritivas, conforme ilustrado na Figura 1.1.

Na extremidade superior da Figura 1.1 é mencionado o aprendizado indutivo, método pelo qual são executadas as generalizações a partir do conjunto de dados, logo em seguida consta os tipos de aprendizado, supervisionado (preditivo) e não supervisionado (descritivo). O aprendizado supervisionado é dividido de acordo com os tipos dos rótulos dos dados: é considerado discreto para casos de classificação e contínuo para casos de regressão. Já as tarefas descritivas são divididas em: agrupamento de dados (do inglês *clustering*) onde os dados são combinados de acordo com alguma similaridade; e associação que consiste em determinar padrões frequentes de associações entre atributos de um conjunto de dados. Sabe-se que, quando se trata de risco de vida, os métodos de classificação automática aplicados à análise de ECG devem apresentar o mais alto nível de confiabilidade e consistência para serem ferramentas úteis. No entanto ainda se busca alcançar este resultado, apesar de um trabalho recente apresentar resultados de melhor acurácia do que quando comparados a interpretação de um médico cardiologista especialista, permitindo expectativas promissoras tal como mencionado em (Hannun et al., 2019). As aplicações em detecção e classificação de anomalias em resultados de ECG mantêm-se como um desafio, visto que existem dificuldades para automatizar a análise e

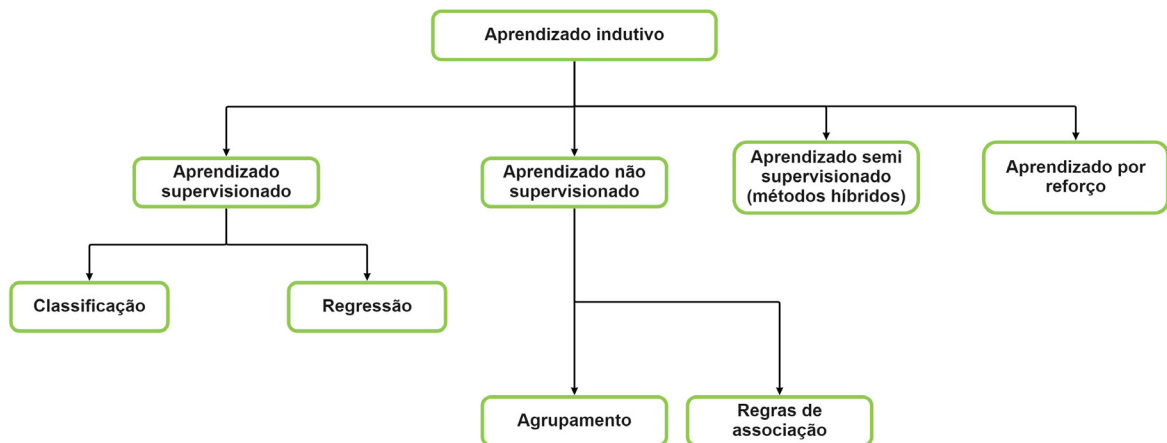


Figura 1.1: Diagrama de aprendizado.

compreensão dos sinais. Contudo, técnicas de ECG são usadas em diferentes situações na qual cada uma possui características específicas. Um contexto completamente diferente de um simples exame, por exemplo, é o monitoramento do paciente em uma sala de emergência, onde qualquer batimento cardíaco anormal deve ser reconhecido imediatamente. Em ambos os casos, a tarefa de interpretação de batimentos cardíacos deve ser automatizada, o que exige o desenvolvimento de classificadores altamente eficientes, baseados em métodos de reconhecimento de padrões e aprendizado de máquina.

Por volta das últimas duas décadas, a aplicação de técnicas de aprendizado de máquina para classificadores de análise automática de ECG vem recebendo uma forte atenção de pesquisas segundo (Jambukia et al., 2015; Berkaya et al., 2018) onde é possível encontrar abordagens de aprendizado profundo (do inglês *deep learning* DL), tem sido usado com sucesso para a detecção e classificação de sinais de ECG de forma automática. (Parvaneh et al., 2019) apresentaram abordagens de DL em detecção de arritmias cardíacas, (Ebrahimi et al., 2020) também demonstraram métodos recentes de DL aplicados ao sinal de ECG demonstrando que as Redes Neurais Convolucionais (do inglês *convolutional Neural Network*, CNN) tem sido uma abordagem de grande destaque para extração de característica e classificação. (Hong et al., 2020b) apresentaram diferentes arquiteturas de DL usadas em diversas tarefas de análise de ECG além de detecção de doenças cardíacas.

1.1 JUSTIFICATIVA

A OMS em seu relatório World Health Statistics 2008, entende que por volta de 2030 as principais causas de morte no mundo estarão relacionadas a doenças cardíacas uma vez que, neste relatório são apresentados o crescimento anual dos percentuais de óbitos de doenças cardíacas em relação a doenças de origem relacionadas a falta de infraestrutura, tal como saneamento básico (Organization, 2008). Recentemente a OMS em outro relatório (Organization, 2020) apresenta que as doenças cardíacas ainda permanecem como a principal causa de morte de forma global nos últimos 20 anos, visto que o número de mortes aumentou de 2 milhões a partir de 2000 para quase 9 milhões em 2019. Diante disso, as doenças cardíacas agora representam 16% do total de mortes por todas as causas. No entanto, Europa viu um declínio relativo nas doenças cardíacas, com mortes caindo 15% em 2019. Entretanto mais da metade dos 2 milhões de mortes adicionais ocorreram na região do Pacífico Ocidental (Organization, 2020).

Torna-se evidente a importância de recursos para auxiliar os profissionais da saúde a prevenir e diagnosticar mudanças de padrão nos batimentos cardíacos, tarefas estas que podem impactar na qualidade de vida do paciente. Dentre estes distúrbios no padrão dos batimentos cardíacos encontram-se as arritmias, que são capazes de serem identificadas por meio do eletrocardiograma. Entretanto as abordagens tradicionais de detecção de arritmia, incluindo a investigação manual dos registros de ECG, são demoradas e propensas a erros, além de serem, às vezes, subjetivas gerando uma dificuldade para os médicos e equipes médicas para distinguir os diferentes padrões de arritmias (Ponomariov et al., 2017; Association, 1997). Isso demonstra que existe a possibilidade de não se identificar qualquer doença cardíaca com 100% de precisão até o paciente ser submetido a outros exames, em que atividades que envolvem saúde geram um risco para a vida do paciente.

Contudo, atualmente cresce o número de técnicas para automatizar o reconhecimento e classificação de sinais de ECG, permitindo maneiras de classificar diversos tipos de arritmia, em contextos distintos, como no eletrocardiograma de longa duração, com a finalidade de registrar a atividade elétrica do coração continuamente para análise posterior, ou em unidades de terapias intensivas (UTI) e centro cirúrgicos exigem o monitoramento do paciente seja realizado em tempo real buscando que qualquer anomalia seja rapidamente identificada. Em ambos os contextos requerem uma análise automática e diagnósticos abrangentes de ritmos anormais no coração para uma atuação bem sucedida do médico especialista. Portanto, uma ferramenta capaz de auxiliar quanto a classificação de arritmias de forma automática, por meio do uso de técnicas de detecção de anomalias (Li e Boulanger, 2020) tem se demonstrado promissora no auxílio de diagnóstico e prevenção de anomalias no padrão do batimento cardíaco.

1.2 OBJETIVOS

A seguir, o objetivo geral dessa dissertação é abordado, seguido pela descrição dos objetivos específicos.

1.2.1 Objetivo geral

O objetivo geral dessa dissertação é comparar abordagens que utilizam aprendizado de máquina para detecção de anomalias em séries temporais com o intuito de classificar de forma automática arritmias cardíacas.

1.2.2 Objetivos específicos

Os objetivos específicos dessa dissertação são os seguintes:

- (a) Apresentar uma revisão sistemática da literatura relacionada à detecção automática em sinais de ECG;
- (b) Tratar sinais de artefatos musculares, movimento do eletrodo e ruído de flutuação da linha de base no ECG, estes considerados como ruídos;
- (c) Utilizar de abordagens de aprendizado não supervisionado como *Autoencoders* para o processamento e extração de características do sinal de ECG;
- (d) Aplicar o algoritmo para classificação do sinal utilizando técnicas de aprendizado de máquina ou aprendizado profundo nos sinais de ECG;

- (e) Empregar de métricas de validação como acurácia, precisão e sensibilidade para validar os resultados encontrados na detecção de anomalias no batimento cardíaco por meio do sinal de ECG de modo a compreender o desempenho do modelo;
- (f) Avaliar o modelo preditivo em duas bases de dados validado e público, disponível no banco de sinais de ECG Physionet; ¹
- (g) Avaliar os resultados obtidos utilizando as métricas de desempenho como acurácia, precisão e sensibilidade para comparação e discussão com trabalhos recentes da literatura relacionados a detecção automática de batimentos cardíacos.

1.3 METODOLOGIA DE PESQUISA

A metodologia de pesquisa segundo (Andrade Marconi e Lakatos, 2018) é um conjunto de atividades sistemáticas e racionais que possibilitam alcançar o objetivo - conhecimentos válidos e verdadeiros - buscando nortear um caminho a ser seguido, detectando erros e auxiliando as decisões do cientista. Quanto à natureza da pesquisa, optou-se neste projeto por um viés de pesquisa aplicada, na qual o objetivo é gerar conhecimentos úteis para o avanço da Ciência, com aplicação prática prevista, dirigidas à solução de problemas específicos. Para os objetivos, decidiu-se por uma pesquisa exploratória, pois este tipo de pesquisa busca proporcionar uma maior familiaridade com o problema a ser abordado, tornando-o mais evidente para a construção de hipóteses. Portanto, diferentes abordagens de aprendizado de máquina serão avaliadas visando a descoberta de possíveis soluções na utilização dos métodos propostos. Quanto à abordagem, esta pesquisa caracteriza-se por uma pesquisa de caráter qualitativo afim de apresentar os passos seguidos para a construção da abordagem proposta. Embora o estudo disponha caráter qualitativo, existe a possibilidade da utilização de um método quantitativo onde os resultados possibilitam uma discussão e comparação com o estado da arte encontrado na literatura. Tal encaminhamento da pesquisa permite um entendimento amplo no que tange ao entendimento da tecnologia abordada e o seu impacto dentro do contexto de classificação de batimentos cardíacos de forma automática.

Como finalidade, essa pesquisa visa estudar abordagens de processamento de sinais e também de inteligência artificial com foco em aprendizado de máquina e ou aprendizado profundo, aplicando-as em sinais de ECG. Além disso, uma pesquisa bibliográfica atualizada proporcionará um suporte aos métodos e validação das abordagens adotadas. A figura 1.2 apresenta a sequência metodológica proposta para esta pesquisa, em que o objetivo principal consiste no desenvolvimento de um classificador automático de arritmias cardíacas.

A etapa inicial consiste em uma revisão de literatura sobre ECG, processamento de sinais, aprendizado de máquinas e aprendizado profundo em que serão apresentados os principais conceitos sobre detecção de arritmias cardíacas de forma automática, além de apresentar uma discussão a respeito das abordagens utilizadas encontradas na literatura. Após a revisão será proposto um novo algoritmo obtido por meio de combinações de técnicas de pré-processamento de sinais para filtragem do sinal eliminando assim ruídos como artefatos musculares, movimento do eletrodo e ruído de flutuação da linha de base no ECG; e modelos de aprendizado profundo para extração características, reconhecimento de padrões e classificação. A seguir serão realizados testes buscando identificar padrões episódios sintomáticos de ritmo estimulado que caracteriza algumas patologias. Para avaliar se os resultados obtidos são satisfatórios de modo a apresentar o mais alto nível de confiabilidade e consistência, serão utilizadas de algumas métricas de validação

¹<https://physionet.org/content/mitdb/1.0.0/>

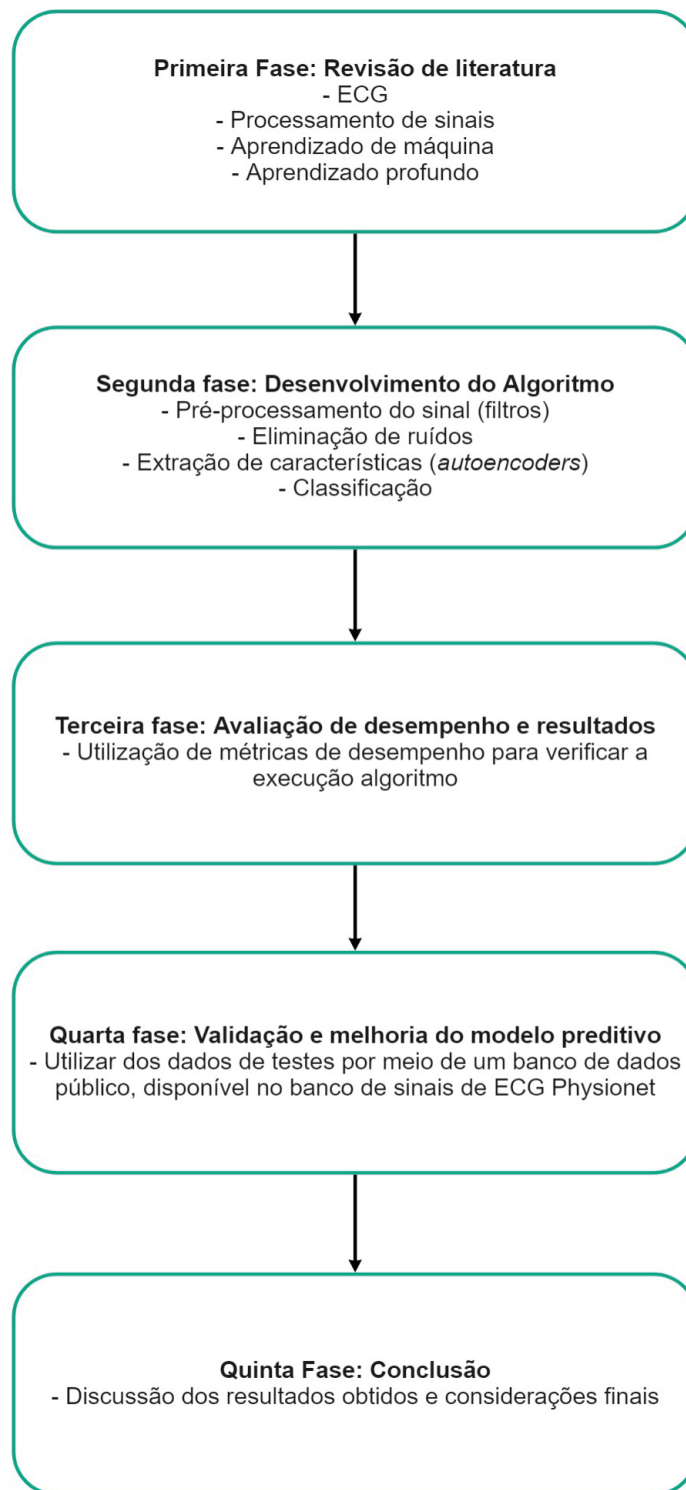


Figura 1.2: Sequência metodológica da pesquisa

buscando averiguar o desempenho dos resultados encontrados nas bases de dados consolidadas. Finalizando o trabalho será apresentada uma discussão dos resultados além de comparar com os resultados encontrados na literatura e as considerações finais.

1.4 ESTRUTURA DO DOCUMENTO

Esta dissertação está organizada em cinco capítulos. O Capítulo 1 introduziu o problema abordado, apresentando os objetivos, justificativa e a metodologia da pesquisa.

No Capítulo 2 são explicados os principais conceitos envolvidos no ECG, atividade elétrica do coração, arritmias cardíacas, assim como uma apresentação dos conceitos de redes neurais, redes de convolução, redes neurais recorrentes e *autoencoder* mais especificamente além de apresentar uma seção de revisão sistemática de literatura e trabalhos relacionados.

No Capítulo 3 é descrito como o algoritmo foi desenvolvido, os detalhes dos bancos de dados utilizados e os principais conceitos sobre avaliação de desempenho e as métricas utilizadas.

No Capítulo 4 os resultados obtidos e suas comparações são abordados. Finalmente, o Capítulo 5 apresenta a discussão dos resultados, as conclusões da dissertação e as propostas de pesquisa futura.

2 FUNDAMENTOS TEÓRICOS

Esta seção apresenta os temas fundamentais relacionados aos objetivos dessa dissertação, considerando o eletrocardiograma, redes neurais artificiais incluindo redes convolucionais e redes neurais recorrentes e codificadores automáticos (do inglês *autoencoder*, AE).

2.1 O ELETROCARDIOGRAMA (ECG)

O eletrocardiograma foi construído no século XIX do qual possibilitou o conhecimento de forma mais extensa a respeito do funcionamento do coração e das cardiopatias, sendo consolidado ao longo do tempo com aceitação no âmbito dos médicos (Giffoni e Torres, 2010).

A palavra eletrocardiograma é uma combinação de três palavras: eletro, que pertence a sinais elétricos; cardio, que se traduz como coração; e grama, que vem do grego, significando desenho, personagem, letra, sendo no presente parte fundamental em consultas cardiológicas e essencial para o diagnóstico de arritmias cardíacas (Najarian e Splinter, 2012).

O ECG então, é o registro das atividades elétricas produzidas pelo coração, medidas por meio de eletrodos colocados sobre a superfície corporal, representando a soma das atividades elétricas, conforme ilustrado na Figura 2.1, que ocorrem a cada instante do ciclo de um batimento cardíaco.

2.1.1 Atividade elétrica cardíaca

A eletrocardiografia surgiu e desenvolveu-se graças a pesquisadores ilustres que souberam captar o desenvolvimento da eletrofisiologia e de novas tecnologias na elaboração de uma ferramenta de diagnóstico relevante (Giffoni e Torres, 2010).

Einthoven pode ser considerado o pai da eletrocardiografia, já que seu galvanômetro de corda permitiu registros fidedignos e com a padronização empregada até hoje. O sucessor de Einthoven foi o estudioso das arritmias, Thomas Lewis, que também foi professor de Frank Wilson. As derivações unipolares desenvolvidas por Wilson permitiram o registro dos potenciais elétricos em qualquer parte do corpo. A eletrocardiografia também proporcionou o estabelecimento da teoria coronariana das síndromes anginosas e, posteriormente, novas aplicações clínicas, tais como os testes ergométricos, eletrofisiológicos, Holter e a eletrocardiografia de alta resolução (Giffoni e Torres, 2010).

O coração humano é um órgão formado por quatro cavidades ocas decompondo-se em segmentos. A cavidade superior é composta pelos átrios direito e esquerdo e a inferior pelos ventrículos esquerdo e direito. Este órgão tem o funcionamento de uma bomba fazendo com que o sangue percorra por dentro de uma rede de vasos sanguíneos, permitindo com que circule pelos demais órgãos do corpo humano, da qual esta atividade mecânica é um resultado de contrações organizadas dos átrios e ventrículos, gerado por impulsos elétricos. A fonte natural do estímulo elétrico tem como ponto de partida o nodo sinoatrial que se propaga pelos átrios, causando uma contração dessa região (despolarização atrial). Na sequência o estímulo é conduzido para nodo atrioventricular seguindo pelo feixe de *His* também conhecido como fascículo atrioventricular e seus ramos, chegando nas fibras de *Purkinje* e causando a contração dos ventrículos (despolarização ventricular). As estruturas envolvidas na condução produzem potenciais de ação que constitui-se de formas de onda durante cada ciclo cardíaco, conforme mostrado na Figura 2.1. A colaboração de cada potencial de ação ao longo do tempo estabelece

potenciais elétricos em diferentes pontos do corpo, na qual se destacam as atividades dos músculos atriais e ventriculares por representarem a maior parte do tecido cardíaco (Bronzino e Peterson, 2018).

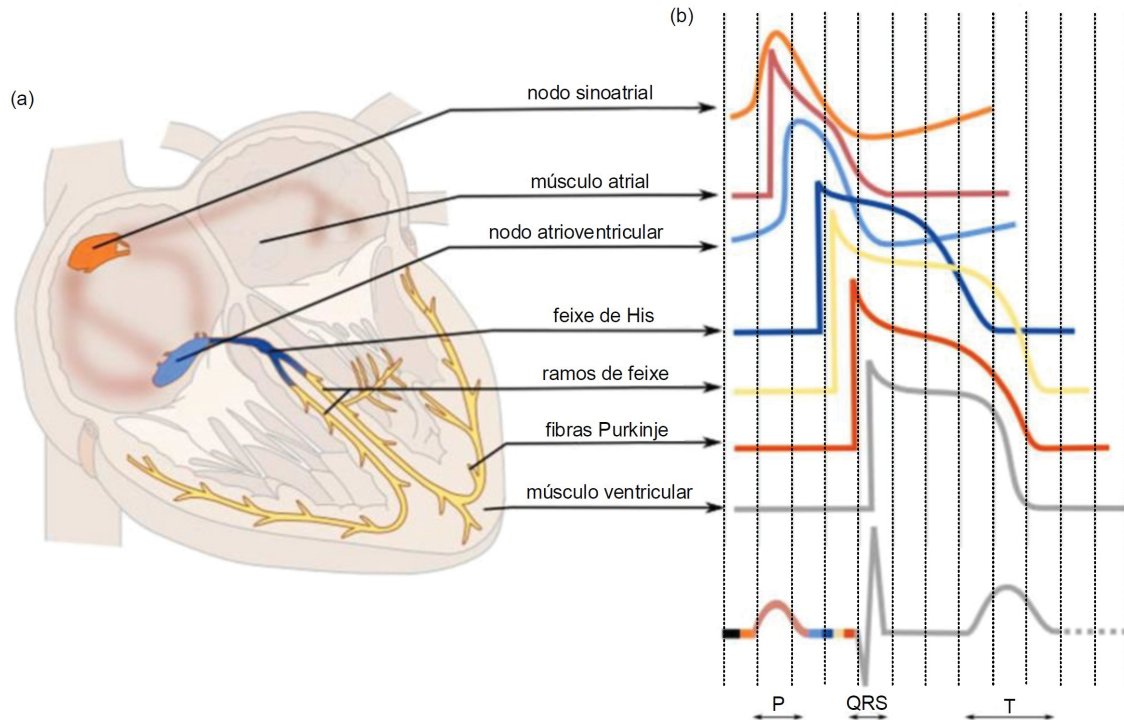


Figura 2.1: Ilustração dos Sistemas excitatório e condutor do coração (a) e morfologia típica dos "PA's" em cada tipo de estrutura (b).

Quando a estimulação elétrica percorre o coração, uma pequena fração da corrente de diferentes potenciais de ação atinge a superfície do corpo, resultando em diferenças de potencial em diferentes pontos do corpo que podem ser registradas por eletrodos aplicados na pele. Um ECG é um registro gráfico dessas diferenças de potencial ao longo do tempo, representando a atividade elétrica do coração, contendo as ondas P, Q, R, S e T, intervalos e segmentos, conforme mostrado na Figura 2.1 (b).

As ondas Q, R e S formam um parâmetro denominado complexo QRS geradas quando os ventrículos se despolarizam antes de sua contração, ou seja, enquanto a onda de despolarização se propaga pelos ventrículos. A onda P representa a contração atrial (despolarização), seguida pelo complexo QRS, que inclui a despolarização ventricular. Por fim, a onda T representa o relaxamento ventricular (repolarização), é produzida pelos potenciais gerados, enquanto os ventrículos se restabelecem do estado de despolarização (Mohrman e Heller, 2018).

2.1.2 As derivações eletrocardiográficas

Segundo (Webster, 2010) a derivação é uma unidade vetorial que define a direção que um vetor cardíaco com magnitude constante deve ter para gerar a tensão máxima em um par de eletrodos existindo assim, três modalidades convencionais: derivações dos membros ou bipolares; derivações dos membros aumentada e derivações dos membros aumentada e derivações precordiais no peito (Mond et al., 2016).

De acordo com (Hall e Guyton, 2011) as derivações bipolares ou de membros, conforme ilustrado na Figura 2.2, são conhecidas como "bipolares" que quer dizer que o ECG registrado

por meio de dois eletrodos posicionados nos membros de modo que tem-se três derivações bipolares padrão dos membros: derivação I, II, III.




Figura 2.2: Disposição das derivações I, II e III. O triângulo de Einthoven está sobreposto ao tórax (Hall e Guyton, 2011)

A derivação I corresponde ao terminal negativo do ECG conectado ao braço direito (do inglês *right arm*, RA), e o positivo, ao braço esquerdo (do inglês *left arm*, LA). Esta ordem faz com que se registre um valor positivo (valor acima da linha de voltagem zero do ECG) quando o potencial elétrico do braço direito (RA) for eletronegativo em relação ao braço esquerdo (LA) uma vez que, quando ocorre o oposto, o ECG registra valor situado abaixo da linha. Na derivação II, o terminal negativo do ECG é conectado ao braço direito (RA), e o positivo, neste caso quando o braço direito (RA) tem um potencial elétrico menor ao da perna esquerda (do inglês *left leg*, LL) exibe um registro positivo e quando ocorre o inverso ECG registra um valor negativo (abaixo da linha). A derivação III corresponde no terminal negativo do ECG conectado ao braço esquerdo (LA), e o positivo, à perna esquerda (LL). Com isso o ECG exibe um registro positivo quando o braço esquerdo (LA) estiver com potencial elétrico menor que a perna esquerda (LL). Contudo é possível identificar a derivação aplicando a lei de Einthoven sendo que, se os potenciais elétricos de duas derivações eletrocardiográficas bipolares dos membros são conhecidos, o potencial elétrico poderá ser determinado pela soma vetorial dos dois primeiros (Hall e Guyton, 2011). Portanto, a combinação das três derivações compõe o triângulo de Einthoven, conforme ilustrado na Figura 2.2. Na Figura 2.3 são ilustrados registros dos resultados de um ECG nas derivações



Figura 2.3: Exemplo de registro do eletrocardiograma nas derivações I, II e III (Hall e Guyton, 2011)

bipolares padrão dos membros (Hall e Guyton, 2011). É possível perceber que os registros das derivação são semelhantes entre si de modo que ambas apresentam as ondas P, T e o QRS positivo sendo possível analisar e verificar por meio da lei de Einthoven de modo que a soma dos potenciais da derivação I e III tende a ser igual ao potencial da derivação II (Hall e Guyton, 2011).

Nas derivações unipolares registra-se isoladamente, o potencial elétrico de uma região ou de um ponto. O potencial elétrico cardíaco é transmitido a cada um dos membros, na qual foram denominados de aVR (aumentada, tensão, braço direito), aVL (aumentada, tensão, braço esquerdo) e aVF (aumentada, tensão, pé esquerdo) na qual são medidas em relação ao Terminal Central de Wilson (TW), de modo que cada derivação mede o potencial elétrico de um ponto comum criado, unindo as outras duas ligações. Para aVR, a seta de referência agora aponta para o braço direito sendo uma deflexão negativa, enquanto que para aVL e aVF os desvios são geralmente positivos conforme ilustrado na Figura 2.4 na qual o ponto centro funcional de TW.

Por fim as derivações no peito, denominadas de precordiais, também são unipolares e os registros são obtidos por meio de seis posições no peito padronizados, (V_1 a V_6) (Mond et al., 2016) conforme ilustrado na Figura 2.5.

Sendo assim, o resultado do sinal que compõe o ECG é descrito por 12 derivações, conforme apresentado na Tabela 2.1, situados em locais padronizados dentro do corpo humano. Estas derivação são concebidas por derivações periféricas (três bipolares e três unipolares




Figura 2.4: Derivações dos membros aumentada.




Figura 2.5: Derivações no peito

realçadas) que usam extremidades superiores e inferiores como pontos de aquisição de potenciais para formar as derivações *I*, *II*, *III*, *aVR*, *aVL* e *aVF*, respectivamente, conforme ilustrado na Tabela 2.1 e pelas derivações torácicas anteriores monopolar (*V*₁ a *V*₆) das quais medem o potencial por meio de eletrodos localizados no tórax do indivíduo.

2.1.3 As características dos sinais de ECG

Há uma infinidade de métodos de reconhecimento baseados em ECG, cada um com seu próprio conjunto de vantagens e desvantagens. O objetivo das propriedades (características) do ECG é classificar um único indivíduo, aproveitando a variabilidade entre indivíduos. Sendo assim, um intervalo de tempo de onda de ECG ou a forma do batimento cardíaco podem ser utilizados

Tabela 2.1: Derivações eletrocardiográficas.

Autor	Descrição	Derivação
Eithoven (Hall e Guyton, 2011)	Bipolares	I = LA-RA II = LL-RA III = LL-LA
Frank Wilson (Hall e Guyton, 2011)	Unipolares precordiais	$V_1 = V_1 - (RA+LA+LL)/3$ $V_2 = V_2 - (RA+LA+LL)/3$ $V_3 = V_3 - (RA+LA+LL)/3$ $V_4 = V_4 - (RA+LA+LL)/3$ $V_5 = V_5 - (RA+LA+LL)/3$ $V_6 = V_6 - (RA+LA+LL)/3$
Emanuel Goldberg (Hall e Guyton, 2011)	Unipolares aumentadas	$aVR = RA - (LA+LL)/2$ $aVL = LA - (LL+RA)/2$ $aVF = LL(LA+RA)/2$

para estabelecer uma característica. Há uma série de fatores que dificultam a comparação dos métodos de análise de ECG em que os picos, limites, inclinações e outras características de uma onda servem como referências. Estas características são encontradas na literatura como temporal, amplitude, morfológica, autocorrelação, análise de fase do espaço e baseada em frequência (Odinaka et al., 2012; Hong et al., 2020b). A característica temporal trata-se do link entre as diferentes ondas em que o complexo QRS mencionado na seção 2.1 representa este link. A amplitude dos batimentos cardíacos de um indivíduo varia de uma pessoa para outra, e essa variabilidade é imediatamente reconhecida pelo indivíduo. É importante observar que, ao medir a característica de amplitude de uma onda de ECG, é comum compará-la com o pico R da onda. As características morfológicas do ECG são as que nos dizem como ele se parece como um todo, como intervalos específicos se encaixam (P-QRS-T). Para extrair informações morfológicas do pulso, pode-se simplesmente calcular a média dos valores observados de intervalos específicos (ex. QRS) ao longo de vários batimentos cardíacos alinhados (pico R). A autocorrelação é sensível a mudanças e chama a atenção para padrões não aleatórios. Isso é especialmente verdadeiro para o complexo QRS, que mantém uma grande quantidade de invariância de forma e largura de tempo. Os sinais de ECG podem ser definidos em espaço bi ou tridimensional usando a abordagem de atraso de tempo, dependendo da aplicação. Pela primeira vez, é possível identificar aspectos anteriormente desconhecidos da atividade do coração usando ECGs tridimensionais de derivação única com atraso de tempo (4-36ms) e amplitude normalizada. Usando um modelo preditivo linear, o conteúdo de frequência dos dados de ECG foi modelado (codificação preditiva linear). Os primeiros quarenta pontos da reconstrução linear do ECG são combinados com os primeiros quarenta pontos da reconstrução linear do ECG para criar o modelo de espectro para cada sujeito dado por 2.1 em que $x[n]$ é o valor atual

$$\hat{x}[n] = - \sum_{i=1}^p a_i x[n-1] \quad (2.1)$$

onde os coeficientes a_i são avaliados minimizando o erro $e[n]$

$$e[n] = x[n] - \hat{x}[n] \quad (2.2)$$

2.1.4 Arritmias cardíacas

As doenças do coração também conhecidas como cardiopatias indicam alguma alteração no coração de origem patológica, sendo capaz de causar ritmos cardíacos anormais (arritmias) podendo ser detectadas por meio de distúrbios da sua atividade elétrica. As arritmias são classificadas em taquiarritmias e bradiarritmias. Na primeira a frequência cardíaca pode ultrapassar 100 batimentos por minuto, enquanto nas bradiarritmias a frequência se encontra abaixo dos 60 batimentos por minuto. Contudo, uma arritmia pode acontecer de forma isolada de modo que o ritmo cardíaco pode estar regular durante o acontecimento. Segundo (Davies e Scott, 2014) diversas arritmias são provocadas por batimentos prematuros também denominados ectópicos em que apresenta alterações morfológicas no registro eletrocardiográfico. Este batimento é provocado por uma ativação elétrica anormal podendo ser originados na região dos átrios, na junção atrioventricular ou na região dos ventrículos.

São exemplos de arritmias o batimento atrial prematuro ocorrendo quando o sinal elétrico chega muito cedo ao coração derivando-se da região superior do coração (átrios), sendo considerados comuns em muitas pessoas saudáveis. No entanto, um batimento ventricular prematuro ocorre quando o sinal elétrico vem da região inferior do coração (ventrículos), sendo comuns entre pessoas idosas. A fibrilação atrial (FA) também é um tipo de arritmia cardíaca, ou batimento cardíaco anormal, provocada pela instabilidade dos sinais elétricos originados nos átrios. Ao longo desse distúrbio do ritmo, as contrações normais e coordenadas entre os átrios e os ventrículos são danificadas, intervindo no potencial do coração de bombear sangue com eficiência por todo o corpo.

As arritmias cardíacas podem causar morbidade e mortalidade. Por exemplo, a FA, como a arritmia mais comum, está associada ao aumento do risco de acidente vascular cerebral (Hindricks et al., 2020). Existem diversos mecanismos que parecem contribuir para a presença concomitante de FA dentre eles idades avançadas (Berry et al., 2004; Najarian e Splinter, 2012). Estas cardiopatias afetam mais de quatro milhões de pessoas nos Estados Unidos da América (EUA) gerando um custo de saúde que se torna um fardo econômico substancial (Tang et al., 2014). Segundo um relatório apresentado pelas Nações Unidas, o envelhecimento da população mundial deverá aumentar a cada dia e até 2030, a previsão é que o número de adultos com idade acima de 60 anos aumentará 56,00% de 901 milhões para 1,4 bilhão. Além disso, a população crescente entre 60 anos e acima foi estimada em 2,1 bilhões em 2050. Esse aumento na população idosa tem se apresentado como um desafio econômico e de saúde para o mundo (Nations, 2018; Acharya et al., 2017a), uma vez que o sistema cardiovascular humano torna-se sujeito a doenças e fica mais fraco à medida que a pessoa envelhece, assim também as artérias e a parede muscular do ventrículo esquerdo engrossam e encolhem com o envelhecimento, resultando na diminuição da complacência dos vasos sanguíneos das artérias (Chow et al., 2012; Berry et al., 2004).

Contudo, as doenças causadas por distúrbios do padrão de batimento cardíaco podem ser identificadas por eletrocardiograma (ECG) de modo que é uma etapa essencial para tarefas na prática clínica, porque o ECG é o teste não invasivo realizado com frequência para avaliar a condição do coração. Além disso, os dados de ECG podem ajudar no diagnóstico de doenças cardiovasculares, tais como contrações prematuras dos átrios (do inglês *premature contractions of the atria*, PAC) ou ventrículos (do inglês *premature contractions of the ventricles*, PVC), fibrilação atrial (FA), infarto do miocárdio (do inglês *do inglês myocardial infarction*, MI) e insuficiência cardíaca congestiva (do inglês *congestive heart failure*, CHF), (Hong et al., 2020a). Recentemente, pode-se observar o desenvolvimento de monitores de frequência cardíaca portáteis na medicina, como os monitores Holter (Nikolic et al., 1982), e vários dispositivos médicos vestíveis, tal como o *Apple Watch*. Portanto, a quantidade de dados de ECG que precisa ser analisada cresceu rapidamente e pode ser rastreada por cardiologistas humanos. Portanto, a

análise automática e precisa dos dados de ECG se tornou um tema importante de pesquisa utilizando abordagens de aprendizado de máquina, ademais, muitos aplicativos emergentes podem ser implementados com base em dados de ECG, incluindo identificação biométrica e estadiamento do sono.

2.1.5 Base de dados de ECG

A base de dados de arritmia do Instituto de Tecnologia de Massachusetts no laboratório (do inglês *Boston's Beth Israel Hospital*, MIT-BIH) (Moody e Mark, 2001) consiste em 48 registros de ECG de meia hora de 47 indivíduos no Hospital Beth Israel de Boston. Cada sequência de dados de ECG tem uma resolução de 11 bits em uma faixa de 10 mV com uma frequência de amostragem de 360 Hz, sendo constituído por duas derivações, representados em canal 1 e 2 de acordo com a Tabela 2.2, de modo que a primeira uma derivação modificada MLII e a outra uma das derivações modificadas V_1 , V_2 , V_4 ou V_5 (Goldberger et al., 2000). Os rótulos dos batimentos foram anotados de forma independente por vários cardiologistas, da qual o consenso resolveu as diferenças nos diagnósticos em nível de batida e de ritmo.

Tabela 2.2: Tipos de derivações e agrupamento de registros do banco de dados de arritmias do MIT-BIH

Canal 1	MLII	MLII	MLII	V_5	V_5	MLII
Canal 2	V_2	V_4	V_5	V_2	MLII	V_1
						101 105 106 107 108 109
						111 112 113 115 116 118
						119 121 122 200 201 202
IDs dos pacientes	103	124	100	102	114	203 205 207 208 209 210
	117		123	104		212 213 214 215 217 219
						220 221 222 223 228 230
						231 232 233 234

De acordo com as diretrizes da Associação para o Avanço da Instrumentação Médica (AAMI, do inglês *Association for the Advancement of Medical Instrumentation*), estabelece-se cinco classes clinicamente pertinentes sendo N (Normal), S (batimento ectópico supraventricular), V (batimento ectópico ventricular), F (batimento de fusão entre um normal e um ectópico ventricular) e Q (batimento não classificado). Considerando que as amostras correspondentes à base de dados do MIT-BIH representam rótulos detalhados, um mapeamento destas classes para as classes de batimentos cardíacos estabelecidas pela AAMI é apresentado na Tabela 2.3.

De acordo com (De Chazal et al., 2004) adota-se o conjunto de dados DS_1 para treinamento e o DS_2 para teste, sendo este padrão empregado em diversos trabalhos posteriores conforme apresentado na Tabela 2.4. A AAMII recomenda excluir registros que apresentem pulsos provenientes de fontes artificiais como o de marcapasso presente nos sinais 102, 104, 107 e 217, contudo todos os 44 registros restantes com exceção daqueles produzidos artificialmente são geralmente utilizados em trabalhos envolvendo classificação de arritmias.

2.2 APRENDIZADO DE MÁQUINA

O aprendizado de máquina é um tipo de inteligência artificial que permite aprimorar o desempenho na execução de alguma tarefa por meio da experiência, sem qualquer assistência humana, analisa dados e descobre padrões. Quando um padrão definido por dados ou um conjunto de regras é usado para executar uma ação, o aprendizado de máquina pode automatizar

Tabela 2.3: Mapeamento das classes da base MIT-BIH para as classes AAMI

AAMI	MIT-BIH	Descrição
N <i>Batimento Normal</i>	N	Batimento normal
	L	Bloqueio do ramo esquerdo
	R	Bloqueio do ramo direito
	e	Batimento de escape atrial
	j	Batimento do escape nodal (juncional)
S <i>Batimento ectópico supraventricular</i>	A	Batimento atrial prematuro
	a	Batimento atrial prematuro aberrante
	J	Batimento nodal (juncional) prematuro
	S	Batimento supraventricular prematuro
V <i>Batimento ectópico Ventricular</i>	V	Contração ventricular prematura
	E	Batimento de escape ventricular
F <i>Batimento de Fusão</i>	F	Batimento de fusão normal e ventricular
Q <i>Batimento desconhecido</i>	P ou /	Batimentos cardíacos com marcapasso
	f	Fusão de batimentos normais com marcapasso
	U	Batimentos não classificados

Tabela 2.4: Organização da base de dados segundo a AAMI

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

praticamente qualquer operação que possa ser realizada. Desta forma para prever valores de saída futuros, os algoritmos de aprendizado de máquina usam dados históricos como entrada sendo uma técnica amplamente empregada em tais mecanismos como: sistemas de recomendação, detecção de fraude, filtragem de spam, detecção de ameaças de *malware*, automação de processos de negócios e manutenção preditiva, sendo estes apenas algumas das aplicações comumente usadas.

O diagnóstico de doenças cardiovasculares depende fundamentalmente da classificação precisa dos sinais do ECG. Entretanto, a categorização do ECG com precisão é um tema desafiador que a ser abordado. A fim de diagnosticar anormalidades cardíacas e determinar as opções de tratamento de um paciente, é necessário fazer um diagnóstico precoce e correto dos vários tipos de arritmia. A classificação de ECG pode ser realizada por meio de vários classificadores, com redes neurais artificiais se tornando um classificador popular e amplamente utilizado para categorização de ECG durante os últimos anos (Jambukia et al., 2015).

Quando o coração bate, o eletrocardiograma (ECG) registra a atividade elétrica, visto que as ondas A P, QRS e T mencionadas na seção 2.1.1 são todas registradas descrevendo assim o ciclo de um batimento cardíaco tal que, a extração e segmentação das características dessas ondas (sinal do ECG) são críticas na detecção da grande maioria dos distúrbios cardíacos (Roopa e Harish, 2017). No entanto técnicas de pré-processamento, bancos de dados de ECG, técnicas de extração de recursos, classificadores e medidas de desempenho estão recebendo uma forte atenção de pesquisas segundo (Jambukia et al., 2015; Berkaya et al., 2018) conforme ilustrado na Figura 2.6.




Figura 2.6: Diagrama do fluxo de tratativa dos dados e classificação.

No pré-processamento, o sinal é filtrado para reduzir ruídos e formas de onda indesejadas, para isso têm se utilizado ferramentas matemáticas de processamento de sinais. Em seguida, técnicas de extração de características permitem com que o classificador se concentre apenas em informações importantes presentes nos sinais. Por fim, a função de classificação processa as características extraídas do batimento cardíaco do paciente, produzindo um classificador treinado a agrupar os batimentos cardíacos de acordo com suas características. Tradicionalmente, a análise automática de ECG confia nas regras de ouro do diagnóstico. Conforme mostrado na Figura 2.7, este é um método de dois estágios que requer especialistas humanos para projetar recursos úteis com base em dados de ECG brutos, que são referidos como "recursos especializados" e, em seguida, implantar regras de decisão ou outros métodos de aprendizado de máquina para gerar resultados finais.

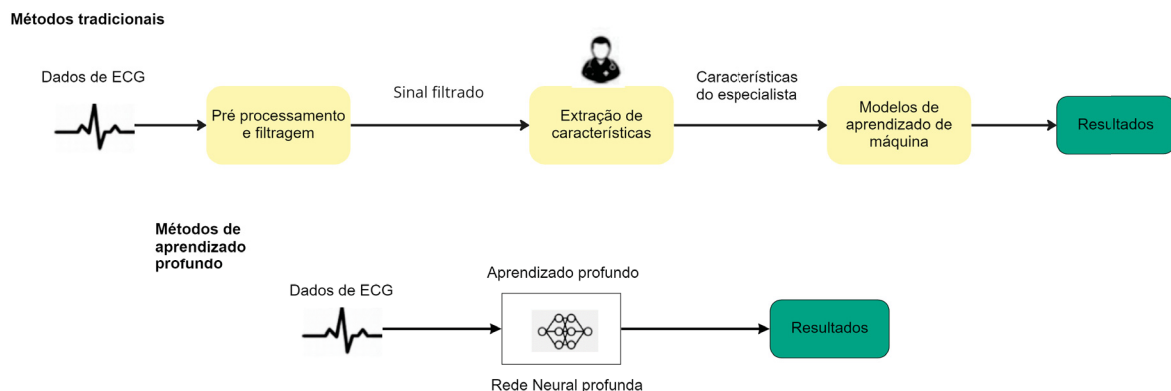


Figura 2.7: Comparação entre métodos tradicionais e aprendizado profundo

A extração de características por especialistas pode ser classificada em características estatísticas tais como (variabilidade da frequência cardíaca (Camm et al., 1996), entropia da amostra (Alcaraz et al., 2010) e coeficientes de variação e histogramas de densidade (Tateno e Glass, 2001)), e características no domínio da frequência (Romero e Serrano, 2001; Lin, 2008). Atualmente técnicas de aprendizagem de máquinas têm sido empregadas para extração de características abordando um método conhecido como "aprendizagem de características". No entanto, estas abordagens ainda são limitados pela qualidade dos dados e conhecimento especializado humano (Guglin e Thatai, 2006; Shah e Rubin, 2007; Schläpfer e Wellens, 2017). De modo a resolver a necessidade do conhecimento especializado humano tem se empregado técnicas de aprendizado profundo em que tem-se demonstrado promissor para lidar com problemas de extração de características e classificação (Siontis et al., 2021).

2.3 REDES NEURAIS ARTIFICIAIS

O conexionismo é um conjunto de técnicas utilizadas em diversos campos, como a inteligência artificial, para modelar os fenômenos biológicos como o das redes neurais naturais. Uma rede neural artificial (RNA) é uma abordagem conexionista amplamente utilizada atualmente, inspirada nos neurônios do cérebro humano. As características que evidenciam as RNAs são o número de elementos computacionais, denominados de neurônios, a função de ativação aplicada em cada neurônio, a forma como os neurônios são conectados (topologia) e o algoritmo usado para o treinamento da RNA. Em um ambiente computacional, o modelo é implementado por meio da interligação de módulos, treinados para representar o conhecimento. Logo as RNAs são compostas por modelos matemáticos que permitem realizar reconhecimento de padrões, controle de sistemas, extração de características e classificação complexa, consistindo de um sistema da qual abrange pequenos módulos interconectados que processam valores de entrada, inspirados no comportamento de redes neurais biológicas. Quando houver informações sobre o padrão de entrada, eles passarão por um treinamento denominado supervisão ou aprendizado supervisionado, e quando não houver conhecimento prévio sobre a categoria a ser classificada, eles passarão por um treinamento denominado não-supervisionado ou aprendizado não-supervisionado. Contudo antes de apresentar as RNAs, torna-se adequado descrever o neurônio artificial, que apresenta uma estrutura formada por valores de entrada, pesos que ponderam os valores de entrada e a função de ativação, conforme ilustrado na Figura 2.8

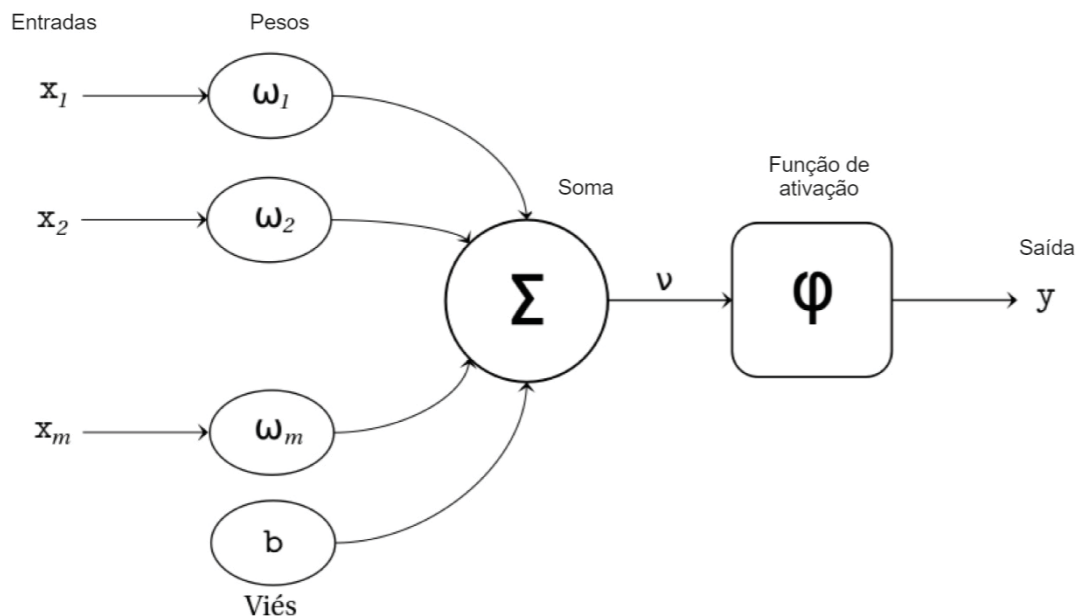


Figura 2.8: Modelo de um neurônio artificial

O neurônio artificial pode ser descrito em termos matemáticos de acordo com a Equação 2.3 em que y consiste na saída do neurônio, $\omega_1, \omega_2, \dots, \omega_m$ pertencem aos pesos do neurônio e x_1, x_2, \dots, x_m , são referentes aos sinais de entrada, b faz-se o bias e φ como função de ativação, diante disso, esse modelo torna-se a base para a construção de uma grande família de RNA (Haykin, 2009).

$$y = \varphi \left(\sum_{i=1}^n \omega_i x_i + b \right) \quad (2.3)$$

Funções de ativação acrescentam propriedades não-lineares em redes neurais além de restringir a amplitude de saída do neurônio, com o objetivo de transformar o sinal oriundo de uma soma ponderada dos pesos e suas respectivas entradas em um sinal de saída. Existem diversos tipos de funções de ativações na literatura, contudo as funções de ativação mais usadas são as funções sigmoide e unidades lineares retificadas (do inglês *Rectified Linear Unit*, ReLU), dadas por

$$y = \frac{1}{1 + e^{-m}} \quad (2.4)$$

$$y = \max(0, m) \quad (2.5)$$

respectivamente da qual m representa a soma ponderada das entradas, por meio de $(\sum_{i=1}^n \omega_i x_i + b)$.

Diante disso esta seção apresenta redes neurais de múltiplas camadas e posteriormente as redes profundas.

2.3.1 Redes neurais multicamadas

Em uma rede neural artificial, os neurônios são organizados em camadas conforme demonstrado na Figura 2.9 que demonstra uma rede neural simples, também conhecida como rede perceptron multicamada (do inglês *Multilayer perceptron*, MLP). Pode-se observar que, como as entradas multicanais são fornecidas ao modelo sob a forma de um vetor de dimensão d , sendo composta por uma camada de entrada de modo que cada neurônio projeta sua saída aos demais neurônios da camada seguinte, uma vez que os nós representam as entradas. A camada seguinte, denominada como camadas ocultas e, em seguida, tem-se uma última camada denominada de camada de saída. Essa rede neural é denominada de totalmente conectada (do inglês *fully connected*) visto que possui uma conexão de cada nó em cada camada para todos os outros nós nas camadas adjacentes.

As MLPs possuem um poder computacional maior do que aquele apresentado por redes sem a camada oculta. Ao contrário destas redes mais simples, as MLPs podem resolver problemas que não são linearmente separáveis. Redes com mais de duas camadas intermediárias têm a capacidade de resolver qualquer problema de mapeamento, seja ele linearmente separável ou não, desde que devidamente ajustada.

As RNAs que apresentam conectividades com os neurônios sem apresentar laços ou ciclos, como ilustrado na Figura 2.9, são consideradas como redes de alimentação direta (do inglês *feedforward*), contudo, existem diversos outros padrões de ligação entre os neurônios denominado arquiteturas, na qual inclui redes mais profundas formadas de múltiplas camadas escondidas, como o caso das redes de convoluções e as redes recorrentes que serão apresentadas posteriormente.

Uma rede MLP passa por um treinamento de forma supervisionada de modo que a rede é sistematicamente apresentada a um conjunto de dados contendo os padrões de entrada categorizados, denominados dados de treino. Em seguida, a rede é submetida a um novo padrão de entrada que contém da mesma distribuição dos dados de treino, denominado conjunto de teste, e assim o sinal de saída é atribuído a uma determinada classe. Partindo desse pressuposto o aprendizado supervisionado utiliza a resposta desejada para realizar um mapeamento específico de entrada-saída que minimiza uma função de interesse chamada de função de custo, ilustrada na equação 2.6,




Figura 2.9: Estrutura de uma MLP com uma única camada oculta

$$f(m, b) = \frac{1}{n} \sum_{i=1}^n (y_i - (mx_i + b))^2 \quad (2.6)$$

onde n representa o número de amostras. As funções de custo empregadas incluem entropia cruzada e o erro quadrático médio. A entropia cruzada mede a quantidade média de informação transmitida de uma distribuição de probabilidade (a "verdadeira" distribuição) para outra (a distribuição prevista pelo modelo) para descrever a mesma sequência de eventos, de modo a medir quão bem o modelo de aprendizado de máquina está prevendo a distribuição verdadeira conforme ilustrado na equação 2.7,

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (2.7)$$

onde $p(x)$ é a distribuição verdadeira, $q(x)$ é a distribuição prevista pelo modelo e x é a variável aleatória. O erro quadrado médio que mede a média dos erros ao quadrado entre os valores previstos e os valores reais conforme ilustrado na equação 2.8.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2.8)$$

O desempenho do aprendizado depende da disponibilidade de exemplos rotulados representando a distribuição dos dados de interesse, em que cada exemplo consiste no sinal de entrada e seu rótulo correspondente. Os parâmetros da rede são ajustados de acordo com o sinal de erro, definido como a diferença entre a resposta desejada e a resposta fornecida pela rede. Para isso o algoritmo da retro-propagação do erro (do inglês, *error backpropagation*) (Russell e Norvig, 2010) é utilizado para minimizar a função de custo, tal que emprega um método denominado descida de encosta em lote (do inglês *batch gradient descent*), a fim de atualizar os

pesos da rede, no qual o algoritmo segue a direção inversa para computar os gradientes de pesos em relação a função de custo. A equação 2.9 mostra a regra com a finalidade de atualizar os pesos da rede no instante i

$$\omega_{i+1} = \omega_i - \gamma \nabla H(\omega_i) \quad (2.9)$$

tal que γ é a taxa de aprendizado (do inglês *learning rate*), que define o tamanho do passo que é dado em cada iteração, ou seja, é um valor que tenta controlar a convergência da rede delimitando passos a serem incluídos pelo algoritmo de retro-propagação do erro, ω vetor de pesos (ou parâmetros) do modelo e $\nabla H(\omega_i)$ são as derivadas parciais (gradiente) da função de custo H em relação aos pesos/parâmetros ω (Ruder, 2016).

Este ajuste é realizado iterativamente minimizando o resultado da função escolhida, de forma a diminuir a distância entre a resposta da rede e a resposta desejada.

2.4 APRENDIZADO PROFUNDO

O aprendizado profundo (do inglês *deep learning*), é um ramo do aprendizado de máquina na qual os algoritmos empregam representações de autoaprendizagem, utilizando de redes neurais artificiais, mencionado na seção 2.3, a fim de imitar a maneira como o cérebro processa as informações. No entanto, o aprendizado profundo nada mais é do que muitos classificadores trabalhando juntos, que são baseados em regressão linear seguida por algumas funções de ativação. Sua base é a mesma da abordagem de regressão linear estatística tradicional $W^T X + b$. A única diferença é que existem muitos nós neurais no aprendizado profundo, em vez de apenas um nó, que é denominado de regressão linear no aprendizado estatístico tradicional. Outro ponto contrastante que precisa ser notado é que no aprendizado profundo existem muitas camadas entre a entrada e a saída. Uma camada pode ter muitas centenas ou mesmo milhares de unidades neurais conforme mencionado na seção 2.3.1. A desvantagem dos classificadores tradicionais de aprendizado de máquina é a necessidade de escrever uma hipótese complexa de forma manual, enquanto na rede neural profunda, ela é gerada pela própria rede, o que a torna uma ferramenta poderosa para aprender relações não lineares de forma eficaz.

Contudo, os métodos de aprendizado profundo têm apresentado resultados promissores em muitas áreas de aplicação, tais como processamento de linguagem natural, visão computacional e reconhecimento de fala (LeCun et al., 2015; Dong et al., 2021). Uma das principais vantagens dos métodos de aprendizado profundo é que não se precisa de especialistas para executar etapas explícitas de extração de características, conforme mostrado na Figura 2.7, além do que extraem recursos de forma automática e implícita com base nas poderosas funções de aprendizagem do modelo de aprendizado.

Alguns estudos provaram por meio de experimentos que, para dados de ECG, os recursos de aprendizado profundo são mais informativos do que os recursos especializados em (Hong et al., 2017, 2019b). Em muitas tarefas de análise de ECG, como detecção de doenças (Clifford et al., 2017) e testes de sono (Ghassemi et al., 2018), o desempenho dos métodos de aprendizado profundo tem apresentado melhor resultado em relação aos métodos clássicos de aprendizado de máquina, da qual contam com o processamento dos dados e extração de características de forma manual.

Diante disso esta seção apresenta redes convolucionais, as redes recorrentes e *autoencoders* assim permitindo explorar de uma forma de aprendizado não supervisionado.

2.4.1 Redes neurais convolucionais

Redes neurais profundas têm sido usadas em muitos campos nos últimos anos. A rede neural convolucional, considerada uma variante da rede neural clássica, constituindo-se de uma ou mais camadas de convolução e de agrupamento (do inglês *pooling*), seguida por uma ou mais camadas totalmente conectadas. Os dados de entrada podem ser unidimensionais (sinais temporais), bidimensionais (imagens com um canal) ou tridimensionais (imagens com dois ou mais canais), resultando em uma rede neural convolucional (do inglês *convolutional Neural Network*, CNN) 1D, 2D ou 3D, respectivamente (Gu et al., 2018). A Figura 2.10 ilustra a arquitetura de uma CNN composta pela camada de entrada, uma camada de convolução, uma de agrupamento, outra camada de convolução seguida uma camada de agrupamento e por fim, duas camadas totalmente conectadas.




Figura 2.10: Arquitetura de uma rede convolucional

2.4.1.1 Camada de convolução

A primeira camada em uma CNN é denominada de camada convolucional e representa um componente chave da arquitetura. Considere a entrada desta camada como uma imagem I com uma ou mais matrizes 2D, onde as conexões em pequenas regiões locais são feitas por meio de filtros F , e a saída consiste em uma ou mais matrizes M em 2D. Este processo, às vezes denominado de mapa de características, de acordo com a equação 2.10 tal que M_{ij}^n denota a saída da $(i$ -ésima, j -ésima) unidade no n -ésimo mapa de atributos, σ é a função de ativação neural não-linear aplicada após cada convolução, $I(i-k; j-l)$ denota o $((i-k)$ -ésimo, $(j-l)$ -ésimo) pixel da imagem de entrada e $F^n(k, l)$ representa o $(k$ -ésimo, l -ésimo) pixel do n -ésimo filtro de convolução (Goodfellow et al., 2016) tal que

$$M_{ij}^n = \sigma\left(\sum_k \sum_j I(i-k, j-l) F^n(k, l)\right) \quad (2.10)$$

a Figura 2.11 apresenta o resultado da convolução de um filtro 3 x 3 a uma imagem 5 x 5 que constituída por um canal. É possível observar no exemplo, o preenchimento com zeros (do

inglês *zero padding*) é igual a zero, isto é, nenhum zero é adicionado às bordas da imagem, e o movimento do filtro é feito com saltos unitários, resultando em um salto (do inglês *stride*) de uma unidade. Durante o processo de convolução, cada filtro gera um mapa de atributos correspondente, o que reduz bastante o número de parâmetros CNN dado que o tamanho do filtro é relativamente pequeno em comparação com o tamanho da matriz de entrada.

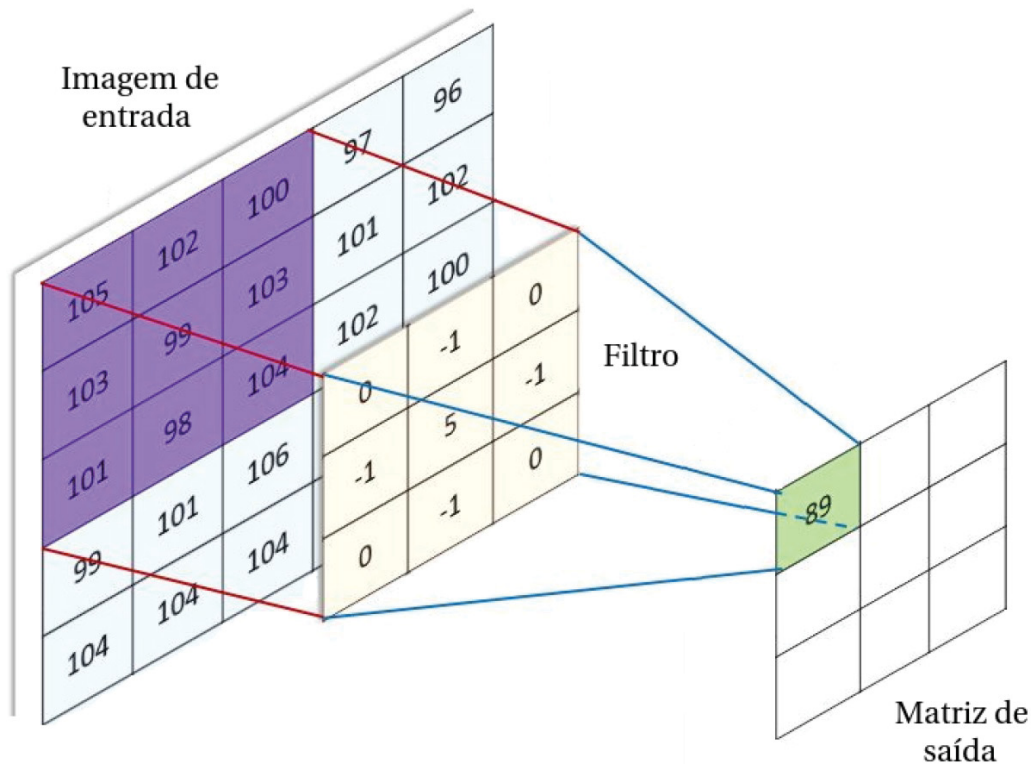


Figura 2.11: Ilustração de uma operação de convolução

2.4.1.2 Camada de agrupamento

Semelhante à Camada Convolutiva, a camada de agrupamento (do inglês, *Pooling layers*) é responsável por reduzir o tamanho espacial do Recurso Convolutivo (Gu et al., 2018). Isso é para diminuir o poder computacional necessário para processar os dados através da redução de dimensionalidade. Além disso, é útil para extrair características dominantes, mantendo assim o processo de treinamento efetivo do modelo. Existem dois tipos de agrupamento: Agrupamento Máximo (do inglês *Max pooling*) e Agrupamento Médio (do inglês *Average Pooling*) conforme a Figura 2.12. O agrupamento máximo retorna o valor máximo da parte da imagem coberta pelo Kernel (filtro) além de funcionar como um supressor de ruído, descartando completamente as ativações ruidosas (Ajit et al., 2020). Também realiza eliminação de ruído (do inglês *de-noising*) juntamente com redução de dimensionalidade. Por outro lado, o agrupamento médio retorna a média de todos os valores da parte da imagem coberta pelo Kernel, além disso cumpre simplesmente a redução de dimensionalidade como um mecanismo de supressão de ruído (Albawi et al., 2017). Portanto, pode-se dizer que o agrupamento máximo tem um desempenho muito melhor do que o agrupamento médio.

A Camada Convolutiva e a Camada de agrupamento, juntas, formam a i -ésima camada de uma Rede Neural Convolutiva. Dependendo das complexidades das imagens, o número de

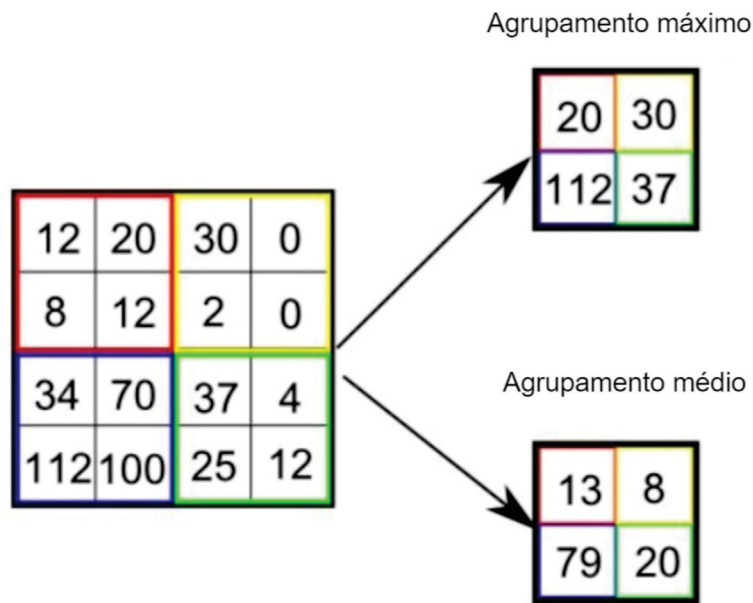


Figura 2.12: Tipos de agrupamento

tais camadas pode ser aumentado para capturar ainda mais detalhes de baixo nível, mas ao custo de mais poder computacional. Depois de passar pelas camadas convolucionais e de agrupamento, o modelo aprendeu com sucesso de modo a entender as características da imagem. Na sequência, para fins de classificação a saída final é nivelada e passa a alimentar uma rede neural regular (Ajit et al., 2020).

2.4.1.3 Camada totalmente conectada

Essa camada é representada por neurônios totalmente conectados a todas as ativações da camada anterior, como nas redes neurais tradicionais. Normalmente sucede as camadas de convolução e agrupamento, podendo representar uma ou mais camadas escondidas, além de incluir a camada de saída (Ajit et al., 2020). A Figura 2.10 ilustra uma arquitetura de uma rede neural de convolução que apresenta uma camada de entrada simulando uma imagem de 28 x 28 pixels, duas camadas de convolução com filtros 5 x 5 produzindo mapas de atributos de 24 x 24, duas camadas de agrupamento 2 x 2 gerando mapas de atributos de 12 x 12 e 8 x 8 respectivamente. A saída achatada é alimentada a uma camada total conectada da qual retropropagação é aplicada a cada iteração de treinamento e, uma camada totalmente conectada como saída com n neurônios, onde n é o número de classes.

2.4.2 Redes neurais recorrentes

A arquitetura de redes neurais recorrente (do inglês *Recurrent Neural Network*, RNN) recentemente tem sido uma arquitetura altamente preferida, especialmente para dados sequenciais de modo que, esta arquitetura tem sido aplicada com sucesso em muitos problemas, como

processamento de linguagem natural (Mikolov e Zweig, 2012), reconhecimento de fala (Graves et al., 2013), geração de descrições de imagens (Karpathy e Fei-Fei, 2015) e tradução automática (Kalchbrenner e Blunsom, 2013). Ao contrário das estruturas de redes neurais *feedforward*, a RNN possui uma estrutura de aprendizado na qual todas as entradas e saídas são conectadas umas às outras. Uma diferença entre o RNN e a estrutura das redes de alimentação direta clássica é que as saídas dos neurônios são aplicadas recursivamente às suas próprias entradas. As RNNs são denominadas de recorrentes porque repetem as mesmas tarefas para todos os itens de um índice, dependendo da saída anterior. Essa estrutura de conexão recorrente foi descrita pela primeira vez por (Hopfield, 1982). Em um trabalho posterior (Jordan, 1997), foi introduzido um modelo no qual conexões repetidas foram usadas para trazer as redes para a memória dinâmica, em que apresentou os resultados para o problema de Ou exclusivo (XOR), em que trata-se de uma operação lógica entre dois operandos, e o valor lógico é verdadeiro se e somente se os dois operandos são diferentes (ou seja, um é verdadeiro e o outro é falso). Esta estrutura de rede foi desenvolvida por (Elman, 1990) para o problema de processamento de linguagem natural. A Figura 2.13 mostra as representações básicas dos modelos de RNN mencionados.

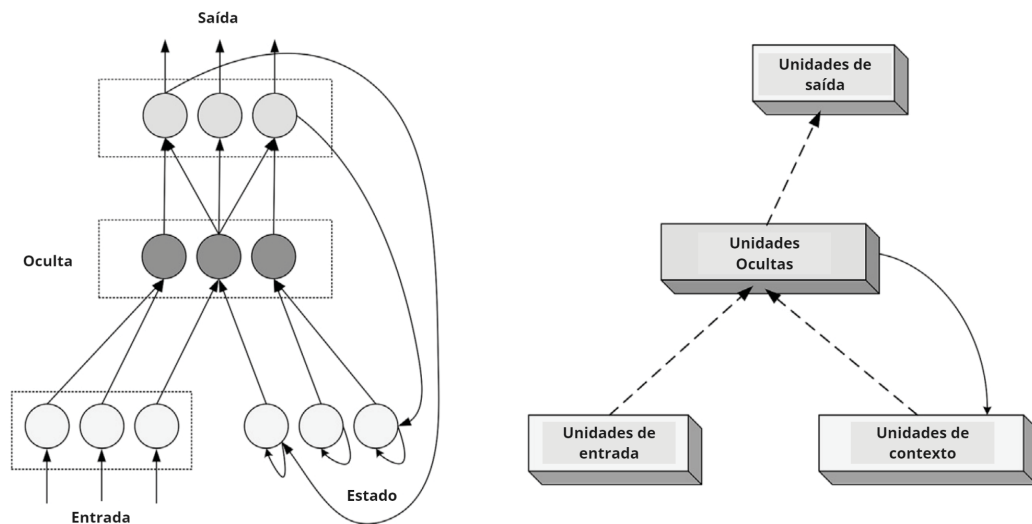


Figura 2.13: Representação básica de modelos RNN usados por Jordan (esquerda) e Elman (direita)

As RNNs têm desvantagens decorrentes do conjunto limitado de informações contextuais e da incapacidade de propagação de tempo de retorno para funcionar corretamente. Devido à natureza iterativa de RNNs padrão, problemas de explosão e desaparecimento de gradientes são frequentemente encontrados. Hochreiter e Schmidhuber (1997) propuseram uma memória de longo prazo (do inglês *Long Short Term Memory*) para superar essas limitações, em que esta arquitetura comparado com o RNN tradicional, apresentou melhores resultados na tarefa de capturar dependências de longo prazo e evitar o problema de desaparecimento de gradientes. Nos LSTMs, cada nó tradicional na camada oculta é substituído por células de memória, sendo esse recurso a principal diferença em relação as RNNs padrão.

2.4.2.1 Memória de curto e longo prazo (*Long-short term memory*)

O tipo mais utilizado de arquitetura RNN são as LSTMs, da qual são estruturas especiais possuindo sua formação em blocos de memória e células de memória, juntamente com as unidades de porta que elas contêm (Olah e Carter, 2016; Tsantekidis et al., 2022). As unidades de portas de entrada multiplicativas são usadas para evitar os efeitos negativos que as entradas

não relacionadas podem criar de modo a controlar o fluxo de entrada para a célula de memória e, a porta de saída controlar o fluxo de saída da célula de memória para outros blocos LSTM. A porta de esquecimento na estrutura do bloco de memória, conforme apresentado na Figura 2.14, é controlado por uma rede neural simples de uma camada. A ativação desta porta é calculada pela Equação 2.11

$$f_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_f) \quad (2.11)$$

onde x_t é a sequência de entrada, h_{t-1} é a saída do bloco anterior, C_{t-1} é a memória do bloco LSTM anterior e b_f é o vetor de polarização. W representa vetores de peso separados para cada entrada e σ é a função sigmoide logística. A função de ativação sigmoide, sendo a saída da porta de esquecimento, é aplicada ao bloco de memória anterior por multiplicação por elemento. Assim, determina-se até que ponto o bloco de memória anterior será efetivo no LSTM atual. Se o vetor de saída de ativação contiver valores próximos de zero, a memória anterior será esquecida.

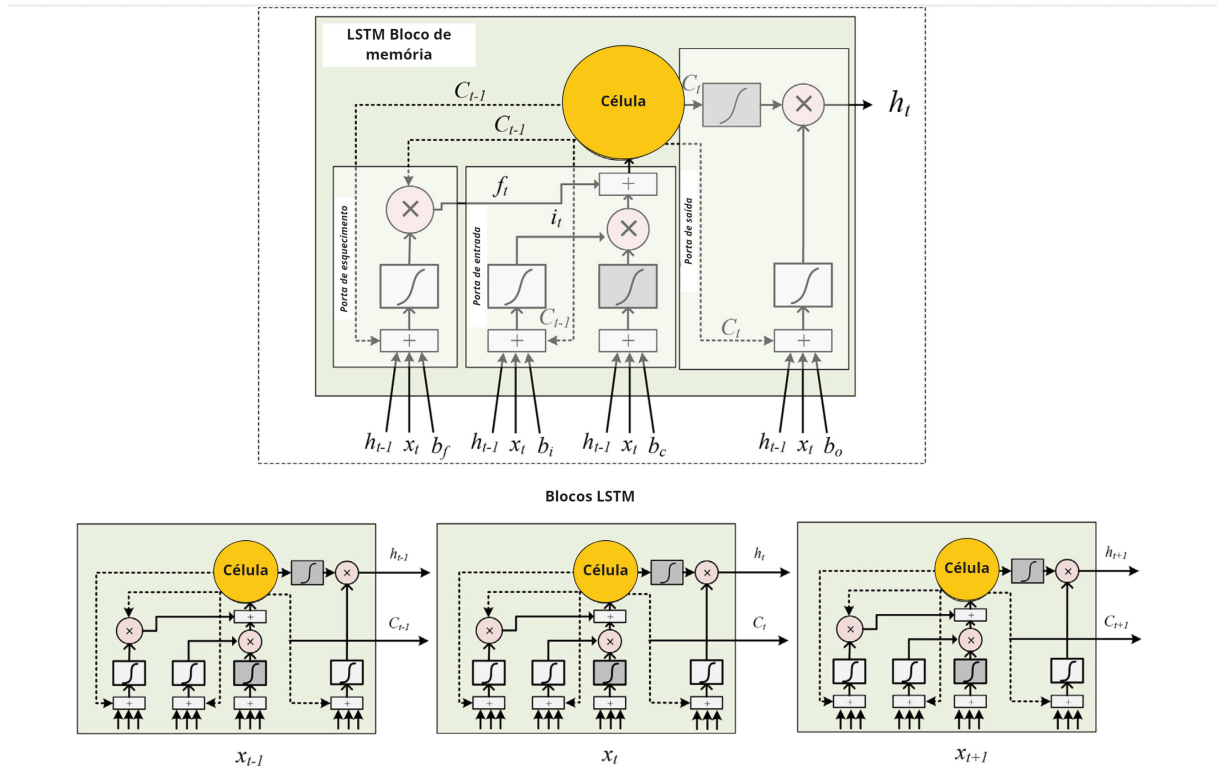


Figura 2.14: Ilustração de Blocos LSTM e a unidade de célula memória

A outra porta, a porta de entrada conforme apresentado na Figura 2.14, é uma seção onde a nova memória é criada por uma rede neural simples de uma camada com a função de ativação tangente hiperbólico (também conhecido como \tanh) e o efeito de bloco de memória anterior, sendo estas operações calculadas pelas equações 2.12 e 2.13. Finalmente, a porta de saída, também apresentado na Figura 2.14, é a seção da qual a saída do bloco LSTM atual é gerada (Olah e Carter, 2016; Tsantekidis et al., 2022). Essas saídas são descritas por 2.14 e 2.15.

$$i_t = \sigma(W[x_t, h_{t-1}, C_{t-1}] + b_i) \quad (2.12)$$

$$C_t = f_t.C_{t-1} + i_t.tanh(W[x_t, h_{t-1}, C_{t-1}] + b_c) \quad (2.13)$$

$$o_t = \sigma(W[x_t, h_{t-1}, C_t] + b_o) \quad (2.14)$$

$$h_t = \tanh(C_t) \cdot o_t \quad (2.15)$$

2.4.2.2 LSTM bidirecional

Uma RNN bidirecional (BRNN) é um modelo proposto para remover várias restrições de RNNs convencionais. Este modelo divide os estados regulares do neurônio RNN em para frente e para trás. Em outras palavras, existem duas redes recorrentes diferentes, para frente e para trás. Essas duas redes se conectam à mesma camada de saída para gerar informações de saída. Com esta estrutura, as situações passadas e futuras de entradas sequenciais em um intervalo de tempo são avaliadas sem demora (Schuster e Paliwal, 1997). A versão LSTM da estrutura BRNN é chamada de LSTM bidirecional (BLSTM). Esta versão pode melhorar o desempenho do modelo LSTM em processos de classificação. Ao contrário da estrutura LSTM padrão, duas redes LSTM diferentes são treinadas para entradas sequenciais na arquitetura BLSTM. A Figura 2.15 mostra uma estrutura básica BLSTM funcionando em entradas sequenciais, tal que X_T representa a entrada e Y_T a saída no instante de tempo T




Figura 2.15: Estrutura básica da rede BLSTM. As redes LSTM na parte inferior indicam o recurso para a frente. As redes acima são usadas para trás. Ambas as redes se conectam a uma camada de ativação comum para produzir saídas.

Os neurônios em um estado avançado de BLSTM atuam como estrutura LSTM unidirecional. Como os neurônios em ambas as redes não estão conectados entre si, o treinamento da rede pode ser fornecido como um LSTM unidirecional normal. O procedimento de treinamento para essas redes geralmente é o seguinte. Na passagem direta, todos os dados de entrada para uma fatia de tempo ($1 < t < T$) são executados via BRNNs e todas as saídas previstas são determinadas. Os passos para frente, conforme apresentado na Figura 2.15 (sentido para a direita) apenas para o tempo de $t = 1$ a $t = T$ e para trás também apresentado na Figura 2.15 (sentido para a esquerda) de $t = T$ para $t = 1$ são concluídos. Uma passagem direta também é concluída para os neurônios de saída. Na passagem para trás, a derivada da função de erro é calculada para a fatia de tempo ($1 < t < T$) que é usada na passagem para a frente. Uma passagem para trás é feita para neurônios de saída e uma passagem para trás é feita para os estados para frente de $t = T$

a $t = 1$ e estados para trás de $t = 1$ para $t = T$. Finalmente, todos os pesos são atualizados. As estruturas BLSTM podem dar melhores resultados do que outras estruturas de rede, dependendo da área do problema. Por exemplo, foi demonstrado que BLSTMs (Graves e Schmidhuber, 2005) são sucessos significativos em tarefas de processamento de fala onde o conteúdo é importante.

2.4.3 Codificadores automáticos - *Autoencoder*

Os codificadores automáticos (do inglês *Autoencoder*, AE) são uma técnica de aprendizado não supervisionado que se tornou popular em várias aplicações de aprendizado de máquina, incluindo compressão de dados como comprimir imagens médicas, recuperação de informações, redução de dimensionalidade e detecção de anomalias (Hinton e Salakhutdinov, 2006), sendo amplamente utilizado no processamento de imagens (Lore et al., 2017), na quebra semântica (Salakhutdinov e Hinton, 2009) e extração de características (Vincent et al., 2008, 2010; Wang et al., 2014). Tornaram-se uma técnica poderosa para o processamento de sinais, incluindo processamento de áudio, processamento de fala podendo ser utilizado para reduzir o ruído em sinais de áudio e analisar sinais de fala. (Goodfellow et al., 2016). Os AE são especialmente úteis em aplicações na qual há muitas informações redundantes ou irrelevantes nos sinais, pois eles são capazes de aprender representações compactas dos sinais, eliminando as informações desnecessárias

Os AEs são compostos por duas partes principais: um codificador (do inglês *encoding*) e um decodificador (do inglês *decoding*). O codificador recebe uma entrada de dados e a transforma em uma representação de baixa dimensão nas representações ocultas, conforme mostrado na equação 2.16

$$m = f_{w,b}(x) \quad (2.16)$$

onde x é o vetor de entrada, m é a representação oculta, w é uma matriz de peso e b é o termo de viés, $f(\cdot)$ representa uma função para a projeção linear ou mapeamento não linear. Quando a projeção linear é usada, a estrutura se assemelha à estrutura de análise de componente principal (do inglês *Principal component analysis*, PCA) (Goroshin e LeCun, 2013), também denominado de espaço latente. O decodificador, por sua vez, recebe as representações ocultas de modo a serem reconstruídas para formar o sinal original $\tilde{x}' = g_{w',b}(m)$ sendo que, a função $g(\cdot)$ é uma função de mapeamento linear ou não linear como $f(\cdot)$, m representa o vetor de características obtido na seção do codificador e \tilde{x}' representa o sinal reconstruído. Assim, a grande entrada pode ser reconstruída com vetores de características pequeno. A Figura 2.16 mostra uma representação em diagrama de blocos de uma estrutura AE padrão de três camadas, composto por um módulo codificador, e um módulo decodificador. As camadas de entrada e de decodificação contam com o mesmo número de nós assim sendo maiores que o número correspondente de nós na camada de codificação.

Para determinar os erros nos sinais que foram reconstruídos, segundo (Tavakoli et al., 2020) utiliza-se do Erro Médio Absoluto (do inglês *Mean absolute error*, MAE) conforme apresentado na equação 2.17 como uma função de custo para mensurar o erro de reconstrução do AE.

$$MAE = \frac{\sum_{n=1}^n |x'_i - x_i|}{n} \quad (2.17)$$

Para tal propósito os AEs constituem de uma rede na qual é treinada para reconstruir a entrada original usando o menor número possível de unidades na camada oculta. Isso é feito

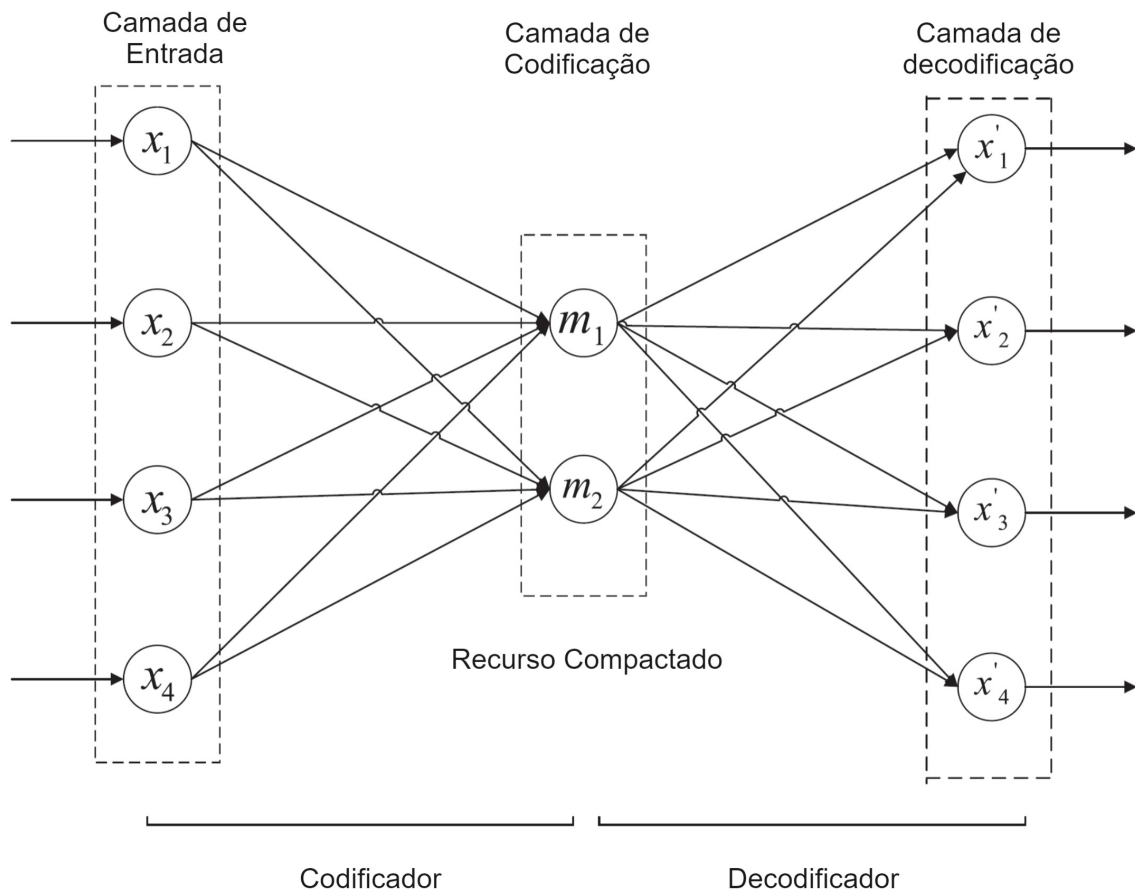


Figura 2.16: Estrutura de um Autoencoder.

minimizando a diferença entre a entrada original e a saída reconstruída usando uma função de custo, como a média dos erros absoluto.

Do ponto de vista intuitivo, os AE podem ser usados para várias tarefas. Em aplicações de compressão de dados, os AEs são usados para transformar dados em um espaço de menor dimensão, economizando espaço de armazenamento. Para redução de dimensionalidade de recursos, semelhante ao PCA, mas seu desempenho é mais forte que o PCA porque o modelo de rede neural pode extrair novos recursos mais eficazes (Song et al., 2018) de modo a simplificar conjuntos de dados complexos e de alta dimensão, tornando mais fácil para os modelos de aprendizado de máquina analisá-los e trabalhar com eles. Além da redução da dimensionalidade dos recursos, os novos recursos aprendidos pelo AE podem ser inseridos no modelo de aprendizado supervisionado, para que o AE possa funcionar como um extrator de características, sendo amplamente utilizados para fins de eliminação de ruído de ECG dado que, os sinais de ECG são frequentemente contaminados por vários tipos de ruído, como desvio da linha de base, ruído de contato do eletrodo e artefatos de movimento, o que pode levar a interpretações imprecisas.

Existem vários tipos de AEs, incluindo AE densos, convolucionais e recorrentes. Os AEs densos são a forma mais simples de AE, com apenas uma camada oculta que representa o código latente. Os AEs convolucionais são usados para processar dados com estrutura espacial, como imagens, e utilizam convoluções em vez de operações de multiplicação de matrizes. No entanto os AEs recorrentes são usados para processar dados sequenciais, como séries temporais, e utilizam redes neurais recorrentes para lidar com a dependência temporal dos dados (Hong et al., 2020b).

Embora os AEs sejam uma técnica poderosa para aprendizado não supervisionado, eles têm algumas limitações. Eles podem ter dificuldades em capturar todas as características importantes dos dados, especialmente em conjuntos de dados complexos e de alta dimensão. Além disso, eles podem sofrer de sobreajuste se o tamanho da camada oculta for muito grande em relação à dimensão dos dados.

Em resumo, os AEs são uma técnica útil para aprender representações compactas dos dados em uma variedade de tarefas de aprendizado de máquina, incluindo compressão de dados, redução de dimensionalidade e detecção de anomalias

2.5 TRABALHOS RELACIONADOS

Uma pesquisa bibliográfica realizada utilizando de duas bases, Google acadêmico e portal de periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) usando da base Scopus®, por meio de um programa de *software* livre para análise de citações denominado *publish or perish* (Harzing, 2020), foi possível identificar 10 artigos contendo revisão sistemática de literatura em seu título e resumo com o foco no uso de abordagens de aprendizado de máquina e ou aprendizado profundo em sinais de eletrocardiograma humano, de modo que 4 artigos foram selecionados pelo maior número de citações.

Parvaneh et al. (2019) apresentaram uma revisão abordando somente artigos que apresentam abordagens de aprendizado profundo em detecção de arritmias, contendo 52 artigos em um período de 2011 a 2019. Ebrahimi et al. (2020) demonstraram uma revisão sobre os métodos recentes de DL aplicados ao sinal de ECG para fins de classificação considerando 75 estudos relatados em 2017 e 2018 concluindo que a CNN é predominantemente observada como a técnica adequada para extração de recursos, observada em 52% dos estudos. Hong et al. (2020b) revisaram 191 artigos em um período de 2010 a 2020, da qual 108 foram publicados após 2019, demonstrando diferentes arquiteturas de aprendizado profundo usadas em diversas tarefas de análise de ECG, como: detecção/classificação de doenças, anotação/localização, estágio do sono, identificação biométrica humana, e eliminação de ruídos, onde abordagens por meio de arquiteturas híbridas contendo uma rede neural convolucional e uma rede neural recorrente, permite alcançar resultados ainda melhores.

Matias et al. (2021) apresentaram uma revisão de estudos que utilizam Inteligência Artificial para predição de FA, referenciando 12 estudos no período de 2009 a 2019 onde 3 aplicaram técnicas de aprendizado profundo, 6 usaram métodos de aprendizado de máquina e outros 3 focaram na aplicação de modelos gerais de inteligência artificial. Além disso, mais da metade dos estudos selecionados foram publicados desde 2016, corroborando que esse tema é muito recente e tem alto potencial para pesquisas adicionais.

A busca na literatura pode ser realizada por meio de dois métodos: mapeamento sistemático e revisão sistemática da literatura. O mapeamento do sistema (também conhecido como estudo de escopo) fornece uma visão geral da área de pesquisa e visa detectar os principais caminhos presentes na literatura da área de pesquisa. Os resultados do estudo de mapeamento podem identificar áreas adequadas para revisões sistemáticas da literatura e áreas mais adequadas para pesquisas preliminares (Petersen et al., 2015).

Uma revisão sistemática da literatura (RSL) é um procedimento a fim de identificar, avaliar e interpretar um grupo de estudos relacionados que abordam uma questão de pesquisa específica. Um estudo individual que investiga uma questão de pesquisa específica e contribui para uma revisão sistemática é denominado de estudo primário. Uma revisão sistemática é uma forma de pesquisa secundária porque analisa a pesquisa primária relacionada a uma questão de pesquisa específica com o objetivo de integrar/sintetizar as evidências relacionadas a essa questão

de pesquisa (Keele et al., 2007). Para tanto optou-se por uma RSL para avaliar e sintetizar de forma rigorosa e transparente as evidências disponíveis em métodos de aprendizado profundo existentes para dados ECG a partir das perspectivas de arquiteturas de modelo e tarefas de aplicação, buscando identificar a lacuna de conhecimento, avaliar a qualidade e sintetizar as evidências evitando duplicar esforços e assim orientar a tomada de decisão.

2.5.1 Revisão sistemática de literatura

Segundo as discussões encontradas na literatura, conduzida por uma revisão abrangente, foram procurados artigos em que utilizou-se de métodos de aprendizado de máquina e/ou aprendizado profundo para dados de ECG, seguindo as diretrizes apresentadas em (Keele et al., 2007) e (Kitchenham e Brereton, 2013). O processo de busca e seleção de literatura é ilustrado na figura 2.17. Foi considerado um processo de quatro estágios que consiste em identificação, triagem, elegibilidade e inclusão inspirado na abordagem de (Matias et al., 2021).

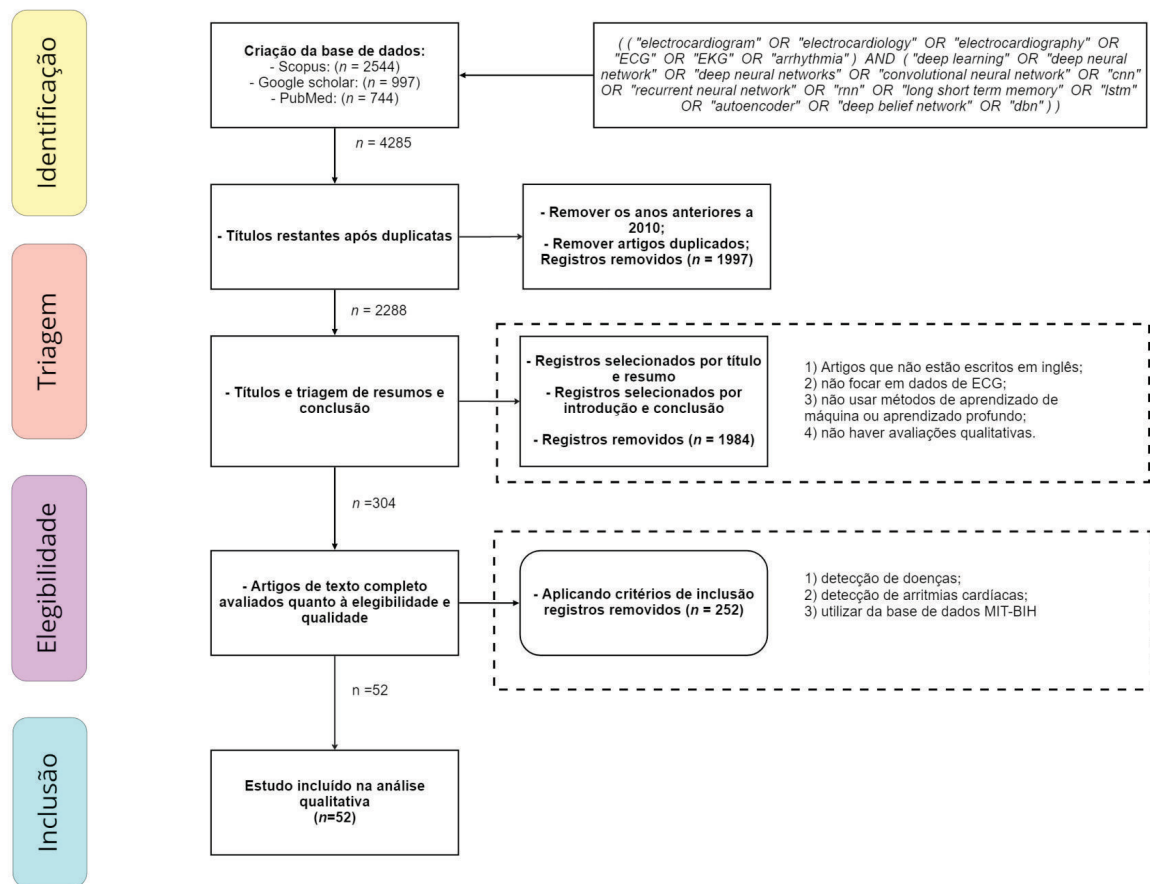


Figura 2.17: Diagrama de fluxo de identificação e inclusão de artigos

O objetivo principal desta RSL é pesquisar os trabalhos desenvolvidos entre 2010 a dezembro de 2021 relativos as aplicações de abordagens de aprendizado de máquina e/ou aprendizado profundo com foco na classificação de arritmias cardíacas. Partindo deste objetivo foram definidas as seguintes questões de pesquisa:

- QP1: Quais são as principais abordagens utilizadas a fim de classificar de forma automática arritmias cardíacas?

- QP2: Quais são as principais contribuições utilizando de aplicação de arquiteturas híbridas baseadas em AE com camadas de LSTM para extração de características?

Em seguida são definidos os critérios de inclusão e exclusão, as estratégias para realizar a busca em bases de dados e a avaliação crítica dos artigos e a seleção dos estudos que devem ser incluídos na RSL.

A fim de identificar os estudos primários que forneçam evidência direta a respeito das questões de pesquisa (Keele et al., 2007), foram definidos os seguintes critérios na RSL:

- detecção de doenças;
- classificação de arritmias cardíacas;
- utilizar da base de dados MIT-BIH.

Os critérios de exclusão foram definidos tendo em vista descartar estudos irrelevantes no contexto das questões de pesquisa. Os critérios de exclusão foram definidos como:

- artigos que não estão escritos em inglês;
- não focar em dados de ECG;
- não usar métodos de aprendizado de máquina ou aprendizado profundo;
- não haver avaliações qualitativas.

Em seguida, definiu-se uma *string* de pesquisa com as palavras-chave para procurar nas bases de dados buscando cobrir as questões da pesquisa. Para gerar as *strings* de busca, os sinônimos são unidos por meio de um operador OR, e as frases de pesquisa são unidas por um operador AND visto que cada base de dados tem sua própria sintaxe de pesquisa. Para tanto inspirado em (Parvaneh et al., 2019), os termos gerais de pesquisa foram compilados em palavras-chaves de forma que não diferenciam em maiúsculas de minúsculas:

("electrocardiogram"OR "electrocardiology"OR"electrocardiography"OR"ECG"OR "EKG"OR "arrhythmia") AND ("deep learning"OR "deep neural network"OR "deep neural networks"OR "convolutional neural network"OR "cnn"OR "recurrent neural network"OR "rnn"OR "long short term memory"OR "lstm"OR "autoencoder"OR "deep belief network"OR "dbn")

Para evitar a perda de artigos que não mencionam explicitamente essas palavras-chave em seus títulos, foi expandido na busca para incluir em outros campos de cada artigo. Contudo, deve-se observar que muitos artigos não relacionados mencionaram pelo menos uma vez algumas das palavras-chaves em suas seções de introdução ou seções de trabalhos relacionados, o que proporcionou o resultado de um acentuado conjunto inicial de artigos. O número de artigos coletados na etapa de identificação é 4285, ao remover os anos anteriores a 2010 e aplicando o primeiro critério de exclusão em que limita somente a artigos escritos na língua inglesa e de remover duplicatas, o número de artigos caiu para 2288. Em seguida, na etapa de triagem dos artigos foi conduzida utilizando o *publish or perish* para selecionar estudos em que apresentam as palavras-chaves nos títulos reduzindo o número de artigos para 781. Ainda na etapa de triagem examinando resumos, introdução e conclusão, o número de artigos foi reduzido a 304. Na etapa seguinte em avaliação da elegibilidade foram analisados textos completos e aplicados os critérios de inclusão. Como resultado, 1984 artigos foram excluídos por triagem e 252 artigos foram excluídos por avaliação de texto completo conforme ilustrado na figura 2.17.

A Figura 2.18 apresenta o número de publicações por ano que utilizam de abordagens de aprendizado profundo em problemas utilizando ECG totalizando 304 publicações, sendo 257 de revistas e 42 de conferências conforme ilustrado na Figura 2.19, que compreende um período de 2010 a 2021. Em 2010 e 2021 não houve publicação em conferências que satisfizessem os critérios de inclusão e exclusão. É possível observar que o número de artigos publicados é expressivo, devido ao maior número de publicações estar entre os anos de 2019 e 2020 e com uma diminuição no ano posterior se aproximando do ano de 2018. A Figura 2.21 e Figura 2.20 apresentam a porcentagem de publicações por ano em revistas e conferências.




Figura 2.18: Número de publicações por ano




Figura 2.19: Número de publicações por ano em conferência e revistas

Dos 304 artigos selecionados para a próxima etapa de elegibilidade cada artigo foi analisado de acordo com os seguintes aspectos conforme mostra a figura 2.22:

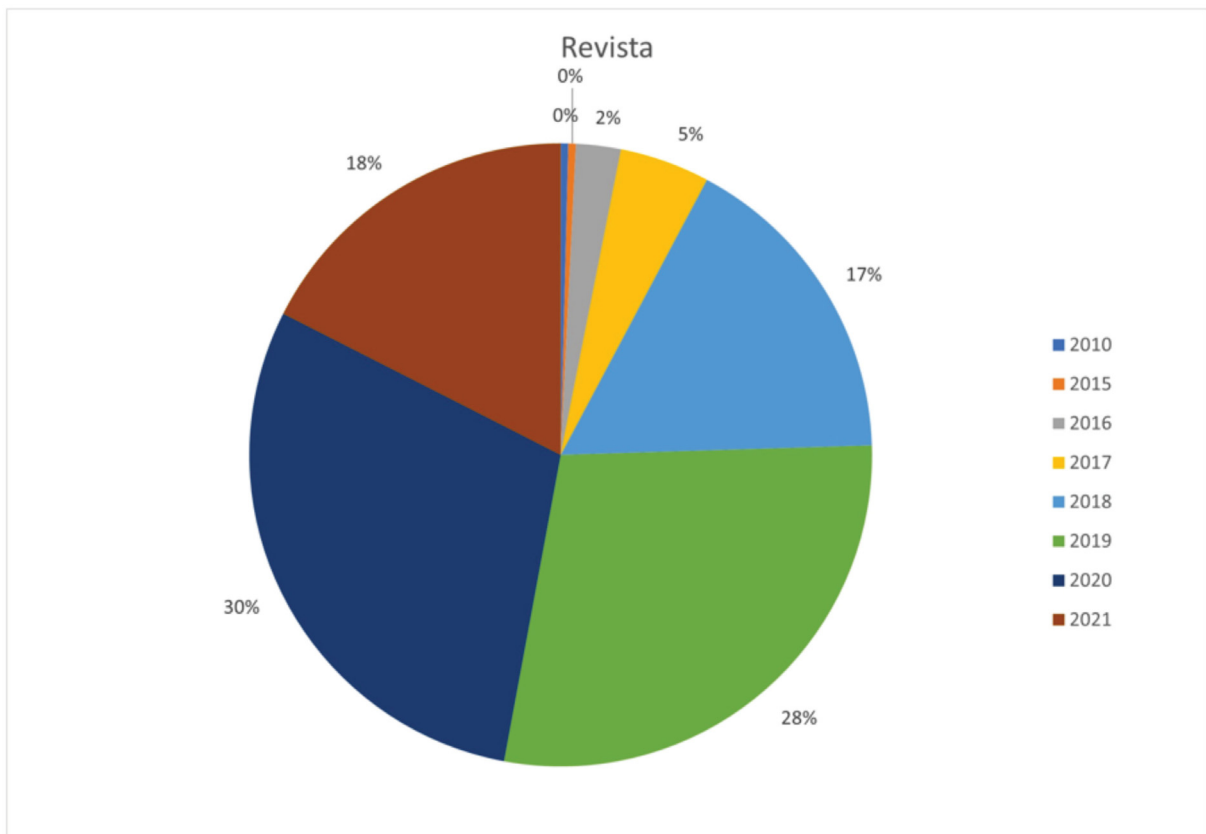


Figura 2.20: Porcentagem de publicações por ano em revistas

- Tarefa: as tarefas de aplicação direcionadas eram (1) detecção de doenças (por exemplo, doenças específicas, como AF, MI, CHF, elevação de ST ou arritmia de diagnóstico geral), (2) anotação ou localização (por exemplo, anotação do complexo QRS, anotação de onda P, localizando a origem da ativação ventricular), (3) estadiamento do sono, (4) identificação biométrica humana, (5) eliminação de ruído e (6) outros.
- Modelo: as arquiteturas de modelo profundo incluem (1) CNNs, (2) RNNs, (3) combinações de CNNs e RNNs, CRNNs, (4) do inglês *autoencoders* (AEs), (5) redes adversárias gerativas (GANs) e (6) outras abordagens. Também determinamos (7) se cada artigo incluía recursos especializados tradicionais ou conhecimento especializado integrado ao construir um modelo profundo.
- Dados: as estatísticas de dados são (1) o tamanho do conjunto de dados, (2) número de canais (número de condutores de eletrodo), (3) duração, (4) anotações, (5) fontes, (6) ano de coleta e (7) quantidade de artigos em que os dados foram usados.

Durante a etapa de elegibilidade, seguindo os aspectos mencionados anteriormente, foi possível reduzir para 199 artigos, sendo que 84 (aproximadamente 42,67%) artigos foram publicados antes de 2019, 112 (aproximadamente 57,85%) foram publicados após 2019, 116 foram publicados pela comunidade de informações médicas e engenharia biomédica e somente 25 (aproximadamente 13%) foram publicados pela comunidade de inteligência artificial e mineração de dados conforme apresentado na Figura 2.23.

Foram incluídos apenas 52 artigos que atendiam aos critérios de inclusão, os quais abordavam a detecção de doenças cardíacas e arritmias utilizando a base de dados MIT-BIH.

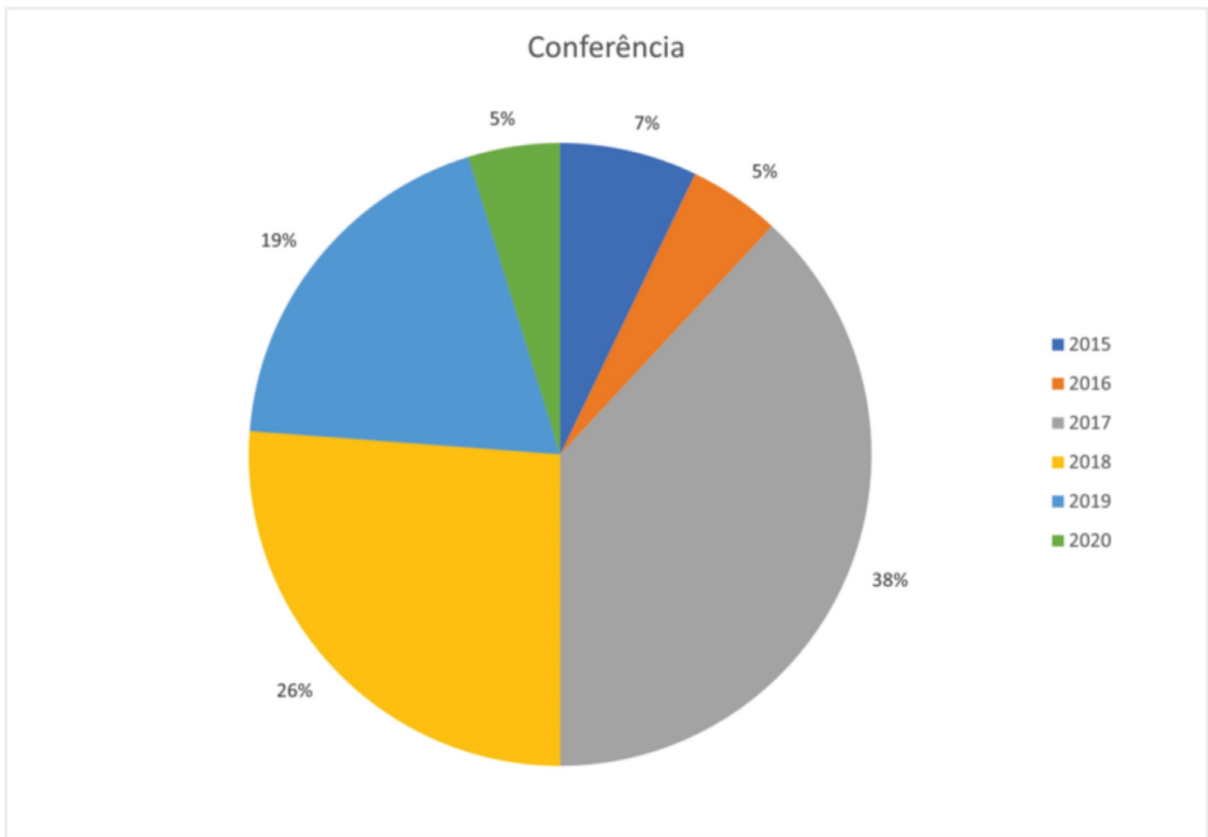


Figura 2.21: Porcentagem de publicações por ano em conferências

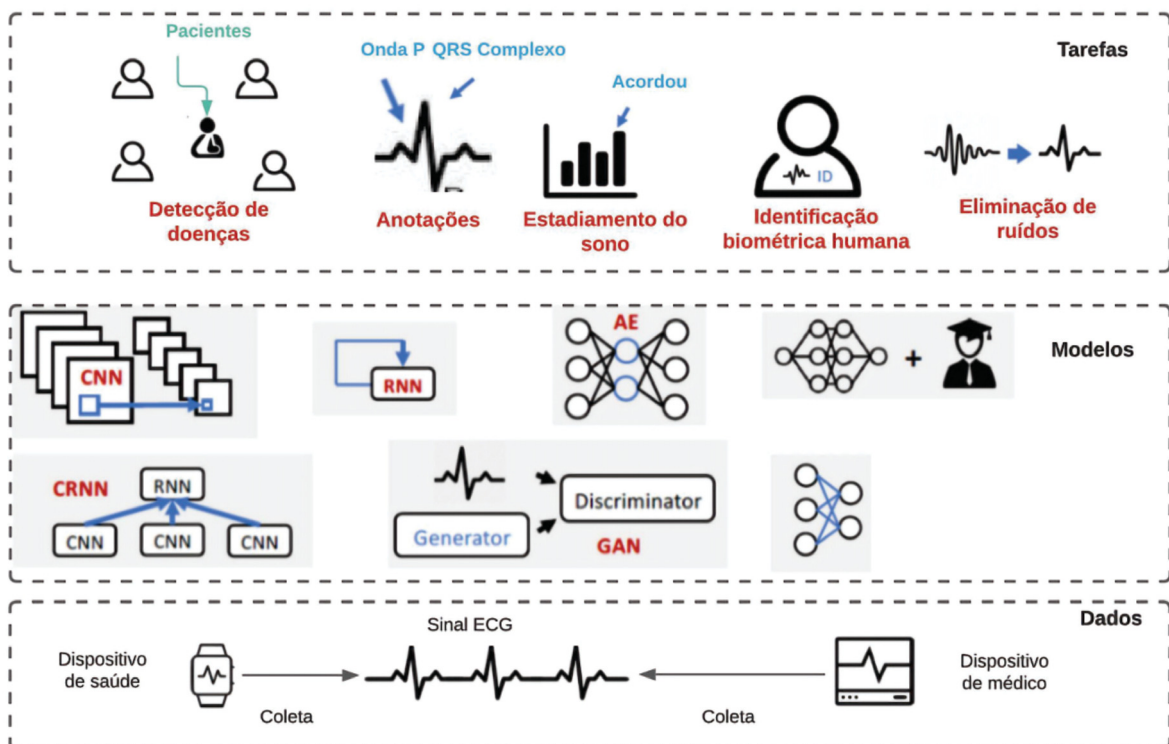


Figura 2.22: Resumo da análise dos artigos

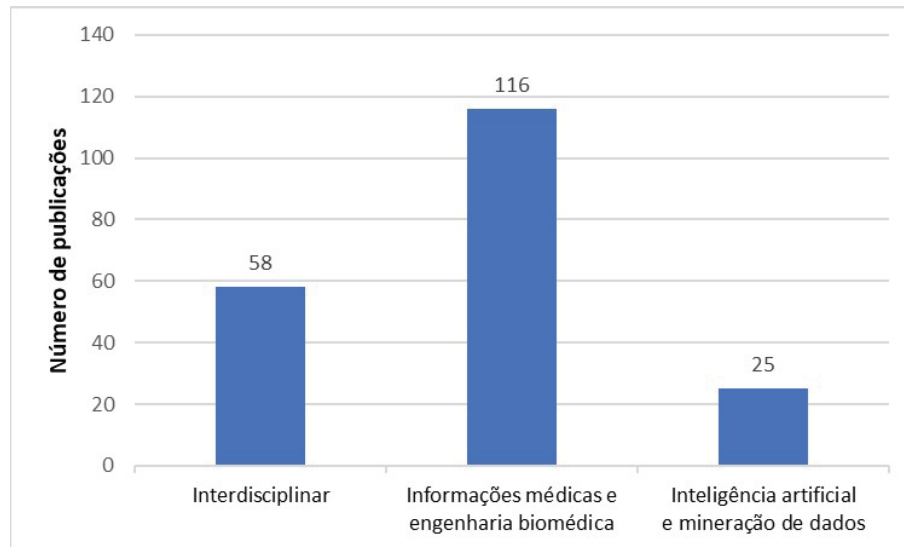


Figura 2.23: Número de publicações por grupos e comunidades

Esses artigos foram selecionados por demonstrarem as principais abordagens empregadas na classificação automática de arritmias cardíacas, além de utilizarem uma base de dados em comum e apresentarem um estudo comparativo com outras abordagens encontradas na literatura. No entanto foi possível identificar na análise estatística a ausência de estudos em revista no ano de 2022 visto que apresentavam uma base de dados diferente da escolhida como validação para este estudo o que poderia impactar em ter uma comparação não justa entre as abordagens onde o mesmo acontece para estudos em conferências.

2.5.2 Trabalhos relacionados ao tema da dissertação

Devido a capacidade de extração de características de forma automática encontrados no aprendizado profundo, diversas técnicas de redes neurais profundas são utilizadas, tal como CNN que é amplamente utilizada para classificação de imagens, processamento de linguagem natural e processamento de sinal. Uma CNN típica consiste em várias camadas convolucionais, seguidas por uma camada de normalização de lote, uma camada de ativação, uma camada de saída, uma camada de *pool* e uma camada de classificação (por exemplo, uma camada totalmente conectada), conforme descrito em (Hannun et al., 2019). Para a classificação de ECG, em geral, utiliza-se de dois tipos de CNN, a saber, 1D CNN e 2D CNN. A 1D CNN opera aplicando o kernel na dimensão do tempo dos dados originais de ECG (Kiranyaz et al., 2016; Yin et al., 2016).

Yildirim et al. (2018) propõe uma estrutura completa de ponta a ponta projetada ao contrário de uma extração e seleção de recursos artesanais usados nos métodos tradicionais, tendo como principal contribuição projetar um novo modelo de CNN 1D, enquanto 2D CNN geralmente opera nos dados de ECG convertidos, como a matriz de distribuição de distância com base no cálculo de entropia (Li et al., 2018), matriz de nível de co-ocorrência cinza (Sun et al., 2019), ou recursos combinados, incluindo morfologia, intervalo RR e correlação de batimentos cardíacos (Li et al., 2019a). O intervalo RR é a distância entre duas ondas R sucessivas de modo que, no ritmo sinusal o intervalo deve ser constante sendo medido desde o início de uma onda R até o início da próxima onda R, conforme mostrado na figura 2.24. Sua duração está relacionada a frequência cardíaca. Em resultados de eletrocardiogramas com ritmo regular é possível calcular este intervalo por meio do valor da frequência cardíaca.




Figura 2.24: a) intervalo RR; b) segmento ST

Xia et al. (2017) abordam a aplicação de redes neurais convolucionais profundas para detecção automática de FA, no entanto, a estrutura de entrada de parâmetro de 2 dimensões é essencial para as redes profundas, sendo o ECG é um sinal variável no tempo de uma dimensão, não corresponde ao requisito para a estrutura de entrada, então a fim de resolver esses problemas, adotou-se a transformada wavelet estacionária para pré-processamento de ECG e, em seguida, o sinal processado é reorganizado em estrutura de parâmetros bidimensional para atender aos requisitos de estrutura de entrada das redes profundas. Já em (Pourbabae et al., 2018) a abordagem proposta opera com um grande volume de dados de séries temporais de ECG como entradas para CNN de modo a aprender autonomamente características representativas e principais de Paroxymal AF a fim de substituir efetivamente os recursos artesanais tradicionais e simplificar o processo de extração de características correspondentes a diferentes arritmias cardíacas e eliminando a necessidade de usar um especialista humano para definir características apropriadas e críticas trabalhando com um grande conjunto de dados de séries temporais.

Zhai e Tin (2018) propõem uma abordagem da qual, assim como em (Xia et al., 2017), transformam os batimentos em matriz de acoplamento de batimento duplo como entradas 2-D para o classificador CNN, de modo a capturar a morfologia de batimento e a correlação de batimento a batimento no ECG. Também propôs um procedimento sistemático de seleção de batimentos de treinamento que inclui automaticamente os batimentos mais representativos no conjunto de treinamento para melhorar o desempenho da classificação.

Para a aplicação de 2D CNN alguns estudos utilizam de arquiteturas com o maior kernel como uma rede neural residual (do inglês *residual neural network*, ResNet), rede convolucional densa (do inglês *Dense Convolutional Network*, DenseNet), ou Inception-Net treinada em um conjunto de dados ImageNet, (Deng et al., 2009), (Andreotti et al., 2017) podendo ser ajustado para um conjunto de dados de ECG para encontrar doenças de batimento cardíaco como sugerido em (Wołk e Wołk, 2019) e analisar alterações no padrão do segmento ST. Este segmento representa o início de uma repolarização ventricular que corresponde com a fase de repolarização lenta em um platô dos miócitos ventriculares representando um período de inatividade entre a despolarização e o início da repolarização ventricular, conforme figura 2.24. As alterações deste segmento são de grande importância no diagnóstico das síndromes coronarianas agudas, também conhecidas como arritmias (Wang et al., 2019b). Além de aplicações utilizando de

CNN tem-se as redes neurais recorrentes (RNN) desenhadas para modelos de dados sequenciais, séries temporais, sequências de eventos e processamento de linguagem natural. Particularmente, para dados de ECG, RNN pode ser uma escolha lógica para capturar a dependência do tempo e processar entradas de diferentes comprimentos.

Em Maknickas e Maknickas (2017) apresentam uma rede de LSTM, que aprende padrões diretamente de recursos complexos QRS pré-computados que classificam sinais de ECG tendo com o objetivo de classificar entre normal e FA. Chang et al. (2018) aborda o uso de redes LSTM para explorar as características espectrais e temporais de alta ordem dos sinais de eletrocardiograma (ECG) de múltiplas derivações de pacientes com FA demonstrando que não apenas o desvio dos denominados intervalos RR dos sinais de ECG, mas também suas variações temporais são fundamentais para a detecção de FA. Contudo, (Schwab et al., 2017) compartilhando do mesmo objetivo apresenta uma abordagem de um conjunto (do inglês *ensemble*) RNNs para identificar conjuntamente padrões temporais e morfológicos em gravações de ECG segmentadas de qualquer comprimento. Já em (Zhou et al., 2018) é explorada uma abordagem de rede LSTM contudo para um problema de detecção de contração prematura ventricular (PVC).

Rajan e Thiagarajan (2018) desenvolveram uma abordagem de modelagem generativa com o intuito de uma classificação limitada de ECG um conjunto limitado de canal, da qual utiliza primeiro um modelo Seq2Seq com o objetivo de gerar implicitamente as informações do canal ausente e, em seguida, usa a representação latente de modo a executar a tarefa de supervisão real permitindo o uso de dados não supervisionados e também fornece espaços métricos altamente robustos adequado ao aprendizado discriminativo subsequente. Liu e Kim (2018) utilizaram de uma rede LSTM, no entanto diferente dos demais exploraram na etapa de pré-processamento de dados o uso de uma aproximação de agregação simbólica para melhorar a precisão. Yildirim (2018) apresenta um novo modelo para sequências wavelet, da qual foi gerada uma camada fundamentada em waveletes, em uma rede LSTM bidirecionais profundas denominado DBLSTM-WS para classificar sinais de eletrocardiograma (ECG).

Em Saadatnejad et al. (2020) foram empregadas em sua abordagem a utilização de duas redes LSTM a fim de combinar sinais de ECG brutos e recursos de transformada wavelet (do inglês *wavelet transform*) para execução contínua em tempo real em dispositivos vestíveis, conforme ilustrado na figura 2.25.

Em Li et al. (2019b), um mecanismo de atenção da qual foi incorporado a uma rede BiLSTM para melhorar o desempenho e a interpretabilidade, visualizando pesos de atenção. Para tratamento de sinais de ECG de longa duração com comprimentos de sequência variados e entradas multicanal, foi proposto o uso de CRNN, uma fusão entre CNN e RNN como em Ballinger et al. (2018); Hong et al. (2019a), de modo que a CNN é usada para extração de características locais de um sinal de ECG e uma RNN para resumir os recursos locais ao longo da dimensão de tempo para gerar recursos globais.

Os codificadores automáticos de remoção de ruído empilhado (do inglês *stacked denoising autoencoder* SDAE) (Xia et al., 2018), codificador automático empilhado (do inglês *stacked autoencoder*, SAE) (Zhang et al., 2019; Yin et al., 2017) e auto-codificador convolucional (do inglês *convolutional auto-encoder*, CAE) (Yildirim et al., 2019) são amplamente usados para fins de eliminação de ruídos de ECG porque os sinais de ECG são frequentemente contaminados por vários tipos de ruído, como desvio da linha de base, ruído de contato do eletrodo e artefatos de movimento, o que pode levar a interpretações imprecisas.

Farhadi et al. (2018) apresentam uma combinação de método de aprendizado profundo que tem como objetivo classificar a FA por meio de um sinal de ECG, extrair características espectrais, temporais e não lineares do sinal, também usado em paralelo para classificar AF

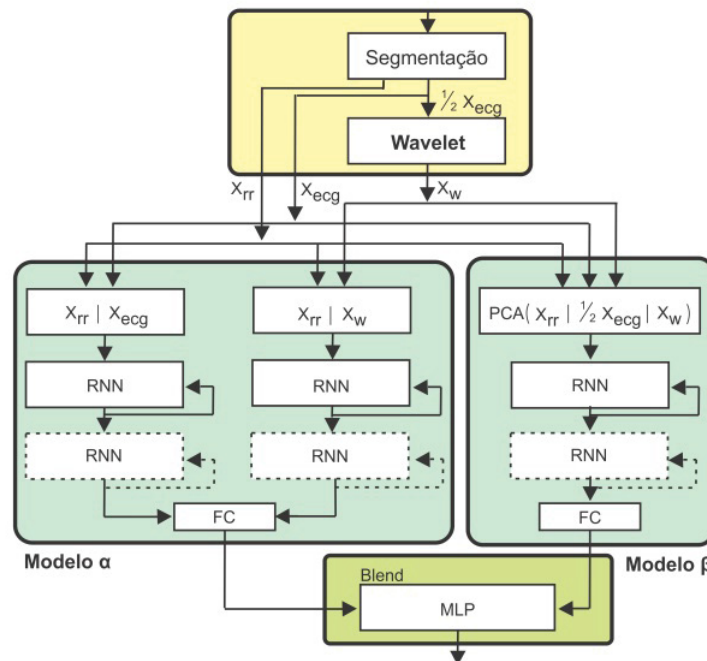


Figura 2.25: Duas redes LSTM (Saadatnejad et al., 2020)

e amostras normais. Wang et al. (2019a) também apresentam um SDAE para a redução de ruído como em (Xia et al., 2018), contudo utiliza de um classificador LSTM bidirecional (Bi-LSTM) aproveitando ao máximo as informações temporais nos dados obtendo a classificação de batimentos cardíacos. Em (Yildirim et al., 2019) apresenta uma estrutura de compressão com o objetivo de reduzir o tamanho do sinal de batimentos do coração, empregando classificadores LSTM para reconhecer automaticamente arritmias por meio de recursos de ECG reduzindo assim significativamente a duração do tempo ao usar redes LSTM para obter os resultados.

Por meio da síntese dos resultados encontrados na RSL foi possível responder as questões de pesquisa elaboradas:

QP1: Quais são as principais abordagens utilizadas a fim de classificar de forma automática arritmias cardíacas?

No decorrer da pesquisa realizada foi possível identificar qual o modelo de referência mais utilizado, conforme ilustrando na Figura 2.26 e 2.27. A CNN contendo 25 artigos, foi aplicado em 48% dos casos selecionados sendo a abordagem mais utilizada dentre os selecionados. O segundo modelo de referência mais utilizado foi a RNN (LSTM) com 10 artigos sendo aplicado em 19% dos casos, empatado também com 10 artigos totalizando também 19% dos selecionados encontram-se os modelos híbridos RCNNs. Os artigos menos utilizados contam com os AE e redes neurais e outros com 5 e 2 artigos respectivamente representando 10% e 4% do selecionados.

QP2: Quais são as principais contribuições utilizando de aplicação de arquiteturas híbridas baseadas em AE com camadas de LSTM para extração de características?

Foi possível identificar 10 artigos que utilizam de arquiteturas híbridas fundindo CNN com RNN contudo, 5 artigos utilizam de AE de modo que ambos utilizam de redes neurais conectadas e/ou camadas convolutivas em problemas de redução ruídos e extração de características, representando 10% dos artigos selecionados. Contudo, cabe mencionar que não

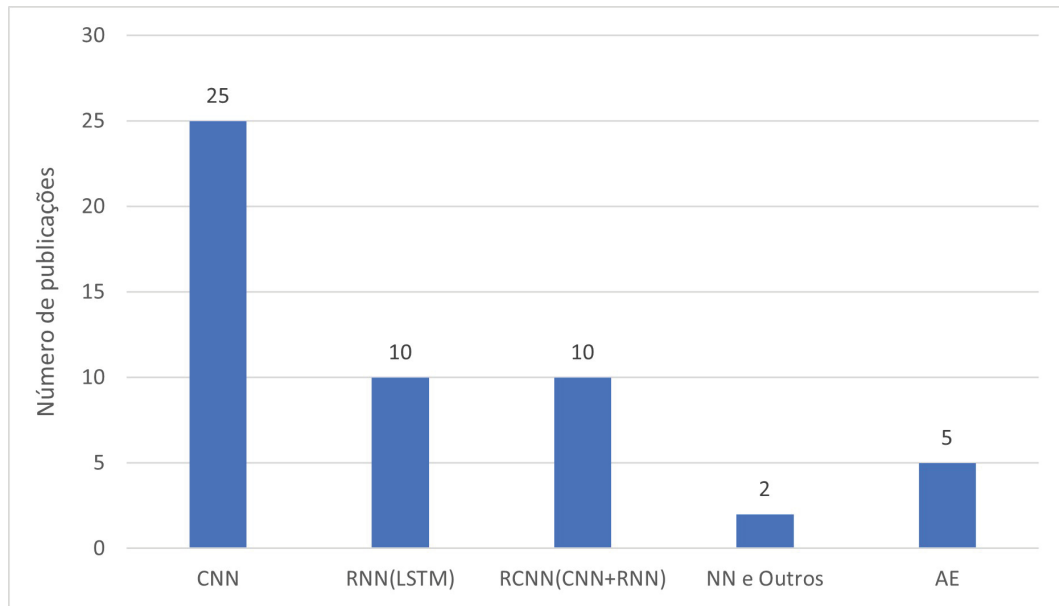


Figura 2.26: Número de artigos por abordagens




Figura 2.27: Porcentagem de artigos por abordagens

foram encontrados artigos na base de dados da qual foi realizada pesquisas em que tenha sido utilizado abordagens de AE com camadas de LSTM.

2.6 CONSIDERAÇÕES DO CAPÍTULO

As considerações finais deste estudo permitem compreender melhor a relação entre ECG e as técnicas de aprendizado de máquina e aprendizado profundo. O ECG é uma técnica não invasiva e amplamente utilizada para avaliar a atividade elétrica do coração na qual foi possível explorar a construção do sinal e as derivações que compõe um sinal de ECG padrão,

sendo fundamental para o diagnóstico de diversas doenças cardiovasculares. Ainda se tratando de elementos relacionados ao coração foi discutido as principais formas arritmias cardíacas e a base de dados que será empregada neste estudo.

As técnicas de aprendizado de máquina e aprendizado profundo têm se mostrado cada vez mais promissoras na área da saúde, especialmente no auxílio ao diagnóstico de doenças complexas. Nesta seção, foi possível constatar que o uso de aprendizado de máquina e aprendizado de profundo para análise de sinais de ECG pode trazer diversos benefícios, como uma maior precisão na detecção de anomalias e a possibilidade de desenvolvimento de ferramentas de apoio à decisão clínica.

Foi possível ilustrar, por meio de uma RSL, o processo de seleção dos artigos relevantes para este estudo e discutir trabalhos relacionados ao tema. Isso permitiu direcionar a abordagem utilizada neste estudo, através de duas questões principais. Dentre os trabalhos relacionados, destacam-se aqueles que propõem algoritmos baseados em abordagens como CNN, RNN (LSTM), híbridas (RCNN) e outras, para a classificação de arritmias cardíacas. Além disso, alguns estudos também abordaram o uso de técnicas de pré-processamento de dados, como AE, para melhorar a análise de sinais de ECG, incluindo a remoção de ruídos e normalização dos dados.

No entanto, apesar dos avanços obtidos até o momento, ainda há desafios a serem enfrentados na aplicação de aprendizado de máquina e aprendizado de profundo na análise de ECG. É necessário considerar a qualidade dos dados, a necessidade de grandes conjuntos de dados para treinamento dos algoritmos e a interpretabilidade dos resultados obtidos.

Por fim, este estudo permitiu compreender melhor a aplicação de técnicas de aprendizado de máquina e aprendizado de profundo na análise de sinais de ECG, bem como os benefícios e desafios envolvidos nessa abordagem. Esta seção pode contribuir para o desenvolvimento do procedimento de construção de uma nova abordagem dividida em pré processamento utilizando de filtragem e segmentação, extração de características aplicando AE e classificação na qual serão discutidas na próxima seção de modo a contribuir para uma detecção de arritmias de forma automática e, conseqüentemente, para a melhoria dos diagnósticos impactando na saúde e qualidade de vida dos pacientes.

3 METODOLOGIA

Este capítulo descreve os processos de desenvolvimento e avaliação do modelo proposto. Na literatura, a classificação de ECG está focada especialmente em CNN, além de usar a transformada wavelet para aprimorar a extração de características. Quanto à CNN, com o aumento da quantidade de camadas de rede neural, sua capacidade de aprendizado aumentará gradualmente, no entanto, simplesmente aumentar o número de camadas de rede neural não contribui para a precisão do modelo de CNN. Contudo, com o aumento do número de camadas, o problema do desvanecimento do gradiente (do inglês *vanishing gradient*) no modelo de rede CNN é gradualmente exposto (Bengio et al., 1994), embora tenha sido proposta diversas abordagens para resolver o problema de desvanecimento do gradiente, como métodos de inicialização normalizada ou métodos normalizados intermediários (He et al., 2015; Saxe et al., 2013). No entanto, ainda permanece uma limitação da qual, a precisão do modelo é reduzida devido ao aumento das camadas de rede, apesar disso a rede LSTM não apresenta este problema, aparentando ter um desempenho melhor que a CNN na maioria dos casos. No entanto, a rede LSTM raramente é utilizada para a classificação de arritmias conforme foi identificado por meio da RSL. Partindo do pressuposto utilizar desta abordagem é possível assim evitar o problema do desvanecimento do gradiente. O objetivo desta dissertação é introduzir novas abordagens de aprendizado de máquina com o intuito de reduzir ruídos, identificar as características do sinal e classificar as detecções de anomalias presentes nos batimentos cardíacos, tais como Contração Atrial Prematura (PAC), Bloqueio do Ramo Esquerdo (BRE), Bloqueio do Ramo Direito (BRD), Contração Ventricular Prematura (PVC) e Batimento Normal (BN). Para isso será realizado um algoritmo, conforme ilustrado na Figura 3.1, da qual será composto por um filtro para tratar os ruídos, aliado de uma AE construído por uma rede LSTM e um classificador, também composto por uma rede LSTM, conforme apresentado no capítulo anterior. A escolha de utilizar uma arquitetura contendo AE utilizando de uma rede LSTM baseia-se nas características dessas técnicas, de modo a cooperar com o processo de pré-processamento para obter assim um melhor resultado de classificação de arritmias cardíacas. Diferente dos métodos tradicionais de aprendizado de máquina em tarefas de classificação, este não tem a necessidade de inserir manualmente os recursos para o modelo.




Figura 3.1: Diagrama do algoritmo proposto.

3.1 PRÉ-PROCESSAMENTO

Na etapa de pré processamento buscou-se fazer o tratamento dos sinais de modo a reduzir a interferência que os artefatos musculares, movimento do eletrodo e ruído de flutuação

da linha de base no ECG também conhecido como *drift*, sendo uma interferência manifestada como uma flutuação da linha do zero, podendo ser causada pela baixa qualidade dos elétrodos ou pelo movimento de objetos de materiais eletroestáticos perto dos circuito de entrada com bio-amplificadores extremamente sensíveis que implica frequências máximas ≤ 1 Hz (Smolarik et al., 2012) a fim de não impactar no resultado final dos sinais que serão analisados.

3.1.1 Filtragem do sinal

Os sinais de ECG humanos é um sinal muito fraco fisiologicamente sendo considerado um sinal elétrico de baixa frequência na qual a amplitude máxima do sinal não excede 5mV, e a frequência se encontra 0.05 e 100 Hz. Devido a polarização entre o eletrodo e o tecido da pele, a coleta do sinal causará elevadas interferências no sinal do ECG (Takamoto et al., 2013). Além do mais, a interferência de frequência de energia também está incluída no sinal do ECG original (Luz et al., 2016). Para resolver de forma efetiva esse ruídos e preservar as características originais dos sinais optou-se por projetar um filtro passa-baixa (Turnip et al., 2021) e um filtro adaptativo (Esposito e D'Andria, 2003) para eliminar os ruídos.

A frequência de um sinal de uma movimentação muscular conhecida como eletromiografia (EMG) está entre 20 Hz e 5000 Hz sendo a frequência de seus componentes relacionada ao seu tipo de músculo, da qual geralmente encontra-se na variação entre 30 Hz a 300 Hz, dado que a frequência do ECG está concentrada entre 5 Hz a 20 Hz (Osowski e Linh, 2001). Isto posto um filtro de passa-baixa foi selecionado para tratar os sinais de interferência advindos da EMG. De acordo com a classificação das características da banda passante do filtro, existem principalmente quatro tipos de filtros clássicos: filtro Butterworth, filtro Chebyshev, filtro Bessel e filtro elíptico (Noceti Filho, 1998; Zverev, 1967; Daniels, 1974; Farias et al., 1999). O filtro Butterworth é conhecido por sua qualidade de ser plano na banda de passagem do filtro, desta forma, a função Butterworth foi escolhida para aproximar a função do sistema do filtro. A equação 3.1 representa o cálculo de sua função de amplitude quadrada onde N é a ordem do filtro e Ω_c é a frequência quando a amplitude diminui para -3 tal que pode ser visto pela equação 3.1

$$|H_a(j\Omega)|^2 = \frac{1}{1 + (\frac{\Omega}{\Omega_c})^{2N}} \quad (3.1)$$

em que o filtro Butterworth precisa apenas de duas representações de parâmetros: N e Ω_c . Assim, a ordem N de um filtro passa-baixa é resolvida na equação 3.2, onde

$$N = \frac{1}{2} \frac{\lg(\frac{10^{0.1A_s} - 1}{10^{0.1A_p}})}{\lg(\frac{\Omega_s}{\Omega_p})} \quad (3.2)$$

A_s representa a frequência de corte da banda de parada do filtro passa-baixa, que é fixada em 100 Hz. A_p é a frequência de corte da banda de passagem, com um valor de 80 Hz, Ω_s é a atenuação da banda de parada com o valor de 1,6rad/s e Ω_p é a atenuação da banda de passagem, com o valor de 1,4rad/s (Yang e Xue, 2008).

Em seguida, a equação da função de amplitude do filtro pode ser obtida por meio da equação 3.1:

$$|H_a(j\Omega)| = \frac{1}{\sqrt{1 + (-1)^N (\frac{s}{\Omega_c})^{2N}}}, s = j\Omega, \Omega = -\infty \sim +\infty \quad (3.3)$$

onde s pode ser resolvido na equação 3.4 de duas maneiras.

$$1 + (-1)^N \left(\frac{s}{\Omega_c}\right)^{2N} = 0 \quad (3.4)$$

Quando o valor de N for par:

$$s = \Omega_s e^{j\frac{(2k+1)}{2N}\pi} \quad (3.5)$$

Da mesma forma quando o valor de N for ímpar:

$$s = \Omega_s e^{j\frac{k}{2N}\pi} \quad (3.6)$$

Depois de resumir a equação 3.5 e a equação 3.6 é possível concluir que:

$$P_k = \begin{cases} \Omega_c e^{j\frac{2k+1}{2N}\pi}, & N : \text{números pares}, \quad k = 0, 1, 2 \dots 2N - 1 \\ \Omega_c e^{j\frac{k}{2N}\pi}, & N : \text{números ímpares}, \quad k = 0, 1, 2 \dots 2N - 1 \end{cases} \quad (3.7)$$

A solução P_k obtida pela equação 3.7 é o pólo da função do sistema. No domínio da frequência complexa, esses pontos são equidistantes no círculo de raio Ω_c , da qual, segundo (Faust et al., 2004), o número total é $2N$. A fim de tornar o filtro passa-baixa estabelecido estável, apenas o ponto do polo no semiplano esquerdo do espaço do domínio da frequência pode ser selecionado (Gass e Fu, 2013), em seguida uma vez tendo o polo estável selecionado, a função de transferência do filtro passa-baixa no domínio analógico pode ser obtida como mostrado na equação 3.8 onde

$$H_a(s) = \prod_{\text{Re}[P_k] < 0} \frac{\Omega_c}{s - P_k} \quad (3.8)$$

$$s = \frac{2}{T} \frac{1 - z^{-1}}{1 + z^{-1}} \quad (3.9)$$

a variável s na função de transferência de domínio analógico $H_a(s)$ na equação 3.8 é transformada pela equação 3.9, e por fim, a função de transferência de domínio digital $H(z)$ é obtida. Deste modo, o sinal de ECG da derivação II original passa pelo filtro passa-baixas a fim de reduzir a interferência de EMG.

Contudo quando se trata de medidas de EMG, a interferência da frequência de energia é representada pela interferência de um campo elétrico de 50 Hz e um campo magnético de 50 Hz, de tal modo que, quando a frequência central da interferência da frequência de energia se desvia, faz com que o efeito de filtragem do filtro comum seja afetado. Com isso houve a necessidade de um filtro adaptativo (Meyer-Baese, 2007) para eliminar a interferência e assim evitar a falha do filtro para ruídos de EMG. Para o desenvolvimento do filtro adaptativo, utilizou-se dos princípios básicos do algoritmo de mínimos quadrados (do inglês *Least Mean Square*), *LMS* (Alexander, 1986) para a projeção de um filtro adaptativo conforme o diagrama da figura 3.2.

A entrada $D(n)$ do canal principal, onde n é o número de iterações, contém o sinal do ECG e ruído de interferência de frequência de energia, no entanto, a entrada de referência inclui ruído de referência de correlação cruzada. $S(n)$ é um componente útil do canal de entrada principal. $Y(n)$ é a saída ajustada através do filtro adaptativo, sendo que a ordem do filtro projetado foi 2. X_1 e X_2 correspondem respectivamente a interferência de frequência de energia e interferência de frequência de energia com um deslocamento de fase de 90 graus onde

$$W_1(n+1) = W_1(n) + \mu S(n) X_1(n) \quad (3.10)$$

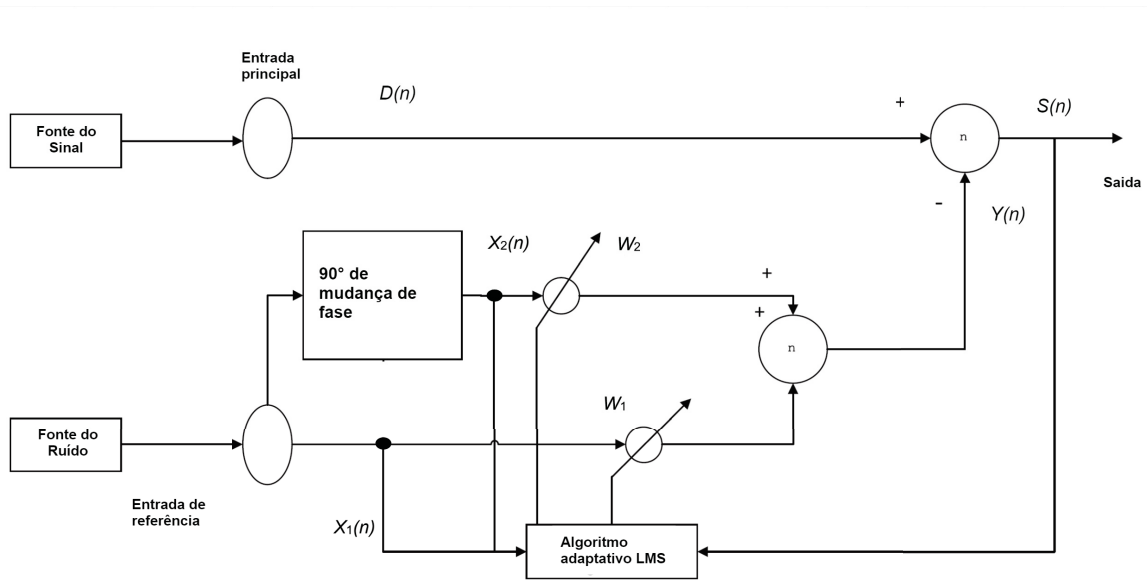


Figura 3.2: Diagrama do filtro adaptativo.

$$W_2(n+1) = W_2(n) + \mu S(n) X_2(n) \quad (3.11)$$

$$Y(n) = X_1(n)W_1(n) + X_2(n)W_2(n) \quad (3.12)$$

$$S(n) = D(n) - Y(n) \quad (3.13)$$

W_1 e W_2 são coeficientes ponderados, onde W_1 corresponde ao coeficiente de interferência de frequência de energia e W_2 corresponde ao coeficiente de interferência de frequência de energia com um deslocamento de fase de 90 graus. A interferência de frequência de energia ponderada é adicionada e subtraída do canal de entrada principal para eliminar a interferência de frequência de energia no canal de entrada principal, sendo ajustado iterativamente por meio do coeficiente de ponderação.

Nas equações 3.10 e 3.11, μ representa o fator de convergência, tendo o seu valor como 0.1 e n o número de iterações. Ao iterar continuamente nas equações 3.10, 3.11, 3.12 e 3.13, o coeficiente de ponderação é ajustado para obter a saída do sinal de ECG $S(n)$ após eliminar a interferência da frequência de energia.

A Figura 3.3 apresenta a forma de onda do sinal original de ECG após diferentes etapas de filtragem. Comparando com a forma de onda do sinal de ECG de entrada, conforme ilustrado na Figura 3.4, pode ser observado que o ruído no sinal original foi filtrado.

3.1.2 Segmentação

Na segmentação dos sinais de ECG, foram utilizados batimentos contínuos no grupo arritmia. Os batimentos contínuos do sinal de ECG foram divididos em batimentos únicos. Cada batimento cardíaco é composto por 300 amostras. A segmentação de ECG é baseada no arquivo de registro de posição de pico da onda R marcado manualmente fornecido pelo banco de dados (Chen et al., 2017). Para reter as informações completas dos batimentos cardíacos, optou-se por manter cada posição de pico R, bem como 99 amostras antes e 200 amostras após a posição de




Figura 3.3: Exemplo de um batimento sem passar pelo filtro.




Figura 3.4: Exemplo de um batimento após filtragem.

pico R. A Tabela 3.1 mostra os tipos de arritmias utilizadas neste estudo e o número de amostras aleatórias.

Tabela 3.1: Tipos de arritmias e a distribuição dos dados.

Tipos de arritmias	Quantidade (batimento)
Contração atrial prematura (PAC)	3.000
Bloqueio do ramo esquerdo (BRE)	8.000
Bloqueio do ramo direito (BRD)	7.200
Contração ventricular prematuro (PVC)	7.100
Batimento normal (BN)	72.000
Total de batidas	97.300

Neste estudo foram utilizados 97.300 batidas em cada base de dados para treinamento, teste na qual o conjunto de teste será dividido em teste e validação. Na figura 3.5 são apresentados os detalhes da distribuição dos dados para os conjuntos de treino, teste e validação. 75% dos dados totais da base foram selecionados aleatoriamente para compor o conjunto de treinamento. Os 25 % restantes foram divididos aleatoriamente para um conjunto de teste. Este conjunto de teste foi dividido em teste e validação em que, para verificar o comportamento e necessidade de ajustes do modelo foram separados (35%) dos dados. Para o conjunto de validação foi selecionado (65%) restantes dos dados para validar o comportamento do modelo proposto onde os resultados obtidos serão utilizado na comparação com as demais abordagens encontradas na literatura.

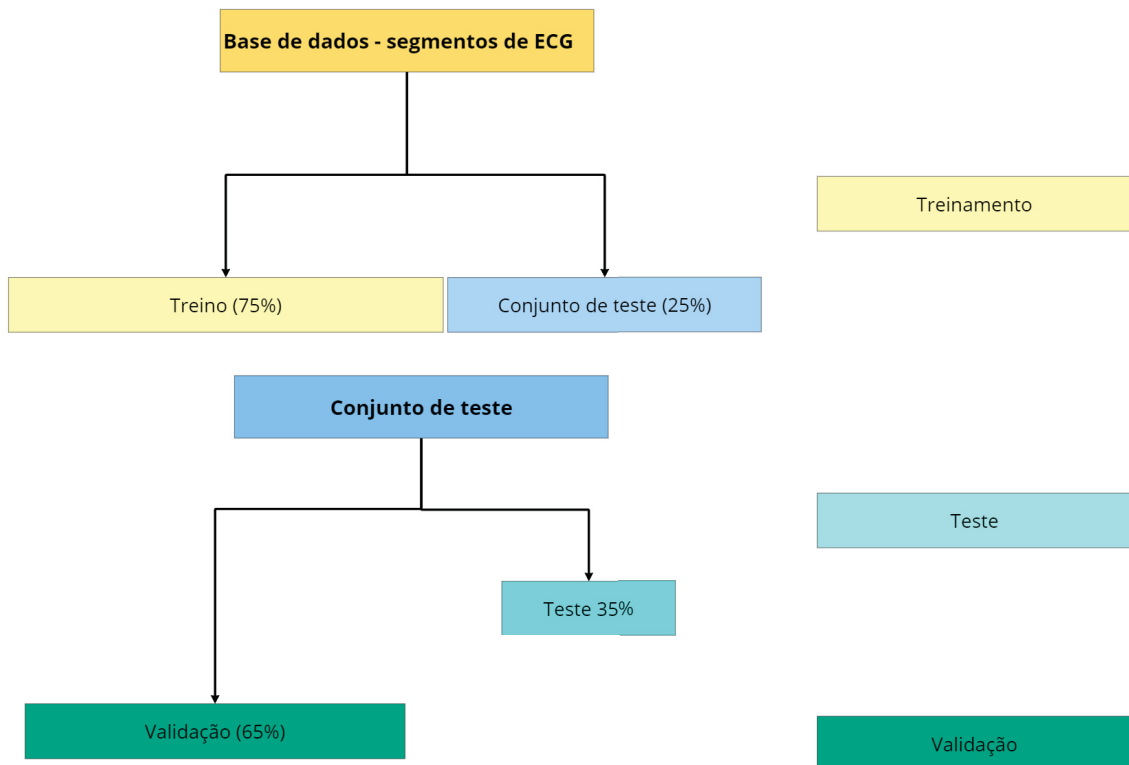


Figura 3.5: Detalhes da distribuição dos dados.

3.2 ARQUITETURA

Para aprender as características do sinal de ECG este estudo propõe um AE baseado em redes LSTM, contendo em sua estrutura uma camada de codificação e decodificação além de entrada e saída. A camada de codificação apresentada na Figura 3.6 é formada por uma rede LSTM de três camadas. Os dados de entrada da primeira camada da rede LSTM é a transformação do sinal original de ECG em um tensor na qual a dimensão da camada é definida em 256. A segunda camada da rede ficou estabelecido uma dimensão de 128 unidades e na terceira camada 64 unidades. A função de ativação definida entre as camadas do codificador foi ReLU. Na sequência da camada de codificação tem-se a camada de decodificação do AE, sendo composta por uma rede LSTM de três camadas e uma camada linear na qual sua estrutura é demonstrada na Figura 3.7.

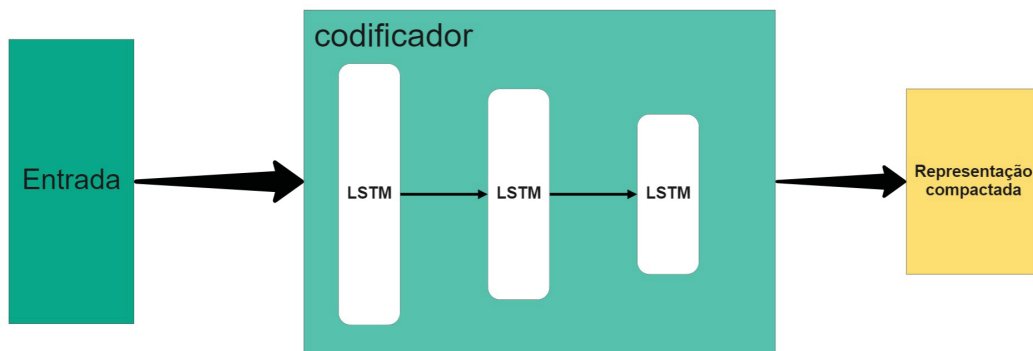


Figura 3.6: Diagrama da estrutura da camada de codificação.

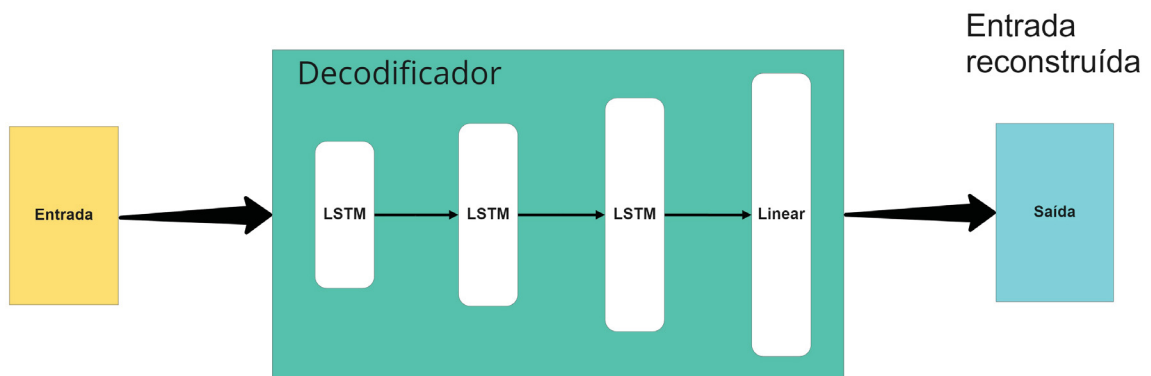


Figura 3.7: Diagrama da estrutura da camada de decodificação.

A dimensão da primeira camada da rede LSTM é definida como 64 unidades da qual recebe os dados comprimidos da camada de codificação. A segunda camada da rede ficou estabelecida como 128 unidades e a terceira camada da rede 256 unidades. Por fim, a camada linear é utilizada para transformar o tensor de saída no formato de dados de ECG (reconstrução do sinal) padrão na qual contém as características do sinal dos dados processados. Os detalhes dos parâmetros utilizados em cada camada são mostrados na Tabela 3.2.

A rede LSTM da camada 1 a ,3 conforme demonstrado na Tabela 3.2, comprime um único batimento cardíaco colocado na entrada de camada a camada, do tamanho de $1 * 300$ para $1 * 64$ de modo a extrair e aprender as características do sinal de batimentos cardíacos únicos.

Tabela 3.2: Detalhes e parâmetros de cada camada do AE

No	Nome da camada	Tamanho unidade	Outros parâmetros
1	LSTM	256	Return Sequences = True
2	LSTM	128	Return Sequences = True
3	LSTM	64	Return Sequences = True
4	LSTM	64	Return Sequences = True
5	LSTM	128	Return Sequences = True
6	LSTM	256	Return Sequences = True
7	LSTM	256*300	

Em seguida, o dado comprimido é expandido para $1 * 300$ por meio das camadas 4 a 7 da rede LSTM e a camada linear, conforme descrito na Tabela 3.2. Diante disso, o erro entre os dados expandidos e os dados originais são calculados e, em seguida, o método de retroalimentação e retropropagação é aplicado fazendo com que os parâmetros internos do modelo sejam atualizados continuamente afim de que, o erro entre a saída reconstruída e a entrada original seja cada vez menor. Para a redução do erro foi utilizado um algoritmo para otimização baseada em gradiente de primeira ordem de funções objetivo estocásticas, com base em estimativas adaptativas de momentos de ordem inferior, mais conhecido como *adam* (Kingma e Ba, 2014), com taxa de aprendizagem de 0,001. Os parâmetros de uma camada LSTM foram considerados como padrão de acordo com a Tabela 3.3. É importante ressaltar que quaisquer outros parâmetros além daqueles mencionados na tabela foram definidos como "none" ou 0. Sendo assim, podemos aprender melhor as características da série temporal de cada tipo de batimento.

A rede LSTM que foi utilizada para o classificador contém cinco camadas. Um bloco LSTM de 32 unidades foi colocado na primeira camada da rede. Uma camada plana (do inglês *flatten*) foi utilizada para ajustar os dados de saída do LSTM e torná-lo adequado para interface com as camadas densas seguintes. Após a camada plana, foi adicionada uma camada densa de 128 unidades. Uma camada de *dropout* com taxas de 0,1 foi usada para evitar problemas de sobreajuste durante o treinamento. Em seguida, uma camada densa de cinco unidades foi posicionada como a última camada da rede, para reconhecer automaticamente as classes de tipos de batimentos de ECG. Portanto, a rede LSTM classifica os tipos de arritmia a partir de recursos fornecidos pelo AE. Os parâmetros da rede LSTM utilizados para o processo de classificação são apresentados na Tabela 3.4

Como foi proposto um AE para extrair características e conforme mencionado na seção anterior foram selecionados apenas cinco classes (tipos de batimentos) da base de dados, portanto optou-se por treinar um AE para cada classe, de modo a obter as características específicas de cada batimento, conforme será discutido na próxima seção de resultados.

Tabela 3.3: Parâmetros da LSTM do AE

parâmetros	valor
<i>activation</i>	tanh
<i>recurrent activation</i>	sigmoid
<i>use bias</i>	True
<i>kernel initializer</i>	glorot uniform
<i>recurrent initializer</i>	orthogonal
<i>bias initializer</i>	zeros
<i>unit forget bias</i>	True

Tabela 3.4: Detalhes de camada e parâmetros usado para o modelo LSTM de classificação

No	Nome da camada	Tamanho unidade	Outros parâmetros
1	LSTM	32	Return Sequences = True
2	Plana	-	-
3	Densa	128	função de ativação = ReLU
4	<i>Dropout</i>	-	taxa = 0.1
5	Densa	5	função de ativação = softmax

3.3 MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO

Para validar o desempenho de um modelo após o treinamento de forma relevante, utiliza-se de métricas de validação, quando se refere à comparação de um objeto reconstruído (predita) em relação a um objeto nativo original, com a finalidade de avaliar quão similar é a reconstrução do objeto predito. Uma métrica frequentemente utilizada em tarefas de regressão como o MAE, na qual avalia o erro entre o objeto original e o mesmo objeto reconstruído, garantindo assim a confiabilidade do resultado. O MAE pode ser calculado pela equação 2.17 conforme abordado no capítulo anterior, tendo como satisfatório valores próximos de 0. Segundo (Tavakoli et al., 2020) pode se utilizar do MAE como uma função de perda para mensurar o erro de reconstrução do sinal pelo do AE. Entretanto para avaliar o desempenho do modelo em funções de classificação métricas relevantes como: Acurácia (Acc) de modo a medir quantas observações, tanto positivas quanto negativas, foram classificadas corretamente. Em outras palavras, a acurácia é a razão entre o número de previsões corretas e o número total de previsões feitas pelo modelo conforme ilustrado na equação 3.14

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.14)$$

onde, TP é verdadeiro positivo, FP é falso positivo, TN é verdadeiro negativo e FN é falso negativo. A Precisão (Pr) representa a proporção de observações corretamente previstas como positivas em relação ao número total de observações previstas como positivas pelo modelo sendo frequentemente apresentada em porcentagem conforme ilustrado na equação 3.15,

$$Pr = \frac{TP}{TP + FP} \quad (3.15)$$

tal que quanto maior o seu valor, menor será a taxa de falsos positivos. Ou seja, quanto maior a precisão, menor será a chance do modelo classificar uma observação negativa como positiva. A sensibilidade (Se) também conhecida como recall é uma métrica que representa a proporção de observações positivas que são corretamente identificadas pelo modelo, em relação ao número total de observações que deveriam ser classificadas como positivas conforme ilustrado na equação 3.16.

$$Se = \frac{TP}{TP + FN} \quad (3.16)$$

Em outras palavras, a sensibilidade mede a capacidade do modelo de detectar todos os casos positivos existentes, evitando assim falsos negativos. É uma métrica especialmente útil em problemas em que os falsos negativos são indesejados, como em exames médicos ou em sistemas de detecção de fraudes. A sensibilidade é geralmente apresentada em porcentagem e quanto maior a sua pontuação, menor será a taxa de falsos negativos.

Para tal propósito, este estudo optou-se por utilizar por métricas de avaliação de desempenho para qualificar e validar os resultados encontrados pelo experimento proposto.

3.4 CONSIDERAÇÕES DO CAPÍTULO

Este capítulo teve o propósito de apresentar os processos relacionados ao desenvolvimento da abordagem proposta. Para isso foi discutido a base de dados a ser utilizada em que, neste caso foi incluída uma base nova que será utilizada para avaliar o modelo em um cenário diferente porém, preservando as características básicas do sinal. Além disso foi proposta uma etapa de pré processamento do sinal da qual foi aplicado um filtro adaptativo para eliminar ruídos e tratar as EMGs e outras possíveis interferências somado a uma segmentação do sinal de modo a reduzir o sinal em batimentos cardíacos. Na próxima etapa foi apresentado a arquitetura proposta que consta de um AE utilizando de uma rede LSTM e um classificador e por fim, uma discussão sobre quais métricas de validação serão abordadas para avaliar a desempenho do modelo proposto.

4 RESULTADOS E DISCUSSÃO

Neste trabalho o desenvolvimento do algoritmo foi feito utilizando algumas bibliotecas do python sendo uma delas para aprendizado profundo como o Tensorflow/Keras. Quanto ao hardware utilizado tendo um processador AMD Ryzen 5 3600X 6-Core unidade de central de processamento (do inglês *central processing unit*, CPU) @ 3.79GHz e computador de 16GB de memória de acesso volátil (do inglês *random access memory*, RAM) e uma placa de vídeo de 8GB (NVIDIA GeForce GTX-3070).

4.1 BASE DE DADOS

A base de dados selecionada para o experimento foram extraídas amostras de sinais de ECG da base de dados MIT-BIH arrhythmia (Moody e Mark, 2001) como mencionado no capítulo 2. Contudo, para a validação do algoritmo optou-se por fazer uma validação em uma base outra base de dados diferente contendo as mesmas características, utilizando dados extraídos da base MIT-BIH arritmia supraventricular (do inglês *supraventricular arrhythmia*) contendo 78 trechos de dois canais de meia hora. O tipo de batimento cardíaco gravado é primeiro calibrado automaticamente e, em seguida, verificado e corrigido por médicos profissionais (Greenwald et al., 1990).

4.2 RESULTADOS DE CLASSIFICAÇÃO DO MODELO

O AE proposto foi utilizado para treinar em cinco tipos diferentes de conjuntos de dados de treinamento de ECG, para extrair os recursos de série temporal de seus tipos de batimentos cardíacos, sendo assim capaz de aprender as características de cada tipo de batimento cardíaco selecionado para este estudo, conforme Figura 4.1. Dessa forma, o erro entre a sequência de dados de saída e a sequência de dados de entrada torna-se estável, e o treinamento do modelo e a coleta das características da sequência de tempo de vários tipos de sinais de ECG são concluídos. Para o treinamento foi utilizada uma opção denominada parada antecipada (do inglês *Early Stopping*) a fim de interromper o treinamento quando uma métrica monitorada não mais apresentar melhorias, para isso um parâmetro de paciência (do inglês *patience*) foi setado em 5, isto é, se passar mais de 5 épocas sem melhorar, o treinamento é encerrado de forma automática. Para todos os resultados do experimento, a fase de treinamento do modelo os parâmetros de controle foram ajustados conforme a tabela 4.1 inspirado em (Yildirim et al., 2018; Yildirim, 2018; Yildirim et al., 2019), dentre eles estão tamanho de lote, épocas, otimizador conforme mencionado no capítulo anterior. Os parâmetros que compõe a camada LSTM foram todos setados em padrão (do inglês *default*) em outras palavras foram definidos como *none* ou 0 com exceção daqueles mencionados no capítulo anterior.

Tabela 4.1: parâmetros de controle.

parâmetro	Valor
Épocas	100
Tamanho do lote	32
Paciência	5
Taxa de aprendizado	0,001

Para verificação do AE foi utilizado o MAE, como função de custo durante o treinamento, como métrica a ser monitorada. Os resultados para cada um dos tipos de batimentos se estabilizou em 0,1. Foi possível perceber que ao utilizar de um sinal diferente daquele aprendido, o erro aumenta estabilizando entre 20 a 25. Isto posto para o classificador selecionar qual saída (sinal reconstruído) será utilizado, foi criado um limiar de erro permitido entre 0,1 a 0,3 na qual foi incluído no pipeline de inferência.

Quando os dados de um sinal de batimento cardíaco são inseridos no modelo conforme a Figura 4.1, cinco AE com diferentes tipos de características de séries temporais de sinal de ECG são respectivamente alimentados e, em seguida, os tipos de sinais de ECG de entrada são filtrados por um limiar de acordo com o valor do erros dos sinais reconstruídos dos cinco diferentes AEs. O tipo de batimento cardíaco na saída do AE com o menor erro de reconstrução, corresponde ao sinal com as características do tipo de batimento da qual será utilizado pelo classificador.

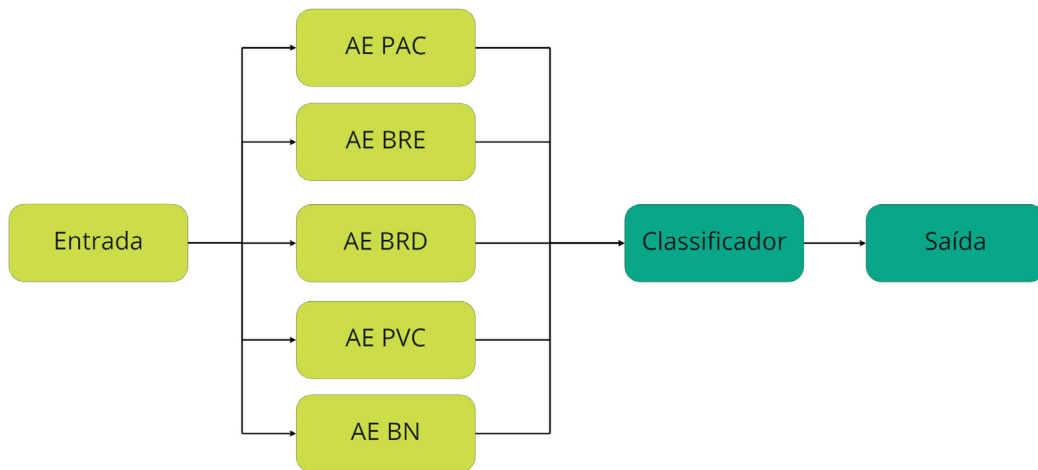


Figura 4.1: Classificação dos tipos de batimentos cardíacos.

Inspirado em (Gómez et al., 2020) da qual utiliza uma rede LSTM maior contendo cinco camadas, optou-se pela realização de experimentos comparativos com outros AEs utilizando o mesmo princípio de construção proposto, porém, com tamanhos diferentes em número de camadas, como mostrado na Tabela 4.2. Conforme apresentado na Tabela 4.2, foram propostos AE com rede de 2 camadas LSTM, 3 camadas LSTM, 4 camadas LSTM e 8 camadas LSTM, tanto para codificação quanto para decodificação. Para a validação, cinco grupos de dados que não foram utilizados no treinamento (segundo a divisão estabelecida no capítulo anterior), foram utilizados para validação do modelo. Os modelos com 5, 6, e 7 camadas foram desconsiderados uma vez que apresentaram resultados muito próximos dos valores de 4 ou 8 camadas além de um elevado custo computacional em detrimento das selecionadas. Olhando para o tempo de processamento o modelo com 8 camadas gastou em média de 29.880 segundos (8,3 horas) enquanto, o modelo com 2 camadas gastou em média 12.600 segundos (3,5 horas). Foi possível concluir que a cada camada adicional, o intervalo de tempo varia em incrementos de 3600 segundos (1 hora).

Segundo o estudo comparativo dentre os AE com diferentes tamanhos, foi possível concluir de que um AE com 3 camadas LSTM obteve o melhor resultado em tarefas de classificação apresentando uma acurácia de 98,57% em teste, sendo assim, selecionado para os demais testes devido ao seu desempenho.

Tabela 4.2: AE com rede LSTM com diferentes quantidades de camadas.

Modelos	Acc em classificação	
	Treinamento	Teste
2 camadas LSTM	93,77%	92,47%
3 camadas LSTM	98,31%	98,57%
4 camadas LSTM	96,64%	97,11%
8 camadas LSTM	98,28%	97,13%

Tabela 4.3: Matriz de confusão aplicado a base de dados de arritmia do MIT-BIH

		Predito					Acc(%)	Se(%)	Pr(%)
		A	L	N	R	V			
Original	A	252	1	8	0	1	98,57	95,09	96,16
	L	5	677	14	4	0			
	N	5	5	6279	6	5			
	R	2	3	10	615	1			
	V	1	1	10	2	607			

O modelo de classificação foi testado no base de dados de arritmias do MIT-BIH e na base de dados de arritmias supraventriculares do MIT-BIH, respectivamente. As matrizes de confusão obtidas são mostradas na Tabela 4.3 e Tabela 4.4, respectivamente.

Na Tabela 4.3 os resultados indicam uma acurácia geral de 98,57%, com sensibilidade e precisão variando de 95,09% a 99,66% e de 96,16% a 97,74%, respectivamente, para as diferentes classes de arritmia. Os resultados sugerem que o modelo proposto é capaz de identificar corretamente a grande maioria dos casos de arritmia. As classes com menor sensibilidade foram a "A"(95,09%) e "R"(98,08%), o que significa que o modelo pode ter dificuldade em identificar essas arritmias em alguns casos. No entanto a classe "N"teve a maior sensibilidade (99,34%) e precisão (99,66%), indicando que o modelo foi eficaz em identificar essa arritmia.

A Tabela 4.4 os resultados na base de dados de arritmias supraventricular indicam que a acurácia geral alcançada pelo modelo foi de 97,59%. Em relação à sensibilidade, a classe "A"apresentou a menor taxa (89,55%), enquanto a classe N teve a maior taxa (99,17%). Em relação à precisão, a classe "V"apresentou a menor taxa (92,43%), enquanto a classe "N"teve a maior taxa (98,97%).

Observa-se que a taxa de acerto foi elevada para todas as classes, indicando que o modelo proposto foi capaz de classificar corretamente a maioria das amostras. No entanto, a classe "A"apresentou a menor sensibilidade, indicando que algumas amostras dessa classe foram classificadas erroneamente como outras classes. Além disso, a classe "V"apresentou a menor precisão, o que indica que algumas amostras de outras classes foram erroneamente classificadas como "V". Em geral, os resultados obtidos na Tabela 4.4 sugerem que o modelo proposto é capaz de classificar corretamente a maioria das amostras de arritmia supraventricular. Contudo, ainda existem alguns casos em que o modelo pode apresentar falhas, especialmente na classe "A"e na classe "V".

4.3 DISCUSSÃO DOS RESULTADOS

Nos últimos anos, a base de dados de arritmias do MIT-BIH tornou-se um tema de bastante atenção na pesquisa de classificação de arritmias cardíacas. Os resultados experimentais deste estudo demonstram que os sinais de ECG normais e de arritmia cardíaca podem ser

Tabela 4.4: Matriz de confusão aplicado a base de dados de arritmia supraventricular do MIT-BIH

		Predito					Acc(%)	Se(%)	Pr(%)
		A	L	N	R	V			
Original	A	240	5	5	8	4	97,59	89,55	91,60
	L	10	647	20	13	10		94,87	92,43
	N	7	18	6235	20	20		99,17	98,97
	R	5	4	4	613	5		92,32	97,15
	V	6	8	23	10	574		93,64	92,43

Tabela 4.5: Matriz de confusão aplicado a base de dados de arritmia do MIT-BIH sem pré-processamento

		Predito					Acc(%)	Se(%)	Pr(%)
		A	L	N	R	V			
Original	A	171	26	28	23	14	90,83	61,96	65,27
	L	32	517	98	32	21		75,36	73,86
	N	58	121	5932	129	60		96,75	94,16
	R	7	8	20	581	15		74,58	92,02
	V	8	14	53	14	532		82,87	85,67

detectados automaticamente por meio de métodos como AE para extração de características e redes neurais para classificação. A abordagem proposta se concentra em fornecer evidências para apoiar a alegação de que os sinais de ECG de arritmia cardíaca demonstram dinâmica alterada em comparação com sinais de ECG normais. Além disso, fornece um método automático e objetivo para distinguir cinco tipos de batimentos cardíacos por meio de sinais de ECG.

Para isso na abordagem proposta, o processo de pré-processamento do sinal de ECG foi considerado uma etapa importante, visto que para um batimento cardíaco analisado por meio de sinais de ECG sob o mesmo limite de tempo, as amplitudes de diferentes tipos de batimentos cardíacos nas bandas de sinal correspondentes, como onda P, complexo QRS e onda T, são diferentes. Médicos profissionais também julgam diferentes tipos de batimentos cardíacos a partir desse ponto de vista. No entanto, existem alguns tipos de batimentos cardíacos que não diferem significativamente em amplitude dentro da mesma banda, e no processo de coleta de sinais de ECG, devido ao fenômeno de polarização da pele e os problemas do próprio equipamento de aquisição, interferência de frequência de energia e outros sinais de interferência aumentam a dificuldade de distinguir as partes com pequenas diferenças de amplitude entre alguns batimentos cardíacos, perfazendo com que o modelo de classificação tenha o seu desempenho reduzido. A fim de melhorar o desempenho do modelo foi proposto um filtro adaptativo discutido no capítulo anterior e, para confirmar a melhora significativa foi utilizado do mesmo modelo de classificação porém, sem a etapa de processamento de modo a experimentar os dados não processados. Os resultados obtidos podem ser encontrados na Tabela 4.5.

Portanto, foi possível concluir, conforme tabelas, que com a etapa de pré-processamento temos uma melhora significativa na desempenho do modelo de 8.57% em acurácia para dados de arritmia.

Recentemente, diferentes abordagens têm sido propostas na literatura para detectar automaticamente os sinais de ECG de arritmia, na qual muitos estudos se concentram em lidar com o problema de classificação de dados de ECG obtidos da base de dados de arritmias do MIT-BIH. Embora os conjuntos de dados utilizados nestes estudos não sejam idênticos, são úteis para fins de comparação, pois compartilham a classificação de sinais de ECG sendo possível uma comparação de forma justa. A Tabela 4.6 apresenta um resumo da comparação do desempenho

Tabela 4.6: Estado da arte sobre a detecção automática das arritmias.

Autor e ano	Quantidade de batimentos	Abordagem	Desempenho		
			Acc	Se	Pr
(Yeh et al., 2009)	102.060	Análise discriminante Linear	96,23%	92,49%	
(Martis et al., 2012)	1.247	SVM-RBF	98,48%	98,90%	
(Li et al., 2016)	1.800	DWT, kernel ICA e PCA, SVM	98,8%	98,50%	98,91%
(Elhaj et al., 2016)	110.094	DWT, PCA, HOS, ICA, SVM-RBF	98,91%	98,91%	
(Zubair et al., 2016)	100389	CNN	92,70%		
(Kiranyaz et al., 2016)	83.648	CNN	99,00%	93,90%	
(Sahoo et al., 2017)	109.494	DWT, SVM	98,39%	99,87%	99,21%
(Acharya et al., 2017b)	109.449	CNN	94,03%	96,71%	
(Acharya et al., 2017a)	21.709	CNN	92,50%	98,09%	
(Oh et al., 2018)	16.499	LSTM e CNN	98,10%	97,50%	98,69%
(Yildirim, 2018)	7.376	LSTM	99,39%		
Esse estudo	97.300	AE, LSTM	98,57%	97,98%	97,55%

de classificação deste estudo com outras abordagens encontrada na literatura na mesma base de dados. Para esta comparação foi-se utilizado os resultados obtidos no conjunto de validação.

Sahoo et al. (2017) apresentaram uma abordagem por meio de transformada wavelet discreta (do inglês *Discrete wavelet transform*, DWT) baseada em multi-resolução para extrair características para classificação e detecção completa de batimentos cardíacos.

Li et al. (2016) abordaram componentes de análise independente (do inglês *Independent Component Analysis*, ICA), PCA e DWT para extrair características de sinais de ECG no domínio do tempo e no domínio da frequência, respectivamente, para assim obter uma classificação completa por meio de máquinas de vetores de suporte (do inglês *Support Vector Machine*, SVM). (Yeh et al., 2009) abordaram uma forma de extração características morfológicas diretamente dos componentes de ECG e, em seguida, usou-as para classificação de batimentos cardíacos. (Elhaj et al., 2016) obteve bons resultados utilizando de uma combinação de redes neurais e máquinas de vetor de suporte para classificar batimentos cardíacos. (Martis et al., 2012) realizou a segmentação de batimentos do sinal de ECG e, em seguida, implementou análise de

componentes principais para completar a classificação do sinal de ECG por meio de SVM com função de base radial (do inglês *Radial Basis Function*, RBF).

Muitos métodos de aprendizado profundo também foram propostos por pesquisadores para a detecção de classificação de arritmias. (Oh et al., 2018) apresenta uma abordagem híbrida utilizando de CNN e LSTM para a detecção de arritmias. (Acharya et al., 2017b) utiliza de CNN para identificar e classificar os sinais de ECG e no mesmo ano apresenta outra forma de detectar e classificar sinais de ECG (Acharya et al., 2017a). Demais estudos utilizando de aprendizado profundo também obtiveram resultados satisfatórios próximo ao estado da arte como em (Zubair et al., 2016) e (Kiranyaz et al., 2016). (Yildirim, 2018) utilizou uma camada baseada em wavelets para decompor os sinais de ECG em sub-bandas de frequência em diferentes escalas, que foram usadas como sequências para a entrada de LSTMs para a tarefa de classificação de 5 classes de batimentos cardíacos.

Tabela 4.7: Estudos recentes sobre a detecção automática das arritmias.

Autor e ano	Abordagem	Base de dados	Número de classes	Desempenho
(Gómez et al., 2020)	BiLSTM, LSTM	MIT-BIH	2	Acc: 82,14% Se: 87,14% Pr:79,22%
(Tang e Tang, 2021)	LSTM, características morfológicas	MIT-BIH	2	Acc: 82,10% Se: 78,40% Pr:84,79%
(Chen et al., 2020)	CNN, BLSTM	MIT-BIH	4	Acc: 96,77% Se: 74,89% Pr:81,24%
(Hammad et al., 2020)	DNN	MIT-BIH	5	Acc: 98,00% Se: 99,70% Pr:95,80%
(Wang et al., 2020)	CNN	CPSC 2018	9 e 4	Acc: 98,57% Se: 97,98% Pr:97,55%
Esse estudo	AE, LSTM	MIT-BIH	5	Acc: 98,57% Se: 97,98% Pr:97,55%

Além disso, na Tabela 4.7 apresenta um resumo dos resultados de vários estudos recentes que utilizaram diferentes abordagens para detectar arritmias em ECGs. Todos os estudos foram realizados na base de dados MIT-BIH, exceto um que utilizou a base de dados CPSC 2018. (Gómez et al., 2020) apresenta um modelo de classificação de ECG usando rede BiLSTM inspirado em (Yildirim et al., 2018), que implica em uma rede LSTM de 5 camadas obtendo como precisão final 82,10% de acurácia.

(Tang e Tang, 2021) utiliza de uma rede LSTM somada a extração de características morfológicas do sinal de ECG obtendo um resultado de 82,14% de acurácia para a tarefa de

classificação. Foi possível identificar que, comparado com os dois modelos acima, o modelo proposto apresenta um maior resultado, conforme apresentado na Tabela 4.6, quando se trata de classificação. Cabe mencionar que com a abordagem proposta por (Tang e Tang, 2021), o modelo proposto de classificação apresenta uma característica de que não precisa definir manualmente o cálculo de características morfológicas como intervalo entre os picos de RR. (Hammad et al., 2020) nos apresenta uma abordagem utilizando de rede neural profunda aliado a algoritmo genético para extração de características e classificação dos sinais de ECG. (Chen et al., 2020), em sua abordagem apresenta um modelo de detecção de arritmia de forma híbrida baseado na fusão de CNN e BLSTM. As informações morfológicas do batimento cardíaco atual e as informações de tempo dos batimentos cardíacos adjacentes são coletadas como base de julgamento da classificação do batimento cardíaco e, (Wang et al., 2020) utiliza de uma abordagem por meio de CNN para adotar os métodos de extração de recursos em várias escalas e complementaridade de informações em escala cruzada para sinais de ECG, obtendo vários *kernels* de convolução em diferentes domínios de aceitação e realizou a extração de características de segmentos de sinal de diferentes tamanhos. No entanto, quando a rede CNN for muito profunda, os parâmetros próximos à camada de entrada do modelo sofrerão pequenos ajustes de forma mais lenta devido ao seu tamanho usando retro-propagação do erro para modificar os parâmetros, com isso, problemas como o desaparecimento de gradiente e explosão de gradiente não podem ser evitados.

Este estudo (destacado em negrito nas Tabelas 4.6 e 4.7) se diferencia de outros estudos na literatura por explorar a utilização de um filtro adaptativo e pela realização tanto da extração de características quanto da classificação dos dados de ECG por meio de metodologias de aprendizado profundo. Embora existam outros estudos na literatura que tenham utilizado redes LSTM para classificar sinais de ECG (Yildirim, 2018; Oh et al., 2018; Gómez et al., 2020; Tang e Tang, 2021), a principal diferença deste estudo é o uso de AE para a extração de características dos sinais de ECG, o que melhorou o desempenho de classificação da rede LSTM. Isso difere de outras abordagens recentes apresentadas na Tabela 4.7.

Também foi possível identificar que em algumas abordagem existe a necessidade de definir manualmente o intervalo de extração de recursos com antecedência visto que quando trata-se de uma grande número de extração de características isso pode se tornar um processo com alto custo.

O método proposto neste estudo tem potencial para servir como meio técnico de apoio a outras abordagens. Embora a precisão de classificação não seja superior à relatada em (Yildirim, 2018), apresenta-se uma nova ferramenta de classificação junto com a construção de um novo formato para se extrair características do sinal em vez de usar diretamente os sinais de ECG.

4.4 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo, foram apresentados e discutidos os resultados obtidos com a abordagem proposta. A primeira seção abordou brevemente as bases de dados utilizados neste estudo. Na segunda seção foi abordado os resultados da reconstrução do sinal pelo AE, bem como as tarefas de classificação nos dados de validação das duas bases. Além disso, foram realizados experimentos comparativos com outros AEs que utilizam o mesmo princípio de construção proposto, mas com tamanhos diferentes em número de camadas, tendo sido obtido o melhor resultado com três camadas.

Na terceira seção, foram discutidos os resultados em comparação com abordagens do estado da arte e com abordagens mais recentes. Constatou-se que algumas abordagens

ainda carecem de definição e ajuste de parâmetros de forma manual na etapa de extração de características.

Com base nos resultados apresentados, conclui-se que a abordagem proposta apresenta desempenho competitivo em relação a outras abordagens existentes na literatura. A utilização do AE para a extração de características e a classificação das arritmias apresentou resultados promissores. Contudo, ainda é necessário aprimorar a extração de características para melhorar ainda mais o desempenho.

5 CONCLUSÃO

Devido ao crescimento do número de técnicas para automatizar o reconhecimento e classificação de sinais de ECG, torna-se evidente a importância de recursos para auxiliar os profissionais da saúde a prevenir e diagnosticar mudanças de padrão nos batimentos cardíacos, tarefas estas que podem impactar na qualidade de vida do paciente. Dentre estes distúrbios no padrão dos batimentos cardíacos encontram-se arritmias cardíacas. No entanto, as abordagens tradicionais de detecção de arritmia, incluindo a investigação manual dos registros de ECG, são demoradas e propensas a erros, além de serem, às vezes, subjetivas gerando uma dificuldade para os médicos e equipes médicas para distinguir os diferentes padrões de arritmias. Para isso o diagnóstico de forma antecipada dos tipos de arritmias tem importância na redução do risco e da taxa de incidência de eventos cardiovasculares.

Esta dissertação teve como objetivo avaliar abordagens de aprendizado de máquina para detecção de anomalias em séries temporais com o intuito de classificar de forma automática arritmias cardíacas.

Nos últimos anos, de acordo com as referências citadas no Capítulo 2, foi possível identificar que o modelo de referência mais utilizado para a classificação de ECG está focada principalmente em CNN, além de usar a transformada *wavelet* visando utilizar as potencialidades existentes buscando alcançar um desempenho melhor. O algoritmo proposto foi selecionado a partir da pesquisa bibliográfica uma vez que não foram identificadas modelos que utilizam de AE com camadas de rede LSTM. O AE no contexto de extração de características e filtragens de sinais de ECG possui um número relativamente pequeno de publicações em relação a CNN ou a modelos híbridos que utilizam de CNN e RNN. Para isso foi proposto um algoritmo que utiliza de AE para extração de características somado a um classificador também utilizando de uma rede LSTM na qual foi possível encontrar um resultado satisfatório em tarefas de classificação por meio de um estudo comparativo.

A etapa de pré-processamento do sinal de ECG foi considerada importante visto que o tratamento dos sinais buscou reduzir a interferência de EMG, movimento do eletrodo e ruído de flutuação da linha de base no ECG conforme mencionado no capítulo 3. A fim de melhorar o desempenho do modelo foi proposto um filtro adaptativo somado a uma segmentação do sinal, na qual foi possível identificar um impacto significativo nos resultados concluindo que, os ruídos afetam na extração de características dos sinais e consequentemente na classificação do mesmo.

Para o processamento e extração de características do sinal foi proposto um AE, treinado em cinco tipos (classes) diferentes em conjuntos de dados de treinamento de ECG, para extrair os recursos de série temporal de seus tipos de batimentos cardíacos, de modo a aprender as características de cada tipo de batimento cardíaco. Foi identificado que o erro entre a sequência de dados de saída e a sequência de dados de entrada no AE apresentou-se estável em um valor abaixo de 1.

Contudo por meio das métricas de desempenho foi possível identificar o tamanho ideal do AE e ajustes dos hiperpâmetros mediante a uma comparação entre os resultados de acurácia dos modelos de diferentes tamanhos da qual o modelo com 3 camadas obteve o melhor desempenho conforme mencionado no capítulo 4. Também foi possível identificar um comportamento satisfatório do modelo nas tarefas de classificação aplicado nos bancos de sinais de ECG Physionet. Comparado com outros modelos de DL em tarefas de classificação de ECG, este modelo obteve a mesma ou até uma acurácia maior, entretanto a estrutura de construção do modelo é simples em tamanho de arquitetura contendo uma pequena variação nos

hiperparâmetros de modo a proporcionar uma fácil reprodução, e também, a mitigar as chances de problemas como desaparecimento do gradiente.

Os resultados obtidos pelo algoritmo proposto, apresentaram que, não há necessidade de definir ou ajustar manualmente os parâmetros de entrada do modelo com antecedência, de forma que os sinais de ECG pré-processados podem ser treinados e classificados diretamente, apresentando resultados satisfatórios em comparação com outras abordagens encontradas na literatura. A abordagem proposta também descarta o problema do desaparecimento do gradiente em tarefas de classificação de sinais de ECG encontrado em abordagens que utilizam de arquiteturas com maior número de camadas como CNN.

Contudo algumas desvantagens foram encontradas, uma vez que o modelo apresentado para classificação de sinais de ECG utiliza de um julgamento de séries temporais de ECG da qual utiliza de um limiar contendo uma regra para selecionar o menor erro como entrada para a classificação. Ao considerar de forma abrangente as características de julgamento eficazes propostas em outros estudos anteriores (como transformada wavelet, características morfológicas de ECG, etc.), os resultados do modelo serão mais confiáveis. No entanto, o modelo atingiu os objetivos propostos e os resultados obtidos foram satisfatórios tal que foi possível constatar por meio de experimentos comparativos.

5.1 PESQUISA FUTURA

Em estudos futuros além da dissertação, sugere-se novas combinações de modo a explorar soluções de engenharia de características específicas para processamentos de sinais, e inteligência computacional para monitoramento de ECG, com um foco particular em como esses métodos podem ser usados de forma eficiente para enfrentar os desafios emergentes do monitoramento individual de ECG dinâmico, contínuo e de longo prazo, e feedback em tempo real, buscando ajudar a esclarecer e fomentar investigações adicionais nesse campo, para explorar aplicações racionais de engenharia de características e inteligência computacional no monitoramento de ECG.

Para isso, existem outras formas como abordagens de previsão de sinais de séries temporais usando redes neurais artificiais aplicadas a ECG. A pesquisa apresenta diversos métodos de processamento de sinais usados na previsão de séries temporais, mas cada método é específico para o problema que resolve. Os métodos atuais envolvem o uso de diferentes tipos de filtros adaptativos, dos quais o método mais comum é o algoritmo LMS utilizado neste estudo, contudo abordagens recentes demonstram outras possibilidades em substituição do filtro por abordagens de aprendizado de máquina.

Além disso, os métodos ensemble (do inglês *ensemble learning*), também denominado de aprendizado por agrupamento, podem ser utilizados para combinar o resultado de múltiplos modelos, buscando produzir um modelo mais preciso. A otimização de hiperparâmetros de forma automática utilizando otimização bayesiana pode ser outra abordagem interessante para melhorar a precisão dos modelos utilizados.

Novas abordagens de métodos de aprendizado profundo também podem ser exploradas para melhorar a classificação de batimentos cardíacos de arritmia de forma automática, sem a necessidade de um julgamento manual de características. Essas abordagens podem ser aplicadas em cenários de eventos em tempo real e com sinais de longa duração, tornando o monitoramento de ECG ainda mais eficiente e preciso.

Em resumo, apresenta-se possibilidades de explorar soluções de engenharia de características e inteligência computacional para o monitoramento de ECG, com o objetivo de enfrentar os desafios emergentes desse campo e melhorar a precisão e eficiência do monitoramento.

REFERÊNCIAS

- Acharya, U. R., Fujita, H., Lih, O. S., Hagiwara, Y., Tan, J. H. e Adam, M. (2017a). Automated detection of arrhythmias using different intervals of tachycardia ecg segments with convolutional neural network. *Information Sciences*, 405:81–90.
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A. e Tan, R. S. (2017b). A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*, 89:389–396.
- Ajit, A., Acharya, K. e Samanta, A. (2020). A review of convolutional neural networks. Em *International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, páginas 1–5.
- Alam, M., Samad, M., Vidyaratne, L., Glandon, A. e Iftekharuddin, K. (2020). Survey on deep neural networks in speech and vision systems. *Neurocomputing*, 417:302–321.
- Albawi, S., Mohammed, T. A. e Al-Zawi, S. (2017). Understanding of a convolutional neural network. Em *International Conference on Engineering and Technology (ICET)*, páginas 1–6, Antalya, Turkey. IEEE.
- Alcaraz, R., Abásolo, D., Hornero, R. e Rieta, J. J. (2010). Optimal parameters study for sample entropy-based atrial fibrillation organization analysis. *Computer Methods and Programs in Biomedicine*, 99(1):124–132.
- Alexander, S. T. (1986). *The Least Mean Squares (LMS) Algorithm*, páginas 68–86. Springer, New York, USA.
- Andrade Marconi, M. e Lakatos, E. M. (2018). *Metodologia do trabalho científico*. Editora Cortez, São Paulo, 24 edition.
- Andreotti, F., Carr, O., Pimentel, M. A. F., Mahdi, A. e De Vos, M. (2017). Comparing feature-based classifiers and convolutional neural networks to detect arrhythmia from short segments of ecg. Em *Computing in Cardiology (CinC)*, páginas 1–4, Rennes, France. IEEE.
- Association, A. H. (1997). Artificial intelligence improves heart attack diagnosis.
- Ballinger, B., Hsieh, J., Singh, A., Sohoni, N., Wang, J., Tison, G. H., Marcus, G. M., Sanchez, J. M., Maguire, C., Olgin, J. E. e Pletcher, M. J. (2018). DeepHeart: Semi-Supervised Sequence Learning for Cardiovascular Risk Prediction. *arXiv e-prints*, página arXiv:1802.02511.
- Bengio, Y., Simard, P. e Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2):157–166.
- Berkaya, S. K., Uysal, A. K., Sora Gunal, E., Ergin, S., Gunal, S. e Gulmezoglu, M. B. (2018). A survey on ecg analysis. *Biomedical Signal Processing and Control*, 43:216–235.
- Berry, C., Rankin, A. C. e Brady, A. J. (2004). Bradycardia and tachycardia occurring in older people: an introduction. *British Journal of Cardiology*, 11(1):61–64.

- Bronzino, J. D. e Peterson, D. R. (2018). *The biomedical engineering handbook: Four volume set*, volume 4. CRC press, Boca Raton, 4th edition.
- Camm, A. J., Malik, M., Bigger, J. T., Breithardt, G., Cerutti, S., Cohen, R. J., Coumel, P., Fallen, E. L., Kennedy, H. L., Kleiger, R. E. et al. (1996). Heart rate variability: standards of measurement, physiological interpretation and clinical use. *circulation*, 93(5):1043–1065.
- Chang, Y., Wu, S., Tseng, L., Chao, H. e Ko, C. (2018). Af detection by exploiting the spectral and temporal characteristics of ecg signals with the lstm model. Em *Computing in Cardiology Conference (CinC)*, Maastricht, Netherlands, volume 45, páginas 1–4.
- Chen, A., Wang, F., Liu, W., Chang, S., Wang, H., He, J. e Huang, Q. (2020). Multi-information fusion neural networks for arrhythmia automatic detection. *Computer Methods and Programs in Biomedicine*, 193:105479.
- Chen, S., Hua, W., Li, Z., Li, J. e Gao, X. (2017). Heartbeat classification using projected and dynamic features of ecg signal. *Biomedical Signal Processing and Control*, 31:165–173.
- Chow, G. V., Marine, J. E. e Fleg, J. L. (2012). Epidemiology of arrhythmias and conduction disorders in older adults. *Clinics in Geriatric Medicine*, 28(4):539–553.
- Clifford, G., Liu, C., Moody, B., Lehman, L.-w., Silva, I., Li, Q., Johnson, A. e Mark, R. (2017). Af classification from a short single lead ecg recording: The physionet computing in cardiology challenge. Em *Computing in Cardiology Conference (CinC)*, Rennes, France. IEEE.
- Daniels, R. W. (1974). *Approximation methods for electronic filter design: with applications to passive, active, and digital networks*. McGraw-Hill Companies.
- Davies, A. e Scott, A. (2014). *Starting to read ECGs: A Comprehensive Guide to Theory and Practice*. Springer London, 1st edition.
- De Chazal, P., O’Dwyer, M. e Reilly, R. B. (2004). Automatic classification of heartbeats using ecg morphology and heartbeat interval features. *IEEE Transactions on Biomedical Engineering*, 51(7):1196–1206.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. e Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. Em *Conference on Computer Vision and Pattern Recognition*, páginas 248–255, Miami, FL, USA. IEEE.
- Dong, S., Wang, P. e Abbas, K. (2021). A survey on deep learning and its applications. *Computer Science Review*, 40:100379.
- Ebrahimi, Z., Loni, M., Daneshtalab, M. e Gharehbaghi, A. (2020). A review on deep learning methods for ecg arrhythmia classification. *Expert Systems with Applications: X*, 7:100033.
- Elhaj, F. A., Salim, N., Harris, A. R., Swee, T. T. e Ahmed, T. (2016). Arrhythmia recognition and classification using combined linear and nonlinear features of ecg signals. *Computer Methods and Programs in Biomedicine*, 127:52–63.
- Elman, J. L. (1990). Finding structure in time. *Cognitive science*, 14(2):179–211.
- Esposito, A. e D’Andria, P. (2003). An adaptive learning algorithm for ecg noise and baseline drift removal. Em Springer, editor, *Italian Workshop on Neural Nets*, páginas 139–147, Berlin. Springer.

- Farhadi, J., Attarodi, G., Jafarnia Dabanloo, N., Mohandespoor, M. e Eslamizadeh, M. (2018). Classification of atrial fibrillation using stacked auto encoders neural networks. Em *Computing in Cardiology Conference (CinC)*, volume 45, páginas 1–3, Netherlands, Maastricht.
- Farias, A. S. et al. (1999). Projeto de filtros transicionais baseados em aproximações polinomiais clássicas. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Centro Tecnológico., Florianópolis, Brasil.
- Faust, O., Acharya U, R., Krishnan, S., Min, L. C. et al. (2004). Analysis of cardiac signals using spatial filling index and time-frequency domain. *BioMedical Engineering OnLine*, 3(1):1–11.
- Gass, S. I. e Fu, M. C., editores (2013). *Laplace Transform*, páginas 864–864. Springer US, Boston, MA.
- Ghassemi, M. M., Moody, B. E., Lehman, L.-W. H., Song, C., Li, Q., Sun, H., Mark, R. G., Westover, M. B. e Clifford, G. D. (2018). You snooze, you win: the physionet/computing in cardiology challenge 2018. Em *Computing in Cardiology Conference (CinC)*, volume 45, páginas 1–4, Netherlands, Maastricht.
- Giffoni, R. T. e Torres, R. M. (2010). Breve história da eletrocardiografia. *Revista Médica de Minas Gerais*, 20:263–270.
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K. e Stanley, H. E. (2000). Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23):215–220.
- Gómez, J., Quispe, A. e Kemper, G. (2020). A comparative study of deep learning techniques aimed at detection of arrhythmias from ecg signals. Em *Proceedings of the 6th Brazilian Technology Symposium (BTSym'20)*, volume 233, páginas 385–395, Cham. Springer International Publishing.
- Goodfellow, I., Bengio, Y. e Courville, A. (2016). *Deep learning*. MIT press, 1st edition.
- Goroshin, R. e LeCun, Y. (2013). Saturating auto-encoders. *arXiv preprint arXiv:1301.3577*.
- Graves, A., Mohamed, A.-r. e Hinton, G. (2013). Speech recognition with deep recurrent neural networks. Em *International Conference on Acoustics, Speech and Signal Processing*, páginas 6645–6649, Vancouver, BC, Canada. IEEE.
- Graves, A. e Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural Networks*, 18(5-6):602–610.
- Greenwald, S. D., Patil, R. S. e Mark, R. G. (1990). Improved detection and classification of arrhythmias in noise-corrupted electrocardiograms using contextual information. Em *Proceedings Computers in Cardiology*, páginas 461–464, Chicago, IL, USA.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. e Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77:354–377.
- Guglin, M. E. e Thatai, D. (2006). Common errors in computer electrocardiogram interpretation. *International Journal of Cardiology*, 106(2):232–237.

- Hall, J. E. e Guyton, A. (2011). Fisiología médica. *Guyton y Hall. 12o*, páginas 1003–1017.
- Hameed, N. M. e Al-Tuwaijari, J. M. (2022). A survey on various machine learning approaches for human electrocardiograms identification. *International Journal of Nonlinear Analysis and Applications*, 13(1):4017–4035.
- Hammad, M., Iliyasu, A. M., Subasi, A., Ho, E. S. e Abd El-Latif, A. A. (2020). A multitier deep learning model for arrhythmia detection. *IEEE Transactions on Instrumentation and Measurement*, 70:1–9.
- Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P. e Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1):65–69.
- Harzing, A.-W. (2020). Everything you always wanted to know about research impact. Em *How to Get Published in the Best Management Journals*. Edward Elgar Publishing.
- Haykin, S. (2009). *Redes neurais: princípios e prática*. Bookman Editora, Porto Alegre, Brasil, 2nd edition.
- He, K., Zhang, X., Ren, S. e Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. Em *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*.
- Hindricks, G., Potpara, T., Dagres, N., Arbelo, E., Bax, J. J., Blomström-Lundqvist, C., Boriani, G., Castella, M., Dan, G.-A., Dilaveris, P. E., Fauchier, L., Filippatos, G., Kalman, J. M., Meir, M. L., Lane, D. A., Lebeau, J.-P., Lettino, M., Lip, G. Y. H., Pinto, F. J., Thomas, G. N., Valgimigli, M., Gelder, I. C. V., Putte, B. P. V., Watkins, C. L., Kirchhof, P., Kühne, M., Aboyans, V., Ahlsson, A., Balsam, P., Bauersachs, J., Benussi, S., Brandes, A., Braunschweig, F., Camm, A. J., Capodanno, D., Casadei, B., Conen, D., Crijns, H. J. G. M., Delgado, V., Dobrev, D., Drexel, H., Eckardt, L., Fitzsimons, D., Folliguet, T., Gale, C. P., Gorenek, B., Haeusler, K. G., Heidbuchel, H., Iung, B., Katus, H. A., Kotecha, D., Landmesser, U., Leclercq, C., Lewis, B. S., Mascherbauer, J., Merino, J. L., Merkely, B., Mont, L., Mueller, C., Nagy, K. V., Oldgren, J., Pavlović, N., Pedretti, R. F. E., Petersen, S. E., Piccini, J. P., Popescu, B. A., Pürerfellner, H., Richter, D. J., Roffi, M., Rubboli, A., Scherr, D., Schnabel, R. B., Simpson, I. A., Shlyakhto, E., Sinner, M. F., Steffel, J., Sousa-Uva, M., Suwalski, P., Svetlosak, M., Touyz, R. M., Dagres, N., Arbelo, E., Bax, J. J., Blomström-Lundqvist, C., Boriani, G., Castella, M., Dan, G.-A., Dilaveris, P. E., Fauchier, L., Filippatos, G., Kalman, J. M., Meir, M. L., Lane, D. A., Lebeau, J.-P., Lettino, M., Lip, G. Y. H., Pinto, F. J., Thomas, G. N., Valgimigli, M., Gelder, I. C. V. e and, C. L. W. (2020). 2020 ESC guidelines for the diagnosis and management of atrial fibrillation developed in collaboration with the european association for cardio-thoracic surgery (EACTS). *European Heart Journal*, 42(5):373–498.
- Hinton, G. E. e Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786):504–507.
- Hochreiter, S. e Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Hong, S., Fu, Z., Zhou, R., Yu, J., Li, Y., Wang, K. e Cheng, G. (2020a). Cardiolearn: A cloud deep learning service for cardiac disease detection from electrocardiogram. Em *Companion*

- Proceedings of the Web Conference 2020, WWW '20*, página 148–152, New York, NY, USA. Association for Computing Machinery.
- Hong, S., Wu, M., Zhou, Y., Wang, Q., Shang, J., Li, H. e Xie, J. (2017). ENCASE: an ENsemble CLASSifier for ECG classification using expert features and deep neural networks. Em *2017 Computing in Cardiology Conference (CinC)*. Computing in Cardiology.
- Hong, S., Xiao, C., Ma, T., Li, H. e Sun, J. (2019a). Mina: Multilevel knowledge-guided attention for modeling electrocardiography signals. arXiv.
- Hong, S., Zhou, Y., Shang, J., Xiao, C. e Sun, J. (2020b). Opportunities and challenges of deep learning methods for electrocardiogram data: A systematic review. *Computers in Biology and Medicine*, 122:103801.
- Hong, S., Zhou, Y., Wu, M., Shang, J., Wang, Q., Li, H. e Xie, J. (2019b). Combining deep neural networks and engineered features for cardiac arrhythmia detection from ECG recordings. *Physiological Measurement*, 40(5):054009.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8):2554–2558.
- Jambukia, S. H., Dabhi, V. K. e Prajapati, H. B. (2015). Classification of ecg signals using machine learning techniques: A survey. Em *International Conference on Advances in Computer Engineering and Applications*, páginas 714–721, Ghaziabad, India. IEEE.
- Jordan, M. I. (1997). Chapter 25 - serial order: A parallel distributed processing approach. Em Donahoe, J. W. e Packard Dorsel, V., editores, *Neural-Network Models of Cognition*, volume 121 de *Advances in Psychology*, páginas 471–495. North-Holland.
- Kalchbrenner, N. e Blunsom, P. (2013). Recurrent continuous translation models. Em *Proceedings of the Conference on Empirical Methods in Natural Language Processing*, páginas 1700–1709, Seattle, Washington, USA. Association for Computational Linguistics.
- Karpathy, A. e Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. Em *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, páginas 3128–3137, Boston, MA, USA.
- Keele, S. et al. (2007). Guidelines for performing systematic literature reviews in software engineering. Relatório técnico, Technical report, Ver. 2.3 EBSE Technical Report.
- Khurana, D., Koli, A., Khatter, K. e Singh, S. (2022). Natural language processing: State of the art, current trends and challenges. *Multimedia tools and applications*, páginas 1–32.
- Kingma, D. P. e Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kiranyaz, S., Ince, T. e Gabbouj, M. (2016). Real-time patient-specific ecg classification by 1-d convolutional neural networks. *IEEE Transactions on Biomedical Engineering*, 63(3):664–675.
- Kitchenham, B. e Brereton, P. (2013). A systematic review of systematic review process research in software engineering. *Information and Software Technology*, 55(12):2049–2075.
- LeCun, Y., Bengio, Y. e Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444.

- Li, F., Xu, Y., Chen, Z. e Liu, Z. (2019a). Automated heartbeat classification using 3-d inputs based on convolutional neural network with multi-fields of view. *IEEE Access*, 7:76295–76304.
- Li, H. e Boulanger, P. (2020). A survey of heart anomaly detection using ambulatory electrocardiogram (ecg). *Sensors*, 20(5).
- Li, H., Yuan, D., Wang, Y., Cui, D. e Cao, L. (2016). Arrhythmia classification based on multi-domain feature extraction for an ecg recognition system. *Sensors*, 16(10):1744.
- Li, R., Zhang, X., Dai, H., Zhou, B. e Wang, Z. (2019b). Interpretability analysis of heartbeat classification based on heartbeat activity's global sequence features and bilstm-attention neural network. *IEEE Access*, 7:109870–109883.
- Li, Y. (2022). Research and application of deep learning in image recognition. Em *IEEE 2nd International Conference on Power, Electronics and Computer Applications (ICPECA)*, páginas 994–999.
- Li, Y., Zhang, Y., Zhao, L., Zhang, Y., Liu, C., Zhang, L., Zhang, L., Li, Z., Wang, B., Ng, E., Li, J. e He, Z. (2018). Combining convolutional neural network and distance distribution matrix for identification of congestive heart failure. *IEEE Access*, 6:39734–39744.
- Lin, C.-H. (2008). Frequency-domain features for ecg beat discrimination using grey relational analysis-based classifier. *Computers & Mathematics with Applications*, 55(4):680–690.
- Liu, M. e Kim, Y. (2018). Classification of heart diseases based on ecg signals using long short-term memory. Em *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, páginas 2707–2710, Honolulu, HI, USA.
- Lore, K. G., Akintayo, A. e Sarkar, S. (2017). Llnet: A deep autoencoder approach to natural low-light image enhancement. *Pattern Recognition*, 61:650–662.
- Luz, E. J. d. S., Schwartz, W. R., Cámara-Chávez, G. e Menotti, D. (2016). Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer methods and programs in biomedicine*, 127:144–164.
- Luz, E. J. S., Schwartz, W. R., Cámara-Chávez, G. e Menotti, D. (2016). Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, 127:144–164.
- Maknickas, V. e Maknickas, A. (2017). Atrial fibrillation classification using qrs complex features and lstm. Em *Computing in Cardiology (CinC)*, páginas 1–4, Rennes, France. IEEE.
- Martis, R. J., Acharya, U. R., Mandana, K., Ray, A. K. e Chakraborty, C. (2012). Application of principal component analysis to ecg signals for automated diagnosis of cardiac health. *Expert Systems with Applications*, 39(14):11792–11800.
- Matias, I., Garcia, N., Pirbhulal, S., Felizardo, V., Pombo, N., Zacarias, H., Sousa, M. e Zdravevski, E. (2021). Prediction of atrial fibrillation using artificial intelligence on electrocardiograms: A systematic review. *Computer Science Review*, 39:100334.
- Meyer-Baese, U. (2007). *Adaptive Filters*, páginas 477–535. Springer, Berlin.

- Mikolov, T. e Zweig, G. (2012). Context dependent recurrent neural network language model. Em *IEEE Spoken Language Technology Workshop (SLT)*, páginas 234–239, Miami, FL, USA. IEEE.
- Mitchell, T. M. (1999). Machine learning and data mining. *Communications of the ACM*, 42(11):30–36.
- Mohrman, D. e Heller, L. (2018). *Cardiovascular physiology*. McGraw-Hill New York, 9th edition.
- Mond, H. G., Garcia, J. e Visagathilagar, T. (2016). Twisted leads: the footprints of malpositioned electrocardiographic leads. *Heart, Lung and Circulation*, 25(1):61–67.
- Moody, G. e Mark, R. (2001). The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3):45–50.
- Najarian, K. e Splinter, R. (2012). *Biomedical signal and image processing*. Taylor & Francis, Boca Raton, 2012, crc press edition.
- Nations, U. (2018). The world population prospects 2019. *Department of Economic and Social Affairs*.
- Nikolic, G., Bishop, R. L. e Singh, J. B. (1982). Sudden death recorded during holter monitoring. *Circulation*, 66(1):218–225.
- Noceti Filho, S. (1998). *Filtros seletores de sinais*. Universidade Federal de Santa Catarina, Florianópolis - Brasil, 4 edition.
- Odinaka, I., Lai, P.-H., Kaplan, A. D., O’Sullivan, J. A., Sirevaag, E. J. e Rohrbaugh, J. W. (2012). Ecg biometric recognition: A comparative analysis. *IEEE Transactions on Information Forensics and Security*, 7(6):1812–1824.
- Oh, S. L., Ng, E. Y., Tan, R. S. e Acharya, U. R. (2018). Automated diagnosis of arrhythmia using combination of cnn and lstm techniques with variable length heart beats. *Computers in Biology and Medicine*, 102:278 – 287.
- Olah, C. e Carter, S. (2016). Attention and augmented recurrent neural networks. *Distill*, 1(9):e1.
- Organization, W. H. (2008). *World health statistics 2008*. World Health Organization.
- Organization, W. H. (2020). Who reveals leading causes of death and disability worldwide: 2000-2019. Disponível em: <<https://www.who.int/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019>>. Acesso em 21 de jun. 2021.
- Organization, W. H. (2021). Cardiovascular diseases (cvds). Disponível em: <[https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))>. Acesso em 21 de jun. 2021.
- Osowski, S. e Linh, T. (2001). Ecg beat recognition using fuzzy hybrid neural network. *IEEE Transactions on Biomedical Engineering*, 48(11):1265 – 1271.
- Pang, G., Shen, C., Cao, L. e Hengel, A. V. D. (2021). Deep learning for anomaly detection: A review. *ACM Comput. Surv.*, 54(2).

- Parvaneh, S., Rubin, J., Babaeizadeh, S. e Xu-Wilson, M. (2019). Cardiac arrhythmia detection using deep learning: A review. *Journal of Electrocardiology*, 57:S70 – S74.
- Petersen, K., Vakkalanka, S. e Kuzniarz, L. (2015). Guidelines for conducting systematic mapping studies in software engineering: An update. *Information and Software Technology*, 64:1–18.
- Ponomariov, V., Chirila, L., Apipie, F.-M., Abate, R., Rusu, M., Wu, Z., Liehn, E. e Bucur, I. (2017). Artificial intelligence versus doctors' intelligence: A glance on machine learning benefaction in electrocardiography. *Discoveries*.
- Pourbabaee, B., Roshtkhari, M. J. e Khorasani, K. (2018). Deep convolutional neural networks and learning ecg features for screening paroxysmal atrial fibrillation patients. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 48(12):2095–2104.
- Rajan, D. e Thiagarajan, J. J. (2018). A generative modeling approach to limited channel ecg classification. Em *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, páginas 2571–2574, Honolulu, HI, USA.
- Romero, I. e Serrano, L. (2001). Ecg frequency domain features extraction: a new characteristic for arrhythmias classification. Em *Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, volume 2, páginas 2006–2008 vol.2.
- Roopa, C. e Harish, B. (2017). A survey on various machine learning approaches for ecg analysis. *International Journal of Computer Applications*, 163(9):25–33.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv e-prints*.
- Russell, S. J. e Norvig, P. (2010). *Artificial intelligence a modern approach*. Pearson Education, Inc.
- Saadatnejad, S., Oveisi, M. e Hashemi, M. (2020). LSTM-based ECG classification for continuous monitoring on personal wearable devices. *IEEE Journal of Biomedical and Health Informatics*, 24(2):515–523.
- Sahoo, S., Kanungo, B., Behera, S. e Sabut, S. (2017). Multiresolution wavelet transform based feature extraction and ecg classification to detect cardiac abnormalities. *Measurement*, 108:55–66.
- Salakhutdinov, R. e Hinton, G. (2009). Semantic hashing. *International Journal of Approximate Reasoning*, 50(7):969–978. Special Section on Graphical Models and Information Retrieval.
- Saxe, A. M., McClelland, J. L. e Ganguli, S. (2013). Exact solutions to the nonlinear dynamics of learning in deep linear neural networks. *arXiv preprint arXiv:1312.6120*.
- Schläpfer, J. e Wellens, H. J. (2017). Computer-interpreted electrocardiograms. *Journal of the American College of Cardiology*, 70(9):1183–1192.
- Schuster, M. e Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11):2673–2681.
- Schwab, P., Scebba, G. C., Zhang, J., Delai, M. e Karlen, W. (2017). Beat by beat: Classifying cardiac arrhythmias with recurrent neural networks. Em *Computing in Cardiology (CinC)*, páginas 1–4, Rennes, France. IEEE.

- Shah, A. P. e Rubin, S. A. (2007). Errors in the computerized electrocardiogram interpretation of cardiac rhythm. *Journal of Electrocardiology*, 40(5):385–390.
- Siontis, K. C., Noseworthy, P. A., Attia, Z. I. e Friedman, P. A. (2021). Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nature Reviews Cardiology*, 18(7):465–478.
- Smolarik, L., Libosvarova, A., Mudroncik, D. e Schreiber, P. (2012). Non-contact ecg signal processing. Em *6th IEEE International Conference Intelligent Systems*, páginas 349–354.
- Song, Y., Shi, G., Chen, L., Huang, X. e Xia, T. (2018). Remaining useful life prediction of turbofan engine using hybrid model based on autoencoder and bidirectional long short-term memory. *Journal of Shanghai Jiaotong University (Science)*, 23(1):85–94.
- Sun, W., Zeng, N. e He, Y. (2019). Morphological arrhythmia automated diagnosis method using gray-level co-occurrence matrix enhanced convolutional neural network. *IEEE Access*, 7:67123–67129.
- Takamoto, S., Ishimaru, S., Kato, M., Kuribayashi, S., Matsuo, H., Miyata, T., Nakajima, Y., Ogino, H., Ohki, T., Okita, Y. et al. (2013). Heart disease: A textbook of cardiovascular medicine heart disease: A textbook of cardiovascular medicine, 2001. *Circulation journal: official journal of the Japanese Circulation Society*, 77(3):789–828.
- Tang, D. H., Gilligan, A. M. e Romero, K. (2014). Economic burden and disparities in healthcare resource use among adult patients with cardiac arrhythmia. *Applied Health Economics and Health Policy*, 12(1):59–71.
- Tang, S. e Tang, J. (2021). Electrocardiogram classification using long short-term memory networks. Em *Advances in Computer Vision and Computational Biology*, páginas 855–862. Springer, Cham.
- Tateno, K. e Glass, L. (2001). Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of rr and δrr intervals. *Medical and Biological Engineering and Computing*, 39(6):664–671.
- Tavakoli, N., Siami-Namini, S., Adl Khanghah, M., Mirza Soltani, F. e Siami Namin, A. (2020). An autoencoder-based deep learning approach for clustering time series data. *SN Applied Sciences*, 2(5):1–25.
- Tsantekidis, A., Passalis, N. e Tefas, A. (2022). Chapter 5 - recurrent neural networks. Em Iosifidis, A. e Tefas, A., editores, *Deep Learning for Robot Perception and Cognition*, páginas 101–115. Academic Press.
- Turnip, M., Dharma, A., Andrian, Afriansyah, A., Oktarino, A. e Turnip, A. (2021). *Integration of FIR and Butterworth Algorithm for Real-Time Extraction of Recorded ECG Signals*, páginas 49–58. Springer, Singapore.
- Vincent, P., Larochelle, H., Bengio, Y. e Manzagol, P.-A. (2008). Extracting and composing robust features with denoising autoencoders. Em *Proceedings of the 25th International Conference on Machine Learning, ICML '08*, página 1096–1103, New York, NY, USA. Association for Computing Machinery.

- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P.-A. e Bottou, L. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *The Journal of Machine Learning Research*, 11(12).
- Wang, E. K., Zhang, X. e Pan, L. (2019a). Automatic classification of cad ecg signals with sdae and bidirectional long short-term network. *IEEE Access*, 7:182873–182880.
- Wang, P., Hou, B., Shao, S. e Yan, R. (2019b). Ecg arrhythmias detection using auxiliary classifier generative adversarial network and residual network. *IEEE Access*, 7:100910–100922.
- Wang, R., Fan, J. e Li, Y. (2020). Deep multi-scale fusion neural network for multi-class arrhythmia detection. *IEEE Journal of Biomedical and Health Informatics*, 24(9):2461–2472.
- Wang, W., Huang, Y., Wang, Y. e Wang, L. (2014). Generalized autoencoder: A neural network framework for dimensionality reduction. Em *Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, Columbus, OH, USA. IEEE.
- Webster, J. G. (2010). *Medical instrumentation: application and design*. John Wiley & Sons.
- Wołk, K. e Wołk, A. (2019). Early and remote detection of possible heartbeat problems with convolutional neural networks and multipart interactive training. *IEEE Access*, 7:145921–145927.
- Xia, Y., Wulan, N., Wang, K. e Zhang, H. (2017). Atrial fibrillation detection using stationary wavelet transform and deep learning. Em *Computing in Cardiology (CinC)*, páginas 1–4, Rennes, France. IEEE.
- Xia, Y., Zhang, H., Xu, L., Gao, Z., Zhang, H., Liu, H. e Li, S. (2018). An automatic cardiac arrhythmia classification system with wearable electrocardiogram. *IEEE Access*, 6:16529–16538.
- Yang, X.-x. e Xue, Y.-j. (2008). Design of a compact low-pass filter with wide stopband. *Journal of Shanghai University (English Edition)*, 12(6):495–497.
- Yeh, Y.-C., Wang, W.-J. e Chiou, C. W. (2009). Cardiac arrhythmia diagnosis method using linear discriminant analysis on ecg signals. *Measurement*, 42(5):778–789.
- Yildirim, O. (2018). A novel wavelet sequence based on deep bidirectional lstm network model for ecg signal classification. *Computers in Biology and Medicine*, 96:189–202.
- Yildirim, O., Baloglu, U. B., Tan, R.-S., Ciaccio, E. J. e Acharya, U. R. (2019). A new approach for arrhythmia classification using deep coded features and lstm networks. *Computer Methods and Programs in Biomedicine*, 176:121–133.
- Yildirim, O., Pławiak, P., Tan, R.-S. e Acharya, U. R. (2018). Arrhythmia detection using deep convolutional neural network with long duration ecg signals. *Computers in Biology and Medicine*, 102:411–420.
- Yin, W., Yang, X., Zhang, L. e Oki, E. (2016). Ecg monitoring system integrated with ir-uwb radar based on cnn. *IEEE Access*, 4:6344–6351.
- Yin, Z., Zhao, M., Wang, Y., Yang, J. e Zhang, J. (2017). Recognition of emotions using multimodal physiological signals and an ensemble deep learning model. *Computer Methods and Programs in Biomedicine*, 140:93–110.

- Zhai, X. e Tin, C. (2018). Automated ecg classification using dual heartbeat coupling based on convolutional neural network. *IEEE Access*, 6:27465–27472.
- Zhang, J., Lin, F., Xiong, P., Du, H., Zhang, H., Liu, M., Hou, Z. e Liu, X. (2019). Automated detection and localization of myocardial infarction with staked sparse autoencoder and treebagger. *IEEE Access*, 7:70634–70642.
- Zhou, X., Zhu, X., Nakamura, K. e Mahito, N. (2018). Premature ventricular contraction detection from ambulatory ecg using recurrent neural networks. Em *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, páginas 2551–2554, Honolulu, HI, USA. IEEE.
- Zubair, M., Kim, J. e Yoon, C. (2016). An automated ecg beat classification system using convolutional neural networks. Em *6th International Conference on IT Convergence and Security (ICITCS)*, páginas 1–5, Prague, Czech Republic. IEEE.
- Zverev, A. I. (1967). *Handbook of Filter Synthesis*. Wiley and Sons, New York, NY, USA.