



PROGRAMA DE
PÓS-GRADUAÇÃO EM
**ENGENHARIA DE SISTEMAS
E PRODUTOS**

Instituto Federal da Bahia
Campus Salvador

Programa de Pós-Graduação em Engenharia de Sistemas e Produtos
PPGESP

**MODELO PARA DETECÇÃO DE
ARRITMIAS CARDÍACAS BASEADO EM
COEFICIENTES DE PREDIÇÃO LINEAR E
REDE NEURAL CONVOLUCIONAL 1D**

Jaimilton dos Santos Lima

DISSERTAÇÃO DE MESTRADO

Salvador
Outubro de 2022

JAIMILTON DOS SANTOS LIMA

**MODELO PARA DETECÇÃO DE ARRITMIAS CARDÍACAS
BASEADO EM COEFICIENTES DE PREDIÇÃO LINEAR E REDE
NEURAL CONVOLUCIONAL 1D**

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Engenharia de Sistemas e Produtos PPGESP do Instituto Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Engenharia de Sistemas e Produtos.

Orientador: Fabrício Gerônimo Simões da Silva
Co-orientador: José Mário Araújo

Salvador
Outubro de 2022

Biblioteca Raul V. Seixas – Instituto Federal de Educação, Ciência e Tecnologia da Bahia - IFBA – Campus Salvador/BA.

Responsável pela catalogação na fonte: Samuel dos Santos Araújo - CRB 5/1426.

L732m Lima, Jaimilton dos Santos.

Modelo para detecção de arritmias cardíacas baseados em coeficientes de predição linear e rede neural convolucional 1D / Jaimilton dos Santos Lima. Salvador, 2022.

69 f. ; 30 cm.

Dissertação (Mestrado Profissional em Engenharia de Sistemas e Produtos) – Instituto Federal de Educação, Ciência e Tecnologia da Bahia.

Orientador: Fabrício Gerônimo Simões da Silva.

Coorientador: José Mário Araújo.

1. Batimentos cardíacos. 2. Coeficientes de Predição Linear (LPC). 3. Rede Neural Convolucional (CNN) 1D. 4. Eletrocardiograma (ECG). I. Silva, Fabrício Gerônimo Simões da. II. Araújo, José Mário. III. IFBA. IV. Título.

CDU 2 ed. 614

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA BAHIA
R. Emídio dos Santos - Bairro Barbalho - CEP 40301-015 - Salvador - BA - www.portal.ifba.edu.br

**INSTITUTO FEDERAL DA BAHIA
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO**

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE SISTEMAS E PRODUTOS - PPGESP

**MODELO PARA DETECÇÃO DE ARRITMIAS CARDÍACAS BASEADO EM COEFICIENTES DE
PREDIÇÃO LINEAR E REDE NEURAL COVOLUCIONAL 1D**

JAIMILTON SANTOS LIMA

Produto(s) Gerado(s): Dissertação

Orientador: Prof. Dr. Fabrício Gerônimo Simões Silva

Coorientador: Prof. Dr. José Mário Araújo

Banca examinadora:

Prof. Dr. Fabrício Gerônimo Simões Silva

Orientador – Instituto Federal da Bahia (IFBA)

Prof. Dr. José Mário Araújo

Coorientador – Instituto Federal da Bahia (IFBA)

Prof. Dr. Eduardo Furtado de Simas Filho

Membro Externo – Universidade Federal da Bahia (UFBA)

Prof. Dr. Antônio César de Castro Lima

Membro Externo – Universidade Federal da Bahia (UFBA)

Prof. Dr. Eduardo Telmo Fonseca Santos

Membro Interno – Instituto Federal da Bahia (IFBA)

Em 13 de outubro de 2022.



Documento assinado eletronicamente por **Antonio Cezar de Castro Lima, Usuário Externo**, em 26/10/2022, às 18:04, conforme decreto nº 8.539/2015.



Documento assinado eletronicamente por **FABRICIO GERONIMO SIMOES SILVA, Docente Colaborador(a)**, em 26/10/2022, às 18:28, conforme decreto nº 8.539/2015.



Documento assinado eletronicamente por **Eduardo Furtado de Simas Filho, Usuário Externo**, em 26/10/2022, às 19:23, conforme decreto nº 8.539/2015.



Documento assinado eletronicamente por **EDUARDO TELMO FONSECA SANTOS, Docente Permanente**, em 04/11/2022, às 21:02, conforme decreto nº 8.539/2015.



Documento assinado eletronicamente por **JOSE MARIO ARAUJO, Professor Titular**, em 12/12/2022, às 13:34, conforme decreto nº 8.539/2015.



A autenticidade do documento pode ser conferida no site http://sei.ifba.edu.br/sei/controlador_externo.php?acao=documento_conferir&acao_origem=documento_conferir&id_orgao_acesso_externo=0 informando o código verificador **2560394** e o código CRC **48566A4B**.

Dedico esse trabalho primeiramente a Jesus Cristo pelo seu grande amor demonstrado na cruz para me tornar um homem livre. A minha esposa Ana e filhos Mateus e Milena pela paciência nos momentos mais tensos da jornada. Aos meus pais pelo dom da vida. Aos amigos de perto e de longe, mas que de alguma forma contribuíram para a realização desse trabalho. Aos familiares pelos incentivos.

AGRADECIMENTOS

Agradeço principalmente a Deus por ter me permitido a plenitude da vida abundante em Cristo Jesus nosso Senhor, à minha esposa Ana Lúcia, aos meus filhos Mateus e Milena pela ternura, amor, paciência, estímulo, confiança, alegria e serenidade, que mesmo tendo o tempo subtraído para dedicar-me ao esforço no cumprimento de meus sonhos, sempre foram um veículo incentivador para concretização desse objetivo.

Aos amigos que perfizeram intromissões que direta ou indiretamente contribuíram para elaboração deste trabalho. Seja por apenas um simples comentário, seja por delongas conversas travadas a respeito do assunto, deixo registrada minha enorme gratidão.

Não obstante, em especial, fico grato aos professores Dr. Fabrício Gerônimo Simões da Silva e Dr. José Mário Araújo, orientador e co-orientador respectivamente pela paciência, atenção e dedicação em me ensinar muitos dos preceitos (mais que o necessário) para elaboração correta e adequada deste trabalho. Ao amigo José Souza de Jesus, pela corroboração na explicação da dinâmica filosófica do funcionamento de uma rede neural convolucional 1D.

Aos meus infindáveis amigos e colegas, que por jus à menção, mas que pela impossibilidade de listá-los devidamente omiti seus nomes, meus sinceros e respeitosos agradecimentos. Aos meus pais, mencionados somente agora, porém não menos importantes, que com tremendas dificuldades e limitações deixaram de lado as possibilidades de conforto e de segurança para prover condições suficientes para que eu e meus irmãos pudéssemos estudar... Deveras tamanha gratidão pudesse aqui solevar, o faria.

*Não vos conformeis com este mundo, mas transformai-o pela renovação
do vosso entendimento.
Jesus Cristo.*

—

RESUMO

Nas últimas décadas, os problemas de saúde decorrentes de doenças cardíacas têm se tornado as maiores causas de mortes no mundo. Ao considerar a taxa de mortalidade e a grande quantidade de pessoas que sofre de doenças cardíacas, torna-se bastante relevante a necessidade de um diagnóstico precoce. Com o intuito de dar uma contribuição no diagnóstico, é proposto o desenvolvimento de um sistema computacional de detecção e classificação dos batimentos cardíacos de alguns tipos de arritmias. Para alcançar esse objetivo, a proposta foi desenvolvida em dois momentos. Primeiro, foi desenvolvido e implementado um algoritmo para estimar a frequência cardíaca dos sinais de ECG utilizando o algoritmo de Coeficiente Predição Linear (LPC). Nessa etapa, foi obtida acurácia acima de 98% na estimação da frequência cardíaca. No segundo momento, foi escolhida uma arquitetura da rede CNN capaz de aprender as características dinâmicas dos batimentos cardíacos gerados pelo algoritmo LPC e as características morfológicas do sinal de ECG. Para treinar a rede, foram utilizados sinais de ECG obtidos da base de dados do *Massachusetts Institute of Technology* (MIT-BIH Banco de Dados de Arritmias) com 2480 sinais e do *PhysioNet/Computing in Cardiology Challenge 2017* com 3720 sinais. Para ampliar o acervo de dados, foi aplicada uma técnica de aumento de dados (*Data Augmentation*). Após a fase de treinamento, os resultados foram de 93,35% para acurácia, 93,12% e 93,08% para precisão e *recall*, respectivamente, para os dados do MIT-BIH. E para os dados do *Physionet*, o modelo alcançou 99,87% tanto para a acurácia quanto para precisão e *recall*, respectivamente. Os resultados do modelo de classificação quando combina as informações obtidas pela combinação do LPC e da Rede Neural Convolutiva Unidimensional são bastante expressivos quando comparados com outras técnicas divulgadas na comunidade científica.

Palavras-chave: 1. Batimentos Cardíacos. 2. Coeficientes de Predição Linear (LPC). 3. Rede Neural Convolutiva (CNN) 1D. 4. Eletrocardiograma ECG.

ABSTRACT

In recent decades, health problems resulting from heart disease have become the biggest causes of death in the world. When considering the mortality rate and the large number of people suffering from heart disease, the need for an early diagnosis becomes quite relevant. In order to contribute to the diagnosis, it is proposed the development of a computational system of detection and classification of heartbeats for some types of arrhythmias. To achieve this objective, the proposal was developed in two stages. First, an algorithm was developed and implemented to estimate heart rate from ECG signals using the Linear Prediction Coefficient (LPC) algorithm. At this stage, accuracy above 98% was obtained in estimating heart rate. In the second moment, a CNN network architecture capable of learning the dynamic characteristics of the heartbeats generated by the LPC algorithm and the morphological characteristics of the ECG signal was chosen. To train the network, ECG signals obtained from the database of the Massachusetts Institute of Technology (MIT-BIH Database of Arrhythmias) with 2480 signals and from PhysioNet/Computing in Cardiology Challenge 2017 with 3720 signals were used. To expand the data collection, a data augmentation technique was applied. After the training phase, the results were 93.35% for accuracy, 93.12% and 93.08% for accuracy and recall, respectively, for the MIT-BIH data. And for the Physionet data, the model reached 99.87% for both accuracy, precision and recall, respectively. The results of the classification model when combining the information obtained by combining the LPC and the Unidimensional Convolutional Neural Network are quite expressive when compared with other techniques published in the scientific community.

Keywords: Heartbeat, Linear Prediction Coefficients LPC, Convolutional Neural Network (CNN) 1D, Electrocardiogram ECG.

SUMÁRIO

Capítulo 1—Introdução	1
1.1 Justificativa	5
1.2 Objetivos	5
1.3 Organização do texto da Dissertação	6
Capítulo 2—Revisão Bibliográfica	7
2.1 Sinais de Eletrocardiograma	9
2.2 Coeficientes de Predição Linear (LPC)	11
2.3 Rede Neural Artificial (RNA)	14
2.4 Rede Neural Convolutacional	17
2.5 Rede Neural Convolutacional Unidimensional (CNN 1D)	17
2.5.1 Camada de Entrada	20
2.5.2 Camada Convolutacional	20
2.5.3 <i>MaxPooling</i>	20
2.5.4 Função de Ativação ReLU	21
2.5.5 Função de Ativação LeakReLU	22
2.5.6 Batch Normalization Layer	22
2.5.7 Camada Softmax	22
Capítulo 3—Estimação da frequência cardíaca Usando Coeficientes de Predição Linear (LPC)	24
3.1 Estimação dos batimentos cardíacos	24
3.2 BOXPLOT	28
Capítulo 4—Classificação de arritmias cardíacas utilizando arquitetura CNN 1D/LPC	31
4.1 Base de Dados de Treinamento	31
4.1.1 MIT-BIH Database Arritmias	31
4.1.2 PHYSIONET Database	32
4.2 Data Augmentation (DA)	32
4.3 Determinação de Hiper-Parâmetros	35
4.4 Resultados	36
4.4.1 Modelo de Classificação CNN 1D/LPC	39

SUMÁRIO

xii

Capítulo 5—Conclusão

47

LISTA DE FIGURAS

1.1	Gráfico de mortes por DCV	1
1.2	Estatística Cardiovascular – Brasil 2022	3
1.3	Fluxograma do projeto	4
1.4	DCV por ano, mês e dia	5
2.1	Complexo QRS	9
2.2	Diferenças de potenciais gerados no coração (OLIVEIRA, 2009)	10
2.3	Contribuição de cada onda para a formação do ECG (OLIVEIRA, 2009)	11
2.4	Neurônio Artificial. haykin2007redes	15
2.5	Translação provocada pelo bias. (HAYKIN, 2007)	16
2.6	Modelo Perceptron.	16
2.7	Rede CNN genérica	18
2.8	Rede CNN 1D	19
2.9	MaxPooling.	21
2.10	Função ReLU.	21
2.11	Função LeakReLU.	22
3.1	Um sinal típico de ECG com destaque para o complexo QRS	25
3.2	Aplicação do método a um trecho do sinal ECG de um paciente saudável.	25
3.3	Cálculo do ritmo cardíaco usando ondas R detectadas	27
3.4	Comparação das classes NSR e BIGEMINY com mesmo valor médio	29
3.5	Comparação das classes estudadas	29
4.1	Data Augmentation nos dados do MIT-BIH Database	33
4.2	Data Augmentation nos dados do MIT-BIH Database	34
4.3	Data Augmentation nos dados do PHYSIONET Database	34
4.4	Data Augmentation nos dados do PHYSIONET Database	35
4.5	Data Augmentation	36
4.6	Desempenho do modelo CNN 1D	38
4.7	Desempenho do treinamento do modelo com dados do MIT-BIT sem o LPC	39
4.8	Modelo da rede neural convolucional 1D	40
4.9	Desempenho de validação de treinamento do modelo CNN/LPC.	42
4.10	Desempenho de validação do modelo com dados do MIT-BIH	43
4.11	Desempenho de validação do treinamento do modelo CNN/LPC usando a base de dados da PHYSIONET.	44
4.12	Desempenho do modelo CNN 1D/LPC com dados da base PHYSIONET	45

LISTA DE TABELAS

3.1	Registros das Patologias	27
3.2	Registros dos batimentos cardíacos	28
4.1	Arquitetura da Rede Neural Convolutacional 1D final	37
4.2	Comparação das arquiteturas testadas	40
4.3	Distribuição dos sinais cardíacos para treinamento e validação - MIT . .	41
4.4	Distribuição dos sinais cardíacos para treinamento e validação - PHYSIO- NET	42
4.5	Análise de desempenho do modelo LPC-CNN	43
4.6	Resultados da matriz de confusão derivada do conjunto de dados de va- lidação LPC-CNN 1D	43
4.7	Análise de desempenho do modelo CNN 1D e do modelo completo LPC- CNN 1D	44
4.8	Comparação entre o modelo CNN/LPC e outras propostas.	46

LISTA DE SIGLAS

- SBC - Sociedade Brasileira de Cardiologia
- LPC - Coeficiente de Predição Linear
- CNN - Convolutional Neural Network
- DCV - Doenças cardiovasculares
- SIDA - Síndrome de Imunodeficiência Adquirida
- SARS - Síndrome Respiratória Aguda Grave
- ARPEN - Associação dos Registradores de Pessoas Naturais do Brasil
- MIT-BIH - Massachusetts Institute of Technology and the Boston Hospital
- PTB - Physikalisch-Technische Bundesanstalt
- GBD - Global Burden of Disease
- DIC - Doença Isquêmica do Coração
- AVC - Acidente Vascular Cerebral
- SUS - Sistema Único de Saúde
- DAC - Doença Arterial Coronariana

- KNN - K-nearest neighbors
- FCG - Fonocardiograma
- ECG - Eletrocardiograma
- AAMI - Association for Advancement of Medical Instrumentation
- - ARR - Arritmias Cardíacas
- ICC - Insuficiência Cardíaca Congestiva
- MI - Myocardial Infarction
- PTB - Physikalisch Technische Bundesanstalt
- HEARTBEAT - Batimentos Cardíacos

CAPÍTULO 1

INTRODUÇÃO

Segundo a Sociedade Brasileira de Cardiologia (SBC), (PRÉCOMA et al., 2019), as doenças cardiovasculares (DCV) são a principal causa de morte no mundo. No Brasil representam cerca de 30% dos óbitos. De acordo com o SBC, as doenças cardiovasculares chegam a matar até duas vezes mais que todos os tipos de câncer, duas vezes e meia mais que os acidentes e mortes por violência e seis vezes mais que as infecções, incluídas as mortes por síndrome de imunodeficiência adquirida (SIDA).

Ainda segundo o relatório, cerca de 14 milhões de brasileiros têm alguma doença no coração e cerca de 400 mil morrem por ano em decorrência dessas enfermidades, o que corresponde a aproximadamente 30% de todas as mortes no país. Neste ano a preocupação da contaminação pelo covid-19 também tem feito muitos pacientes portadores de DCV, e de outras doenças agudas, negligenciarem a rotina de saúde, deixando de ir ao médico (ROCHA et al., 2017). Uma série histórica, Figura 1.1, mostra o aumento das mortes no Brasil por doenças do coração ao longo do período de 2002 até 2018 (OLIVEIRA et al., 2020b).




Figura 1.1 Gráfico de mortes por DCV

Por conta da *síndrome respiratória aguda grave SARS-COV 2*, a SBC vem acompanhando a diminuição do número de atendimentos cardiológicos de urgência no país.

Juntamente com a Associação dos Registradores de Pessoas Naturais do Brasil (ARPEN-Brasil), a SBC tem divulgado dados que mostram um aumento de quase 7% no número de óbitos por doenças cardiovasculares que ocorreram nos primeiros seis meses de 2021, em relação ao mesmo período de 2020 (OLIVEIRA et al., 2022). Em 2019, a DIC (Doença Isquêmica do Coração) foi a principal causa de morte em todas as UF brasileiras, exceto no Amazonas, na região Norte (OLIVEIRA et al., 2022).

No relatório Estatística Cardiovascular – Brasil 2020, são apresentadas informações fornecidas pelo Ministério da Saúde do Brasil e por outras agências governamentais (OLIVEIRA et al., 2022). Fornece também dados gerados por outras fontes e estudos científicos sobre doença cardíaca, acidente vascular cerebral e outras DCV, inclusive estudos do *Global Burden of Disease (GBD)* (Carga Global de Doenças) que é o estudo epidemiológico observacional mais completo em âmbito mundial. O objetivo deste relatório é monitorar e avaliar continuamente as fontes de dados sobre doença cardíaca e acidente vascular cerebral no Brasil para fornecer informações mais atualizadas sobre a epidemiologia dessas doenças para a sociedade brasileira. Esse relatório é resultado do esforço de clínicos e cientistas dedicados e voluntários, profissionais do governo e membros da SBC. Nesta edição são mostradas as estatísticas das seguintes condições clínicas:

1. Doença Cardiovascular Total;
2. Doença Cerebrovascular;
3. Doença Arterial Coronariana, Síndrome Coronariana Aguda e Angina Pectoris;
4. Cardiomiopatia e Insuficiência Cardíaca;
5. Doenças Valvares, incluindo Cardiopatia Reumática;
6. Fibrilação Atrial.

No relatório Estatística Cardiovascular – Brasil 2020, o banco de dados do Serviço de Informação de Mortalidade do Brasil (SIM), mostra que as DCV corresponderam a 27,3% do total de mortes, com a maior proporção na região Sudeste e a menor na região Norte, Figura 1.2. A DIC foi responsável por 32,1% do total de mortes por DCV (Doença Cardiovascular) no Brasil e o AVC (Acidente Vascular Cerebral), por 28,2% (OLIVEIRA et al., 2020a).

O relatório Estatística Cardiovascular – Brasil 2022 traz novos dados sobre o panorama das doenças cardiovasculares no Brasil. Nesse relatório, o Estudo GBD 2019 e a base de dados do SUS mostram que as DCV continuam sendo a causa número 1 de morte no Brasil. Entre as DCV, a DAC (Doença Arterial Coronariana) foi a principal causa de morte no país, seguida pelo AVC em 1990 e 2019 (OLIVEIRA et al., 2022).

A realização do Estudo GBD 2019 indica que 6,1% da população foi estimada com DCV devido ao crescimento e envelhecimento populacional.(OLIVEIRA et al., 2022).

Em 1988, a Constituição Brasileira, também rotulada de “Constituição Cidadã”, estabeleceu em seu artigo 196 que o acesso à saúde é um direito universal, considerando que este é um direito de todos e dever do Estado (SELIG, 2021). No entanto, apesar




Figura 1.2 Estatística Cardiovascular – Brasil 2022

Mortalidade proporcional por doença cardiovascular, doença isquêmica do coração e acidente vascular cerebral, por região no Brasil.

das garantias da Emenda Constitucional 29, o financiamento dos serviços oferecidos pelo SUS tem sido um grande desafio para as políticas públicas no Brasil, principalmente para locais de difícil acesso.

Nesses locais, um dos grandes problemas enfrentados é a escassez de hospitais de alta complexidade cardiovascular que prestam atendimento ao SUS no Brasil. Existem pouco mais de 3 mil leitos no Brasil direcionados à alta complexidade cardiovascular distribuídos em 277 hospitais. Além disso, pouco mais de 20% destes hospitais pelo Brasil são públicos (SELIG, 2021).

Considerando a dimensão territorial do Brasil, percebe-se a dificuldade enfrentada pelas instituições públicas em prestar um serviço de qualidade no atendimento médico em geral e em particular na área de atendimento cardiológico, especialmente para o grande número de pacientes em áreas remotas devido à falta de sistemas de apoio ao diagnóstico e médicos (OLIVEIRA et al., 2020a), (SELIG, 2021). É de conhecimento geral que os hospitais públicos em áreas rurais tem um médico para atender diversos tipos de casos.

Com a finalidade de levar recursos tecnológicos de apoio ao diagnóstico a esses locais, o uso de sistemas computadorizados tem sido bastante útil na identificação de patologias através dos diversos métodos de detecção e classificação de eventos clínicos. Os avanços recentes da tecnologia para detecção de cardiopatias mostram como a utilização de algoritmos de aprendizado de máquina tem sido aplicados a sinais cardíacos obtidos por meio de fonocardiograma (GOES et al., 2020).

Diversas técnicas vêm sendo apresentadas como (SINGH; MEITEI; MAJUMDER, 2020) que apresentam um sistema de classificação automática de sons cardíacos obti-

dos via FCG (Fonocardiograma). Um método baseado em 1 – *class classification* para detecção de anomalias cardíacas em ambientes de dados restritos foi proposto em (UNNIKRISHNAN et al., 2020). Utilizou-se métodos não supervisionados e semi-supervisionados na base do PhysioNet/CinC 2016 e redes neurais de convolução baseadas em *autoencoders* para extração de características não-supervisionadas.

A Transformada de Wavelet foi usada para extração de características dos sinais segmentados. Dois modelos de CNN foram pré-treinados para recebimento dos dados pré-processados, a base de dados utilizada foi a Physionet 2016 (CHEN; WEI; ZHANG, 2020). Para (HUANG; SONG, 2018) problemas cardíacos podem ser detectados a partir de ausculta cardíacas. Dessa forma, a partir da série temporal do sinal de fonocardiograma (FCG), coeficientes *mel-cepstrais* foram extraídos.

A classificação das ausculta foi feita utilizando o modelo de *K-vizinhos Próximos (KNN)* com *distância de Hamming*. Os dados de Ausculta cardíacas também foi usados por (RAZA et al., 2019) para classifica anomalias cardíacas, rotulando os sinais entre normal, murmúrio e extrassístole. Nesse trabalho é feita uma comparação entre modelos clássicos (árvore de decisão, florestas aleatórias e Classificador de vetor de suporte linear) e modelos de redes neurais profundas (Multi-Layer Perceptron ou MLP e Rede Neural Recorrente).

Utilizando Rede Neural convolucional (CNN), (WOLK; WOLK, 2019) propõem um sistema de classificação de doenças cardíacas. Um filtro passa-baixas foi utilizado nos dados de ECG para extrair o espectro do áudio, e uma rede CNN foi utilizada para a classificação dos batimentos como normal ou sob a presença de alguma anormalidade.

Diante deste panorama, a proposta desse trabalho é desenvolver uma ferramenta assistida por computador baseada em uma Rede Neural Convolucional (CNN 1D) combinada com o algoritmo Coeficiente de Predição Linear (LPC), Figura 1.3, que possa classificar os batimentos como normal ou sob condições de anormalidades a partir de sinais de Eletrocardiogramas (ECG).

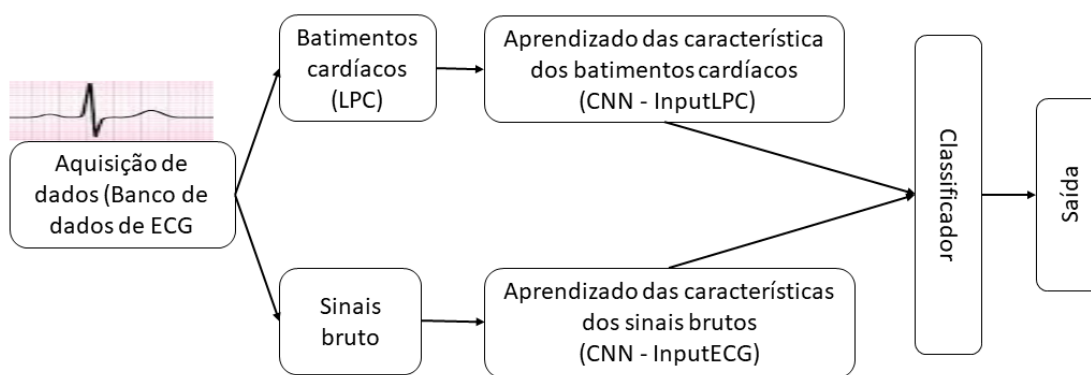


Figura 1.3 Fluxograma do projeto

Por curiosidade coloco aqui informação sobre a ferramenta utilizada pela SBC para registrar, momento a momento o número de pessoas que vão à óbito em decorrência de

DCV, o Cardiômetro, Figura 1.4. Essa ferramenta serve como uma forma de alerta para conscientização da população com os cuidados que deve ter com a saúde do coração.



Figura 1.4 DCV por ano, mês e dia

1.1 JUSTIFICATIVA

De acordo com os especialistas o sinal de ECG é um sinal que sofre com os efeitos de contaminações externas tais como, ruídos provocados pela rede elétrica, movimentos voluntários ou involuntários do paciente no momento de realizar o exame, chaveamento de equipamentos próximos, entre outros, existe a possibilidade de ocorrência de erros no diagnóstico médico. Os estudos mostram que de 2% a 8% dos pacientes que são examinados em unidades de pronto atendimentos são equivocadamente liberados, e muitas dessas pessoas morrem ou sofrem uma parada cardíaca completa (RODRIGUES et al., 2012).

Neste contexto fica claro a importância no desenvolvimento de métodos automáticos que sejam capazes de auxiliar profissionais da área da saúde e até mesmo os próprios pacientes na detecção de sinais indicativos dessa classe de doenças. A análise do sinal de ECG é amplamente usada para diagnosticar doenças cardíacas, que são uma das principais causas de mortalidade em países desenvolvidos e em desenvolvimento.

1.2 OBJETIVOS

Neste trabalho, o objetivo é desenvolver um sistema de detecção e classificação dos batimentos cardíacos de alguns tipos de arritmias, baseado em Coeficientes de Predição Linear (LPC) e uma Rede Neural Convolutacional (CNN) 1D, para auxiliar os profissionais da saúde no diagnóstico de doenças associadas ao coração.

1. Desenvolver um algoritmo baseado em Coeficientes de Predição Linear (LPC) para tratar e extrair a frequência cardíaca dos sinais ECG;
2. Construir uma Rede Neural Convolutacional (CNN) 1D para classificação de sinais ECG;

3. Avaliar o desempenho do método proposto.

1.3 ORGANIZAÇÃO DO TEXTO DA DISSERTAÇÃO

Além da Introdução, a Dissertação é dividida nos capítulos a seguir:

- No Capítulo 2 é realizada uma revisão bibliográfica, onde é apresentado o sinal ECG, o estado da arte, a técnica dos Coeficientes de Predição Linear (LPC), a Rede Neural Artificial RNA, a Rede Neural Convolutacional Unidimensional CNN 1D e a proposta da Dissertação;
- No Capítulo 3, resultados de desempenho sobre o uso de LPC para detecção dos batimentos cardíacos são discutidos;
- No Capítulo 4, o desempenho no uso de uma proposta de classificador baseado em um sistema LPC/CNN-1D é apresentado;
- E na Conclusão, um resumo das maiores contribuições desta Dissertação é apresentado.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

Muitas técnicas têm sido utilizadas no desenvolvimento de algoritmos com a finalidade de classificar sinais biomédicos. Uma dessas técnicas é a *Transformada Wavelet* (CAMPITELLI M. A., 2015). Essa técnica também foi aplicada por (SUTERIO, 2017) para o desenvolvimento do seu algoritmo que utilizou um pacote de Transformadas Wavelet durante o processo de extração das características dos sinais de ECGs. Em seguida, esses dados foram apresentados para uma rede neural artificial de múltiplas camadas completamente conectadas conhecida por Perceptron de Múltiplas Camadas (MLP) (SUTERIO, 2017), para fazer a classificação. O algoritmo encontrou as melhores combinações dos parâmetros utilizados pela rede neural MLP para cada uma das Transformadas *Wavelet* escolhidas chegando a resultados satisfatórios.

No estudo realizado por (PŁAWIAK, 2018), foi apresentado um método de pesquisa que permitia uma boa classificação de cardiopatias, nesse caso, 17 classes com base na análise de sinais de ECG e um sistema neural evolucionário. Para tanto, foram utilizados diversos tipos de algoritmos de pré-processamento, normalização, extração e seleção de recursos, validação cruzada e aprendizado de máquina. Foi obtida uma sensibilidade de 90,20%, precisão de 98,85%, especificidade de 99,39%.

Dois contribuições foram mostradas no trabalho realizado em (LUZ, 2012). Na primeira, foi elaborada uma revisão da literatura dos métodos destinados à classificação de arritmias em sinais de ECG e em segundo, foi apresentado um novo método para classificação de arritmias usando classificação hierárquica. Além disso foram feitas investigações de novas características para representação do batimento cardíaco baseadas em uma representação 2D do sinal de ECG, o Vectorcardiograma (VCG), e redes complexas.

(NOMAN et al., 2019) Desenvolveu um conjunto CNN de frequência de tempo (TF-ECNN) combinando uma CNN-1D com uma CNN-2D com base na fusão em nível de pontuação das probabilidades de classe. Foi projetada uma CNN-1D que aprende diretamente os recursos de sinais brutos de som do coração e uma CNN-2D que recebe entradas de mapas de recursos bidimensionais de frequência de tempo com base em Coeficientes Cepstral de Frequência-Mel.

Em (DAS; CHOWDHARY; GAO, 2020) propôs o desenvolvimento de uma ferramenta de diagnóstico assistido por computador baseado em IA, para classificar anormalidades a partir da leitura de radiografia de tórax para auxiliar os médicos a chegar a um diagnóstico rápido. Empregaram uma Rede Neural Convolutiva (CNN) projetada pelo Google conhecida como XceptionNet para detectar essas patologias nos dados do ChestX-ray14.

Uma automatização de classificação binária foi proposta por (DUNNMON et al., 2019) para possibilitar um alto desempenho de classificação de radiografias de tórax com abordagem de aprendizado de máquina CNNs.

Uma rede neural convolutiva profunda pode ser treinada utilizando milhões de

parâmetros e milhares de neurônios, como a usada para classificar 1,2 milhão de imagens de alta resolução no concurso ImageNet LSVRC-2010 para 1000 classes (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

No trabalho de (ROMDHANE et al., 2020) eles fazem uso de um modelo de CNN profundo que é otimizada por uma nova função de perda chamada perda focal. Essa função melhora a precisão da classificação nas classes de batimentos cardíacos menores, além de melhorar as métricas em geral. Para treinar e avaliar o modelo na identificação de cinco tipos de arritmias (N, S, V, Q e F), foram utilizados as bases de dados de ECG do MIT-BIH e INCART, baseadas no padrão da *Association for Advancement of Medical Instrumentation (AAMI)*.

Na visão de (MADAN et al., 2021), o modelo híbrido baseado em *Deep Learning* é utilizado para detectar três tipos de arritmias. Porém, inicialmente, os sinais unidimensionais de ECG são convertidos para imagens de escalograma. Segundo o artigo, esse processo é realizado para poder eliminar as etapas de filtragem de ruído e a extração de características. Dessa forma, é possível combinar dois modelos, 2D-CNN e LSTM. As três formas de arritmias detectadas são: Arritmias Cardíacas (ARR), Insuficiência Cardíaca Congestiva (ICC) e Ritmo Sinusal Normal (NSR).

No estudo conduzido por (ACHARYA et al., 2017) foi implementado um algoritmo de rede neural convolucional para a detecção automática de batimentos de ECG normais e MI (Infarto do Miocárdio). Obteve-se uma precisão média de 93,53% e 95,22% para os dados com e sem ruído, respectivamente. Os sinais de ECG foram base de dados de ECG diagnóstico PTB (Physikalisch Technische Bundesanstalt). Nesta base há 200 sinais de ECG de 148 indivíduos com MI e 52 indivíduos saudáveis. Cada sinal é amostrado a 1000 amostras por segundo.

A arquitetura *Deep Learning* (DL) proposta por (NURMAINI et al., 2019) é dividida em *Deep Auto-Encoders* (DAEs) no formato de aprendizado não supervisionado e Redes Neurais Profundas (DNNs) como classificador. Nesse modelo foi utilizado 10 classes de dados desbalanceados de sinais de ECG. Os resultados encontrados foram 99,73% de acurácia, 91,20% de sensibilidade, 93,60% de precisão, 99,80% de especificidade e 91,80% de *F1-Score*. Para os autores, o modelo desenvolvido com base na extração de características não supervisionada e rede neural profunda pode ser usado tanto para uma grande população quanto em instalação para uso clínico.

A importância que os sons cardíacos desempenham no diagnóstico de doenças cardíacas, levou (LI et al., 2020) a combinar um método convencional de engenharia de recursos com algoritmos de aprendizado profundo com a finalidade de classificar de forma automática sons cardíacos normais e anormais. Foram extraídas 497 características a partir de oito domínios, que serviram como dados de entrada de uma rede neural convolucional (CNN) projetada. Nesse estudo, os autores substituíram as camadas totalmente conectadas por uma camada de *pool* de média global para obter informações globais sobre os mapas de recursos e evitar *overfitting*. Para avaliar o desempenho do método utilizou-se a validação cruzada estratificada. A precisão média, sensibilidade, especificidade e coeficiente de correlação de Matthews observados no conjunto de dados PhysioNet/CinC Challenge 2016 foram 86,8%, 87%, 86,6% e 72,1%, respectivamente. O desempenho do algoritmo proposto alcança um equilíbrio adequado entre sensibilidade e especificidade.

Existem diversas técnicas que são aplicadas para classificação dos batimentos cardíacos no auxílio dos profissionais da saúde, isso motivou o desenvolvimento de um modelo para detectar e classificar batimentos cardíacos a partir de sinais de ECG, utilizando um algoritmo LPC (Linear Prediction Coeficients) e uma CNN (Convolutional Neural Network) 1D.

2.1 SINAIS DE ELETROCARDIOGRAMA

O sinal de ECG obtido a partir do eletrocardiograma foi uma das primeiras representações dos sinais elétricos produzidos para caracterizar o comportamento do coração e estudados pelas técnicas de processamento de sinais biomédicos.

Esse sinal é produzido por estímulos elétricos que ocorrem no coração. Uma parte da corrente elétrica derivada desses estímulos atinge a superfície do corpo, provocando diferenças de potencial em diversas partes do corpo (OLIVEIRA, 2019). Essas diferenças de potencial são capturadas através de eletrodos colocados sobre a pele a partir de um procedimento chamado de Eletrocardiograma, que devido à sua simplicidade e por ser um exame não invasivo é a técnica mais utilizada no diagnóstico de doenças do coração (BHYRI; HAMDE; WAGHMARE, 2011), (GACEK; PEDRYCZ, 2011).

Na Figura 2.1 é mostrado um exemplo do registro das atividades elétricas dos batimentos normais do coração com destaque ao conjunto de ondas P, Q, R, S e T que compõem um ciclo completo do sinal de ECG.

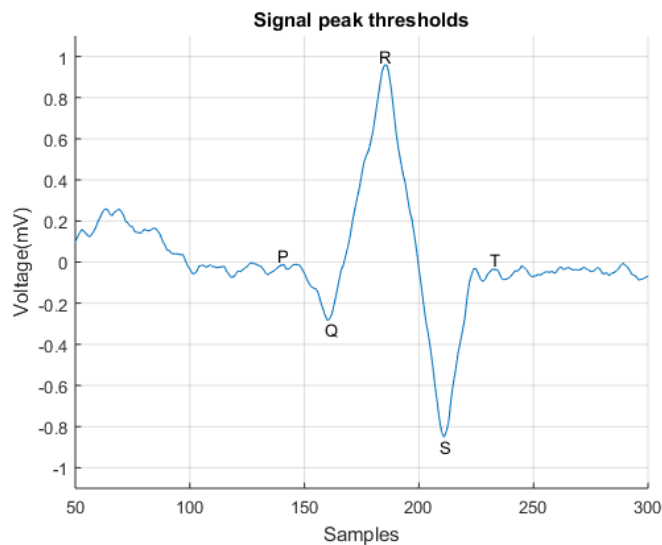


Figura 2.1 Complexo QRS

A estrutura do coração lhe confere a capacidade de se auto-excitar, ou seja, células do miocárdio são capazes de gerar e propagar estímulos elétricos de forma organizada por todas as câmaras do coração, isso possibilita a contração organizada dos átrios e ventrículos e, conseqüentemente, o batimento cardíaco, Figura 2.2.

Neste processo as estruturas envolvidas são:

- fibras de Purkinje, que conduzem o impulso a todas as partes dos ventrículos;
- nódulo atrioventricular, no qual o impulso proveniente dos átrios é retardado antes de passar para os ventrículos;
- nódulo sinoatrial ou sinusal, no qual o impulso auto-excitador rítmico é gerado;
- feixe de His, que conduz o impulso dos átrios aos ventrículos;
- vias internodais, que conduzem o impulso do nódulo sinoatrial para o nódulo atrioventricular.

O sinal de eletrocardiograma é formado pela contribuição de cada potencial de ação, e por representar a maior parte do tecido do coração, a contribuição mais expressiva se dá pelos músculos atriais e ventriculares.

Por ser um registro gráfico destas diferenças de potencial ao longo do tempo, cada estrutura envolvida na condução gera potenciais de ação que contribuem na formação da onda em cada ciclo cardíaco. Essas estruturas são conhecidas como complexo P-QRS-TU (OLIVEIRA, 2009), conforme está mostrado na Figura 2.2.




Figura 2.2 Diferenças de potenciais gerados no coração (OLIVEIRA, 2009)

A representação do sinal de eletrocardiograma mostrada na Figura 2.3 destaca as sete ondas características provenientes dos diversos potenciais de ação gerados pelas diversas estruturas do coração. Essas estruturas são percorridas por um estímulo elétrico e uma

fração deste estímulo elétrico proveniente dos diversos potenciais chegam a superfície do corpo, gerando diferenças de potencial em pontos específicos do corpo. Cada uma dessas sete ondas contribui para a formação do ciclo cardíaco que caracteriza o ECG, formado pelas ondas P, Q, R, S, T. As ondas Q, R e S formam um único parâmetro denominado complexo QRS. Já a onda P representa a contração (despolarização) (OLIVEIRA, 2009).

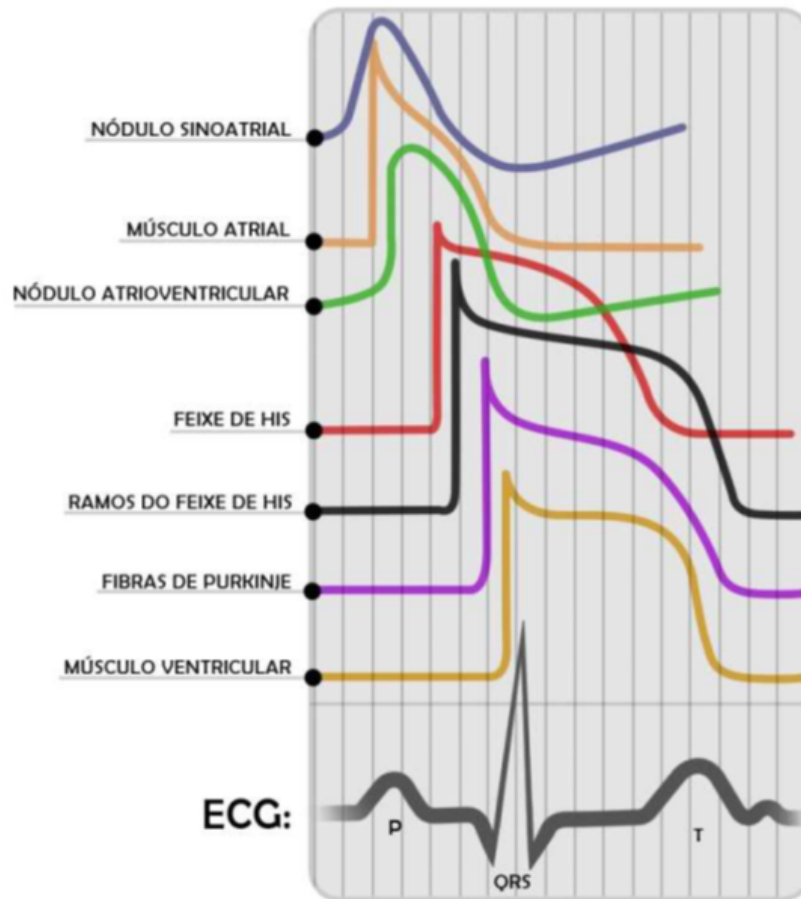


Figura 2.3 Contribuição de cada onda para a formação do ECG (OLIVEIRA, 2009)

Numa breve explicação, pode-se dizer que a onda P representa a contração (despolarização) atrial, em seguida vem o complexo QRS que representa a despolarização do ventrículo, e por fim, a onda T indica o relaxamento (repolarização) ventricular. O complexo QRS é o conjunto de ondas mais importante do sinal de ECG, porque é onde se detecta, por exemplo, a maioria das arritmias.

2.2 COEFICIENTES DE PREDIÇÃO LINEAR (LPC)

A predição linear é uma técnica amplamente utilizada no processamento da fala (HENNING, 2017), pois, é possível realizar uma boa modelagem através desta ferramenta. Em

(OKIDA; MARAR; QUEIROZ,), o método de predição linear é utilizado para extrair características de trechos musicais baseado em alguns detalhes de gêneros do tipo rock e cantos gregorianos. O algoritmo foi implementado para calcular os coeficientes LPC dos trechos de músicas.

No trabalho realizado por (MARVI; ESMAILEYAN; HARIMI, 2013) foram utilizados algoritmos baseados em inspiração biológica tais como: o Genetic Algorithm (AG), Particle Examination Optimization (PSO) e Particle Examination Optimization with Disturbed Differential Velocity (PSO-DV) e o algoritmo Differential Evolution (ED), são usados para encontrar os coeficientes de predição linear LPC que pudessem prever o sinal original com um erro mínimo de previsão em sistemas de processamento da fala.

A ideia central do método LPC é encontrar os coeficientes que possam prever o sinal original com o menor erro de previsão possível. O sinal descrito pela predição linear é composto pela combinação linear de saídas e entradas passadas, conforme pode ser visto na Equação 2.1, (MAKHOUL, 1975a).

$$\hat{x}[n] = - \sum_{k=1}^p a_k x[n-k] + \beta \sum_{i=0}^g y_i u[n-i] \quad (2.1)$$

em que a_k , y_i e o ganho β são os parâmetros que caracterizam o sistema, sendo $x[n]$ o sinal de saída e $u[n]$, sinal de entrada. Aplicando a Transformada Z na equação 2.1 e sabendo que $y_0 = 1$, a função de transferência do sistema é descrita por

$$G(z) = \beta \frac{1 + \sum_{i=1}^g y_i z^{-i}}{1 + \sum_{k=1}^p a_k z^{-k}}, \quad (2.2)$$

onde as raízes do numerador e do denominador descrevem, respectivamente, os zeros e os polos do sistema.

Existem duas simplificações do modelo que são de interesse. Uma delas é o modelo *all-zero*, que zera todos os parâmetros a_k e realiza a predição por intermédio das entradas passadas. Outra é o modelo *all-pole*, que zera todos os parâmetros y_i e realiza a predição através das saídas passadas. Neste trabalho é utilizado o modelo *all-pole*, pois, é o modelo no qual o LPC se baseia.

Sendo assim, depois de aplicar o modelo *all-pole* na Equação 2.1, obtém-se

$$\hat{x}[n] = - \sum_{k=1}^p a_k x[n-k] + \beta u[n] \quad (2.3)$$

em que a_k é o k -ésimo coeficiente preditivo do LPC e p representa a quantidade de amostras passadas que são utilizadas na predição. Além disso, define também a ordem do filtro de predição utilizado. Essa abordagem também pode ser aplicada para minimizar a média quadrática do erro de predição linear em Reconciliação de Dados pela eliminação de *outliers* em (ARAÚJO et al., 2009). Levando-se em conta que o LPC se baseia no fato de expressar o sinal como uma saída de um filtro digital linear (MARVI; ESMAILEYAN; HARIMI, 2013), a reconstrução da sequência $\hat{x}[n]$ utilizando predição linear pode ser aproximada por uma sequência mostrada na Equação 2.4,

$$\hat{x}[n] = - \sum_{k=1}^p a_k x[n-k] \quad (2.4)$$

considerando que a entrada $u[n]$, na maioria dos casos, não é conhecida, e por isso, a predição do sinal $x[n]$ se dá somente com a soma ponderada das amostras passadas (HENNING, 2017). Razão pela qual a predição linear recebe esse nome, ou seja, pelo fato de estimar a amostra atual do sinal $x[n]$ como uma combinação linear de suas p amostras anteriores (MARVI; ESMAILEYAN; HARIMI, 2013; HENNING, 2017; ARAÚJO et al., 2009). De acordo com a teoria de sistemas lineares, a sequência estimada é a saída de um filtro digital de ordem p do tipo FIR (Resposta Impulsiva Finita).

A diferença entre a sequência real e a sequência predita é chamada de erro residual e pode ser escrito conforme a Equação 2.5, sendo que $\hat{x}[n]$ é o sinal estimado (BERALDO, 2017).

$$e[n] = x[n] - \hat{x}[n] \quad (2.5)$$

Considerando que $\hat{x}[n]$ é conhecido, o erro residual $e[n]$ pode ser reescrito conforme a Equação 2.6

$$e[n] = x[n] + \sum_{k=1}^p a_k x[n-k] \quad (2.6)$$

O sinal de erro $e[n]$ é sensível às variações repentinas do sinal $x[n]$ devido ao comportamento de filtro passa-alta (LIMA; SILVA; ARAÚJO, 2020), como pode ser deduzido aplicando a transformada Z ao erro $e[n]$ dividido pela transformada Z do sinal de entrada $x[n]$, cujo resultado é mostrado na Equação 2.7.

$$H(z) = \frac{E(z)}{X(z)} = 1 + \sum_{k=1}^p a_k z^{-k} \quad (2.7)$$

Este comportamento do tipo passa-alta é importante para eliminar a presença de *drift* (componentes de baixa frequência) que podem prejudicar o desempenho do método LPC. Dessa forma, a medição da frequência cardíaca a partir do sinal ECG não é afetada pela presença de *drift* e deslocamentos, como é visto no Capítulo 3.

Para (HENNING, 2017) um dos métodos usados para minimização do erro residual descrito pela Equação 2.5 se dá através do método dos mínimos quadrados (MAKHOUL, 1975b), que busca a minimização do erro quadrático total do sinal. Para um sinal não determinístico, por exemplo o ECG, um sinal cujo comportamento não pode ser reproduzido de maneira exata e repetida (HIGUTI; KITANO, 2003a), pode-se escrever o erro quadrático total de acordo com Equação 2.8.

$$E = \sum_n (e[n])^2 = \sum_n (x[n] + \sum_{k=1}^p a_k x[n-k])^2 \quad (2.8)$$

Logo, a minimização do erro quadrático total pode se dá por

$$\frac{\partial E}{\partial a_k} = 0 \quad (2.9)$$

Determina-se a partir da Equação 2.9 o conjunto de p equações com p incógnitas, denominadas de equações normais, Equation 2.10 (OKIDA; MARAR; QUEIROZ, ; HENNING, 2017).

$$\sum_{k=1}^p a_k \sum_n x[n-k]x[n-i] = - \sum_n (x[n]x[n-i]) \quad (2.10)$$

Considerando que o sinal de ECG é um sinal não determinístico (HIGUTI; KITANO, 2003b), os coeficientes de predição linear a_k que minimizam a média quadrática do erro $e[n]$ podem ser encontrados a partir da solução da Equação 2.11 mostrada na sua forma matricial abaixo (ARAÚJO et al., 2009):

$$\begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} r_0 & r_1 & \dots & r_{p-1} \\ r_1 & r_2 & \dots & r_{p-2} \\ \vdots & \vdots & & \vdots \\ r_{p-1} & r_{p-2} & \dots & r_0 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix} \quad (2.11)$$

em que r_k é a autocorrelação do sinal $x[n]$ calculado pela Equação 2.12

$$r_k = \sum_{i=1}^{N-1-k} x_i[n]x_{k+i}[n] \quad (2.12)$$

2.3 REDE NEURAL ARTIFICIAL (RNA)

Nas últimas décadas, o surgimento das Redes Neurais Artificiais gerou uma grande reviravolta na área de aprendizado de máquina (*Machine Learning*). Estas modelagens computacionais de inspiração biológica foram capazes de superar o desempenho de métodos anteriores de inteligência artificial nas tarefas comuns de aprendizado (O'SHEA; NASH, 2015).

Conceitualmente, uma Rede Neural Artificial é um sistema constituído de unidades de processamento simples, cuja proposta é armazenar conhecimento experimental a partir de um processo de aprendizado de conexões chamadas de pesos sinápticos, para ser usado sempre que for solicitado (KOVÁCS, 2002; HAYKIN, 2007). Na rede neural a unidade fundamental de processamento é o neurônio, Figura 2.4.

Em 1943, o neurofisiologista Warren MacCulloch e o matemático Walter Pitts publicaram o artigo *A Logical Calculus of the Ideas Immanent in Nervous Activity*. Nesse artigo os autores mostraram como era o funcionamento de um neurônio a partir de um




Figura 2.4 Neurônio Artificial. haykin2007redes

modelo de rede neural simples com circuitos elétricos (KOVÁCS, 2002; HAYKIN, 2007). Em 1949, o biólogo e psicólogo Donald Hebb escreveu um livro chamado *The Organization of Behavior*, em que apresenta uma regra de aprendizado filosófica na qual propõe que o aprendizado do cérebro é modificado continuamente conforme vai aprendendo tarefas funcionais diferentes. Isso se tornou uma fonte de inspiração para o desenvolvimento de modelos computacionais de sistemas adaptativos e de aprendizados (KOVÁCS, 2002; HAYKIN, 2007).

Na Figura 2.4 temos um modelo de um neurônio artificial. O par de Equações 2.13 e 2.14 descreve um k -ésimo neurônio em termos matemáticos.

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (2.13)$$

e

$$y_k = \lambda(v_k + b_k) \quad (2.14)$$

em que x_1, x_2, \dots, x_m são os sinais de entrada, os valores $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k , v_k é a saída do somatório após a combinação linear devido aos sinais de entrada. O *bias* b_k realiza uma translação afim na saída do somador linear u_k , aumentando ou diminuindo o valor de entrada da função de ativação λ . Dependendo se o bias é positivo ou negativo, a relação entre a saída do somador linear e o potencial de ativação é alterada conforme a Figura 2.5 (KOVÁCS, 2002; HAYKIN, 2007).

A função de ativação $\lambda(\bullet)$ insere uma não linearidade à saída y_k do neurônio. Assumindo que o *bias* b_k é um parâmetro externo ao neurônio artificial k , é possível reescrever a Equação 2.14 como mostrado na Equação 2.15.

$$y_k = \lambda \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.15)$$

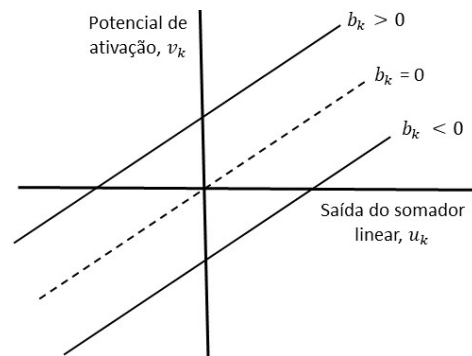


Figura 2.5 Translação provocada pelo bias. (HAYKIN, 2007)

A arquitetura da rede do tipo Perceptron, Figura 2.6, foi introduzida na década de 50 pelo neurobiologista Frank Rosenblatt, em seu trabalho seminal *The Perceptron: A Probabilistic Model For Information Storage and Organization in the Brain*, na Universidade de Cornell. A rede utilizava múltiplos neurônios do tipo discriminadores lineares. Devido as suas grandes contribuições técnicas em sistemas de alta complexidade, muitos o consideram o fundador da neurocomputação (KOVÁCS, 2002; HAYKIN, 2007).

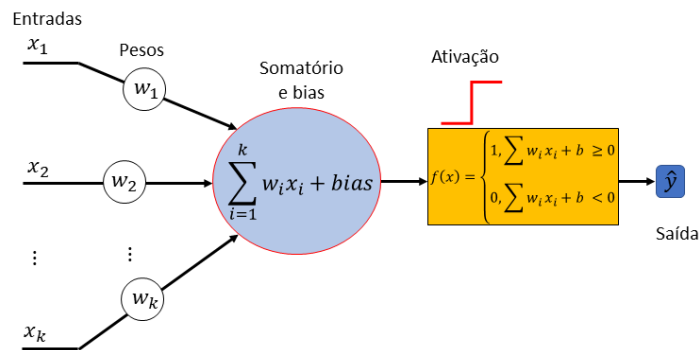


Figura 2.6 Modelo Perceptron.

(MARVI; ESMAILEYAN; HARIMI, 2013), co-fundador do Laboratório de Inteligência Artificial do MIT, construiu em 1951 o SNARC, o primeiro simulador de cadeia neural. No final da década de 60, Marvin Minsky e Seymour Papert utilizaram a matemática para mostrar que existem limitações fundamentais naquilo que o Perceptron de camada única e de múltiplas camadas de Rosenblatt poderiam calcular em situações que incluíam problemas não lineares (KOVÁCS, 2002; HAYKIN, 2007). Isso levou a um esmorecimento no interesse por pesquisas em redes neurais na década de 70. Bernard Widrow da Universidade de Stanford desenvolveu em 1960 um novo modelo de processamento de redes neurais chamado de Adaline (*Adaptive Linear Element*), cujo princípio de treinamento era baseado na Regra Delta. Mais tarde, ele criou a Madaline, que era uma

Adaline Multidimensional (KOVÁCS, 2002; HAYKIN, 2007).

2.4 REDE NEURAL CONVOLUCIONAL

Nas últimas décadas o aprendizado profundo vem demonstrando grande sucesso em vários campos da ciência, principalmente no processamento de sinais biomédicos de imagens radiológicas, reconhecimento da fala, detecção e classificação de batimentos cardíacos, segurança cibernética, dentre outros, como na análise de imagens para detectar infarto do miocárdio a partir de ECGs (ACHARYA et al., 2017), (IZCI et al., 2019).

Diversos métodos têm sido propostos em diferentes categorias de abordagens de aprendizagem em áreas como aprendizado supervisionado, semi-supervisionado e não supervisionado. O desempenho experimental mostra que o aprendizado profundo avança em relação às abordagens tradicionais de aprendizado de máquina. Nesse contexto de técnicas de aprendizado de máquinas a rede neural convolucional (CNN) se destaca no processo de classificação de imagens, reconhecimento de voz, classificação de batimentos cardíacos, entre outras aplicações. As CNNs têm sido bem-sucedidas na detecção e diagnóstico de anormalidades em sinais biomédicos (ALASKAR, 2018), (ATAL; SINGH, 2020).

As Redes Neurais Convolucionais (CNNs) são similares às Redes Neurais Artificiais tradicionais (RNAs), pois, os neurônios se auto-otimizam automaticamente durante o processo de aprendizagem (O'SHEA; NASH, 2015). Entretanto as RNAs trazem uma desvantagem que é a grande demanda por hardware necessários para sua implementação (MONTES; LATTARI; COELHO, 2021). A dificuldade para se treinar uma rede neural artificial de forma eficiente era visível e por isso, outras arquiteturas de redes neurais foram sendo modeladas (OLIVEIRA; CÂMARA, 2019).

O nome Rede Neural Convolucional (CNN) Figura 2.7, se origina do fato de que em pelo menos uma de suas camadas, essas redes neurais artificiais usam a operação de convolução. As ConvNets ou CNNs como são mais conhecidas, precisam de um número relativamente grande de amostras durante a etapa de aprendizado (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

Para a visão computacional, as redes neurais convolucionais se tornaram o novo padrão porque são fáceis de treinar mesmo que para isso, seja necessária uma considerável quantidade de amostras que representem os diferentes tipos de classes (O'SHEA; NASH, 2015). Sendo assim, Redes Neurais Convolucionais (CNNs) podem ser usadas para projetar sistemas de previsão e classificação de sinais biomédicos em estágio inicial (SINGHAL; KUMAR; PASSRICHA,), onde diversos recursos clínicos são fornecidos como entrada para uma CNN.

2.5 REDE NEURAL CONVOLUCIONAL UNIDIMENSIONAL (CNN 1D)

Até aqui as CNNs foram apresentadas com uma arquitetura adequada para processar imagens e vídeos, ou seja, dados no formato 2D. No entanto, uma versão modificada da CNN 2D foi recentemente desenvolvida e passou a ser chamada de CNN 1D (KIRANYAZ et al., 2019). Nesse estudo, ficou comprovado que para certas aplicações, como sinais de ECG, as CNNs 1D têm mais vantagens em relação às CNNs 2D. Isso significa dizer que

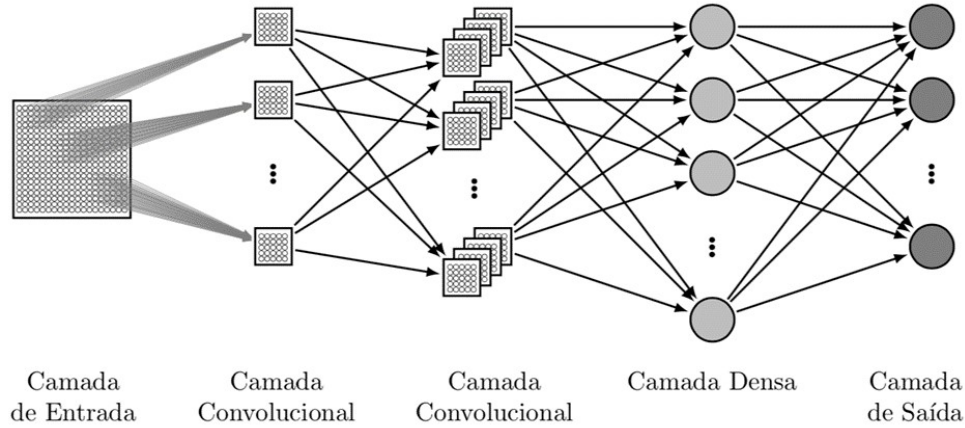


Figura 2.7 Rede CNN genérica

as CNNs 1D têm menor complexidade computacional por trabalhar com matrizes mais simples. E por usarem arquiteturas menos profundas com menor quantidade de camadas ocultas e neurônios, torna a rede menos complicada de ser treinada.

Numa rede CNN unidimensional (1D) típica a saída da camada convolutiva é descrita matematicamente pela Equação 2.16

$$y_i^k = \lambda \left(\sum_{i=1}^N x_i^k * w_i^k + b_i^k \right), \quad (2.16)$$

em que y_i^k é o vetor de saída da i -ésima camada com k -ésimo neurônio, x_i^k é o vetor de entrada, w_i^k é o peso associado a cada entrada, b_i^k é o *bias*, $\lambda(\bullet)$ é a função de ativação e $(*)$ é o sinal da convolução.

Por apresentar baixa complexidade computacional, em certas aplicações, as CNNs 1D são adequadas para aplicativos em tempo real, especialmente os dispositivos móveis e portáteis. Por esse motivo, muitos trabalhos têm proposto métodos baseados em rede neural convolutiva 1D para classificação de patologias a partir dos sinais de eletrocardiograma (ECG) (SHAKER et al., 2019; KIRANYAZ; INCE; GABBOUJ, 2015). Um exemplo de configuração de uma CNN 1D é mostrada na Figura 2.8. O número de camadas escondidas depende da complexidade do problema.

A rede neural convolutiva 1D pode ser implementada para classificação e monitoramento de um eletrocardiograma (ECG), como por exemplo, de pacientes específicos, ou adaptada para unir dois blocos da classificação de ECG em um único bloco de aprendizado: extração e classificação de recursos, aplicando para cada paciente, uma CNN 1D individual treinada usando dados de treinamento comuns e específicos do paciente (KIRANYAZ; INCE; GABBOUJ, 2015). Os recursos (informações) são extraídos dos dados de entrada pelas camadas convolucionais, aplicando a operação de convolução entre o si-

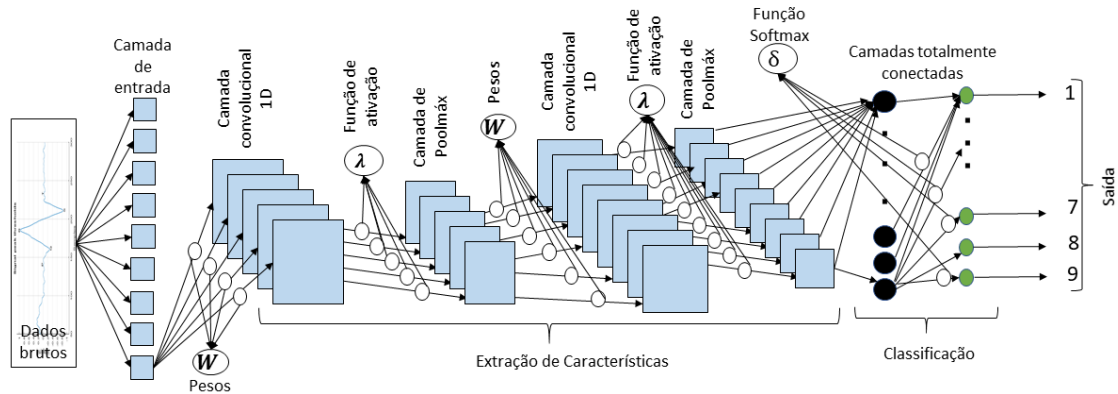


Figura 2.8 Rede CNN 1D

nal de entrada e os núcleos de convolução. Depois os valores calculados são passados por uma função de ativação para tornar esses recursos não lineares (SHAKER et al., 2019).

Recentemente (PICON et al., 2019), desenvolveram uma arquitetura de aprendizado profundo baseada em redes neurais convolucionais 1D (CNN) e uma rede de memória de longo prazo (LSTM) para a detecção de características da fibrilação ventricular FV.

Para detecção de QRS e classificação do batimento cardíaco de sinais de ECG bruto, (LEÓN; ALVAREZ, 2019) mostra uma nova abordagem para detectar batimentos ventriculares usando uma Rede Neural Convolutiva 1D, sem utilizar nenhum pré-processamento do sinal nem extração de recursos. A metodologia de avaliação seguiu o paradigma inter-paciente, onde o algoritmo foi treinado e avaliado usando subconjuntos independentes. De acordo com (LEÓN; ALVAREZ, 2019), ainda existe bastante espaço para melhorias, pois, os resultados mostram que as redes neurais convolucionais são uma abordagem promissora para a construção de classificadores de heartbeat (batimentos cardíacos).

Tal qual as CNNs 2D convencionais, a camada de entrada não aprende nenhuma característica, funciona de forma passiva apenas para receber os dados brutos do sinal de entrada 1D. Na outra extremidade temos a camada de saída que é uma camada tipo MLP (Multilayer Perceptron) cujo o número de neurônios na saída deve ser igual ao número de classes a ser identificadas.

No trabalho realizado por (ACHARYA et al., 2017) foram utilizados dois bancos de dados de ECG para validação do método proposto. Os dois conjuntos de dados tinham mesmo número de batimentos de ECG. Num dos conjuntos foram retirados o ruído e a linha de base do sinal de ECG usando a Transformada Wavelet. Os sinais de ECG utilizados para realizar o trabalho, foram retirados do banco de dados de ECG PTB (Physikalisch-Technische Bundesanstalt). Este banco de dados contém dados de ECG de 200 indivíduos (148 MI-Infarto do Miocárdio e 52 indivíduos saudáveis).

O modelo desenvolvido por (LI et al., 2017) foi utilizado para realiza a classificação de 5 tipos típicos de sinais de arritmia, ou seja, normal, bloqueio de ramo esquerdo,

bloqueio de ramo direito, contração atrial prematura e contração ventricular prematura. Os resultados experimentais no banco de dados público de arritmia do MIT-BIH mostram que o método proposto atinge uma precisão de classificação promissora de 97,5%.

2.5.1 Camada de Entrada

Nas Redes Neurais Convolucionais (CNNs), a camada de entrada pode ser carregada geralmente, por um vetor unidimensional ou multidimensional. Entretanto essa camada não realiza nenhuma operação matemática ou de aprendizado, sua função será a de receber os dados.

2.5.2 Camada Convolutiva

O nome “camada convolutiva” indica que essa camada em algum momento realizará uma operação matemática chamada convolução. A Equação 2.17, descreve a operação matemática de convolução realizada pelas redes neurais convolucionais. Em processamento de dados de séries temporais, como é o caso de sinais de ECG, o treinamento de modelos baseados em rede neural convolutiva CNN produzirá uma linha temporal indicando a posição de diferentes características dos dados treinados gerando mapas de características (HEATON, 2018) e (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$h(k) = (x * \omega)(k) = \sum_{n=-\infty}^{\infty} x(n)\omega(k - n) \quad (2.17)$$

Dependendo da complexidade dos vetores de entrada, é necessário colocar várias camadas convolucionais para melhorar o processo de aprendizado, aumentar a quantidade de características aprendidas pela rede e conseqüentemente, melhorar o seu desempenho.

Neste projeto a camada convolutiva é responsável por gerar mapas de características a partir de filtros 3×1 . Na tarefa de convolução, a matriz do filtro convolutivo desliza sobre o sinal de entrada de acordo com o passo (*stride*) de convolução. Em outras palavras, isso quer dizer que, quando o passo é 1 o deslocamento do filtro sobre o sinal ocorre de coluna em coluna. Quando o passo é 2, o deslocamento do filtro é sobre duas colunas da matriz e assim sucessivamente (MADAN et al., 2021).

2.5.3 MaxPooling

Depois da camada de convolução é aplicada uma camada de MaxPool, Figura 2.9, cuja finalidade é reduzir a dimensionalidade dos dados das camadas anteriores sem que haja prejuízo das informações mais importantes do sinal (SHAKER et al., 2019).

Em outras palavras essa camada é usada para diminuir a dimensionalidade dos sinais de entrada. O MaxPooling é obtido adicionando o filtro máximo a sub-regiões não sobrepostas e selecionando o valor máximo de cada região. Por exemplo, o valor máximo na primeira coluna na terceira linha da Figura 2.9 é 6. Neste trabalho são utilizados filtros 4×1 com padding (preenchimento) igual a 1 para cada camada de convolução 1D (MADAN et al., 2021).




Figura 2.9 MaxPooling.

2.5.4 Função de Ativação ReLU

A função de ativação ReLU (Unidade Linear Retificada), Equações 2.19, é a mais utilizada para projetar redes neurais artificiais.




Figura 2.10 Função ReLU.

A função ReLU é não linear Figura 2.10, e como consequência da característica de não linearidade, nem todos os neurônios serão ativados durante o processo de treinamento como pode ser visto na Equação 2.18. Isso ocorre porque a camada de ativação impedirá que os neurônios cujos valores são negativos sejam ativados (MADAN et al., 2021).

$$f(x) = \begin{cases} x, & \text{se } x > 0, \\ 0, & \text{se } x < 0. \end{cases} \quad (2.18)$$

Em outras palavras, os pesos desse neurônio não serão mais atualizados. Esse neurônio pode então ser chamado Neurônio morto, que é considerado uma espécie de “dano cerebral” permanente em termos biológicos. Isso é a principal desvantagem da função de ativação ReLU.

2.5.5 Função de Ativação LeakReLU

Para resolver o problema de desativação dos neurônios com valores negativos, considerando que nesse projeto será feito o uso de valores negativos durante o processo de treinamento da rede, será utilizada uma nova versão da função de ativação ReLU, chamada LeakReLU, Figura 2.11.

$$f(x) = \begin{cases} x, & \text{se } x > 0, \\ ax, & \text{se } x < 0. \end{cases} \quad (2.19)$$




Figura 2.11 Função LeakReLU.

A função LeakyReLU é uma versão da função ReLU. O gradiente na função ReLU é 0 para os valores de $x < 0$, o que faz com que os neurônios morram por desativações nessa região. A função LeakyReLU resolve este problema. O que se faz com a função LeakyRelu é substituir a linha horizontal por uma linha diferente de zero, Equação 2.19, não horizontal o que costuma ser chamado de vazamento(leaky) aplicando na maioria dos casos um valor bem pequeno, em torno de 0,01 ou 0,02, ainda que alguns autores conseguiram bons resultados utilizando 0,2 (XU et al., 2015). Neste trabalho usou-se um valor pequeno igual a 0,02. A principal vantagem de substituir a linha horizontal é remover o gradiente zero.

2.5.6 Batch Normalization Layer

Durante o processo de treinamento de redes profundas, a BatchNormalizationLayer é uma técnica usada para normalizar as entradas de uma camada anterior e serve como uma regularizadora para evitar que o modelo se sobreponha à medida que o treinamento torna-se mais profundo. Além de melhorar a velocidade de treinamento da rede. (MADAN et al., 2021).

2.5.7 Camada Softmax

A função *Softmax* também conhecida como *softargmax* ou função exponencial normalizada é usada para garantir a probabilidade de que a classe identificada é a classe de

destino. Ela é bastante usada em redes neurais convolucionais para classificação. Ela realiza na saída de uma rede neural a produção de valores no intervalo $[0, 1]$ e divide pela soma das saídas, Equação 2.20. Nessa equação, z representa o vetor de neurônios de saída. A variável j representa o índice do neurônio de saída que está sendo calculado e k representa os índices de todos os neurônios de um nível.

$$\omega_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (2.20)$$

para $j = (1, 2, \dots, K)$ e $z = (z_1, z_2, \dots, z_K) \in \mathbb{R}^K$

Ou seja, num problema com 5 classes, por exemplo, a função *softmax* vai produzir 5 valores, cuja soma é igual a 1, em que cada valor representa a probabilidade da instância pertencer a uma das 5 possíveis classes. As probabilidades são então usadas para decidir qual classe de destino tem maior probabilidade de ocorrer em função dos dados de entrada fornecidos (MADAN et al., 2021).

CAPÍTULO 3

ESTIMAÇÃO DA FREQUÊNCIA CARDÍACA USANDO COEFICIENTES DE PREDIÇÃO LINEAR (LPC)

Nesse capítulo são apresentadas a estratégia e os resultados no uso dos coeficientes de predição linear (LPC) nos sinais de Eletrocardiograma (ECG) para medir a frequência cardíaca. Para isso, foram utilizados os sinais de ECG da base de dados de arritmias cardíacas do *MIT-BIH (Massachusetts Institute of Technology and the Boston Hospital)* e do *PHYSIONET Challenge 2017* para o desenvolvimento de um modelo que possa ser utilizado pelos profissionais da área da saúde no auxílio de diagnósticos médicos. O que motivou a decisão pela utilização desses dois bancos de dados foi a facilidade de conseguir esses dados de sinais de ECG. Além disso os mesmos já vêm no formato compatível com Matlab, sem a necessidade de nenhuma transformação, ou seja, já vêm no formato “.mat”. Para os dados do PHYSIONET, os ruídos são separados em um conjunto de dados a parte. Existem outros bancos de dados de sinais de ECG disponíveis, porém precisa de algoritmos para separar os dados de cabeçalhos e de anotações, como *PTB (Physikalisch-Technische Bundesanstalt)*, *INCART (St. Petersburg Institute of Cardiological Technics 12-lead Arrhythmia database)*, etc. Além disso, em alguns casos esses bancos de dados não estão disponíveis de forma gratuita.

3.1 ESTIMAÇÃO DOS BATIMENTOS CARDÍACOS

Nos trabalhos encontrados na literatura é possível perceber que a maioria das pesquisas sobre a extração de características de sinais de ECG está concentrada no complexo QRS, Figura 3.1. Seguindo essa ideia, neste trabalho utilizou-se um algoritmo desenvolvido com o método baseado no LPC para identificação dos instantes em que ocorre o complexo QRS, com o objetivo de estimar os batimentos cardíacos de algumas patologias cardíacas que posteriormente serão usadas como entradas para uma rede neural que fará a classificação.

A reconstrução da sequência $x[n]$ utilizando predição linear de ordem p pode ser feita por uma sequência mostrada na Equação 2.4, conforme descrito no Capítulo 2. Para entender o uso do LPC na medição da frequência cardíaca, considere o sinal de ECG em tempo discreto $x[n]$, cujas amostras podem ser preditas a partir da sequência $\hat{x}[n]$, Equação 3.1, obtida pelo modelo LPC de quarta ordem ($p = 4$).

$$\hat{x}[n] = - \sum_{k=1}^p a_k x[n-k], \quad (3.1)$$

em que a_k é o k -ésimo coeficiente preditivo do LPC.

A partir da diferença entre o sinal $x[n]$ e o sinal predito $\hat{x}[n]$, é determinado o erro residual de predição $e[n]$, conforme Figura 3.2. Para identificar o intervalo de batimento cardíaco, é usado um limiar de detecção, como pode ser visto na Figura 3.2.




Figura 3.1 Um sinal típico de ECG com destaque para o complexo QRS




Figura 3.2 Aplicação do método a um trecho do sinal ECG de um paciente saudável.

Apesar da escolha do valor do limiar de detecção dos batimentos cardíacos possuir um certo grau de subjetividade (ARAÚJO et al., 2009), é possível definir uma estratégia. Considere uma sequência do erro residual $e[n]$ classificada em ordem crescente a partir do valor absoluto normalizado do erro calculado pela Equação 3.2

$$\tilde{e}[n] = \frac{|e[n]|}{\max_n |e[n]|}, \quad (3.2)$$

É aceitável descartar 10% dos valores maiores de $\tilde{e}[n]$, gerando uma sequência truncada, $\tilde{e}_t[n]$. Considerando que essa nova sequência confere aos eventos de pico um bom destaque, uma referência ao limiar pode ser calculada usando a mediana $\mu_{\frac{1}{2}}$ Equação 3.3:

$$L = \sqrt{\mu_{\frac{1}{2}}(\tilde{e}_t^2[n])}, \quad (3.3)$$

e finalmente fazer uma calibração adequada para o limiar através da Equação 3.4:

$$D = \beta L, \quad \beta > 0 \quad (3.4)$$

Valores adequados do parâmetro β aplicados ao banco de dados MIT foram estabelecidos para $\beta = 6$. A partir disso, uma amostra m é então considerada como um evento *QRS* sempre que a condição $\tilde{e}[n] \geq D$ for correspondida. Dessa forma, para cada duas amostras consecutivas m_1 e m_2 com $m_2 - m_1 = N$, Figura 3.3, o ritmo cardíaco HR em batimentos por minuto (bpm) pode ser estimado, Equação 3.5:

$$HR = \frac{60f_s}{N}, \quad (3.5)$$

em que f_s é a frequência de amostragem em Hertz.

Para avaliar a proposta apresentada foi utilizado a base de dados do Massachusetts Institute of Technology (MIT-BIH) (MOODY; MARK, 2001). Nesta base, os sinais de ECG obtidos de 45 pacientes que podem apresentar algum tipo de doença cardíaca foi aplicado ao LPC.

Por uma questão de simplicidade da avaliação, foram escolhidos registros de pacientes saudáveis e com arritmia, cujas medições dos batimentos cardíacos utilizando o LPC, podem ser vistas na Tabela 3.1. A tabela está descrita da seguinte forma, na coluna Classe são mostrados os nomes das patologias de forma abreviada, na coluna do meio está a definição de cada abreviatura e a coluna Leitura Direta (DR) são exibidos resultados de cada um dos batimentos cardíacos medidos no intervalo de tempo entre os complexos QRS em cada classe.

Os resultados para a medida do ritmo cardíaco utilizando o LPC são exibidos na Tabela 3.2, na qual a coluna Classe mostra várias patologias associadas ao sinal de ECG. Nas colunas método LPC (LPC) e acurácia do método LPC (LPCA), são apresentadas, respectivamente, o batimento cardíaco médio estimado por nosso método e sua precisão

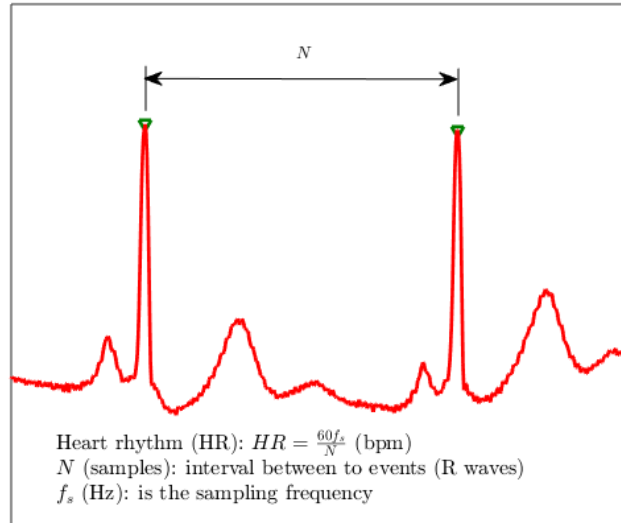


Figura 3.3 Cálculo do ritmo cardíaco usando ondas R detectadas

Tabela 3.1 Registros das Patologias

Classe	Patologia	DR(bpm)
RSN	Ritmo Sinusal Normal	67
APB	Batimento Atrial Prematuro	98
AFL	Flutter Atrial	113
AFIB	Fibrilação Atrial	73
SVTA	Taquicardia Supraventricular	135
WPW	Pré-excitação	65
PVC	Contração Ventricular Prematura	88
VT	Taquicardia Ventricular	110
IVR	Ritmo Ideoventricular	63

em relação à Leitura Direta - Tabela 3.2. Para fins de comparação com a proposta, um código baseado na Transformada *Wavelet* também foi aplicado aos dados para medição do ritmo cardíaco (ARUN, 2020) e os resultados são exibidos nas colunas método *Wavelet* (WT) e acurácia do método *Wavelet* (WTA).

Tabela 3.2 Registros dos batimentos cardíacos

Classe	WT(bpm)	WTA(%)	LPC(bpm)	LPCA(%)
RSN	69	97,02	67	100,00
APB	118	48,22	98	100,00
AFL	99	87,61	113	100,00
AFIB	115	42,47	73	100,00
SVTA	127	94,07	135	100,00
WPW	97	50,77	65	100,00
PVC	66	75,00	88	100,00
VT	83	76,36	112	98,18
IVR	32	50,79	63	100,00

Conforme mostrado na Tabela 3.2, o método LPC apresenta resultados promissores. Em comparação com o método baseado na Transformada *Wavelet*, o método proposto apresenta uma acurácia maior do que 98%. O método usado baseado na Transformada *Wavelet* estima o batimento cardíaco com uma acurácia máxima de 97,02% (patologia RSN). Portanto, mostra um resultado menor que o obtido pelo método baseado no LPC. Além disso, é importante destacar que a acurácia do método usando Transformada *Wavelet* varia no intervalo [42,47% a 97,02%], enquanto que o método proposto com o LPC tem o seu o intervalo de variação entre [98,18% a 100%], isso reforça a eficiência do método.

3.2 BOXPLOT

O *box and whisker plot*, ou simplesmente boxplot, é uma ferramenta gráfica utilizada em pesquisas científicas para resumir e analisar dados. Foi usado pela primeira vez em 1970 pelo matemático estadunidense John W. Tukey (1915–2000) (NETO et al., 2017). No boxplot é possível analisar; tendência central não-paramétrica (mediana), dispersão (quartis 25% e 75%), forma de distribuição ou simetria da amostra (valores pontuais mínimo e máximo), valores atípicos (outliers) e extremos. Numa descrição resumida de um boxplot tem-se:

- Primeiro quartil (Q1): representado pela linha limite inferior da caixa;
- Mediana ou segundo quartil (Q2): Representada pela linha dentro da caixa;
- Terceiro quartil (Q3): representado pela linha limite superior da caixa;
- Limite inferior (tamanho ou extremidade do valor mínimo do conjunto de dados);




Figura 3.4 Comparação das classes NSR e BIGEMINY com mesmo valor médio

- Limite superior (tamanho ou extremidade do valor máximo do conjunto de dados);

Neste trabalho foi utilizado o boxplot para explorar o potencial do método. Foram analisados dois trechos das classes NSR e Bigeminy, com ritmos cardíacos semelhantes do banco de dados(MIT), Figura 3.4. Na figura são apresentadas as estimativas da frequência cardíaca para o ritmo cardíaco gerado. Neste exemplo, o método demonstra ser capaz de capturar a variabilidade da frequência cardíaca, um parâmetro relevante para o diagnóstico de doenças cardíacas. Nos dois casos, o ritmo cardíaco médio está próximo em torno de 112,5 bpm, enquanto o desvio padrão é muito diferente.




Figura 3.5 Comparação das classes estudadas

Visando tornar a base de comparação mais consistente, foram utilizados os primeiros segmentos de cada arritmia/sinal das classes utilizadas nesse estudo, para verificar a

capacidade de detectar variabilidade através do método. Como mostrado na Figura 3.5, a variância pode ser explorada pelo método quando usado para extração de características dos sinais de ECG com objetivo de classificação automática. O código para detecção via LPC foi desenvolvido utilizando o programa ©MATLAB.

CAPÍTULO 4

CLASSIFICAÇÃO DE ARRITIMIAS CARDÍACAS UTILIZANDO ARQUITETURA CNN 1D/LPC

Diversos tipos de algoritmos foram desenvolvidos e outros ainda estão em desenvolvimento para serem utilizados para classificação de sinais de ECG. Isso ocorre devido a necessidade de melhorar os serviços de atendimento a pacientes que sofrem com algum tipo de disfunção cardíaca. As ondas de ECG apresentam uma infinidade de morfologias, mudando de pessoa para pessoa, da situação da pessoa que está fazendo o tratamento, de quanto tempo ela tem sido acompanhada, de ruído provindo do contato do eletrodo com a pele, contração muscular de ruído provindo da rede elétrica, de variação da impedância do eletrodo, modulação da amplitude do ECG de acordo com a respiração e ruído de instrumentos eletrocirúrgicos (OLIVEIRA, 2009).

O modelo desenvolvido aqui, segue uma adaptação do modelo desenvolvido por (XI-ANG et al., 2018). No trabalho desenvolvido por eles, foi utilizada uma estrutura hierárquica de dois níveis; Nível parte e Nível objeto. Nesses níveis são extraídas diferentes tipos de características. A CNN de nível objeto é usada para extrair recursos de granulometria grosseira, que são características morfológicas de uma pulsação inteira do sinal de ECG. Na CNN nível parte, são extraídos os recursos de granulometria mais refinados. Entretanto, todos os recursos extraídos pela CNN 1D de dois níveis, são reunidos e enviados para uma MLP afim de ser feita a classificação do tipo de patologia.

4.1 BASE DE DADOS DE TREINAMENTO

Para desenvolver esta pesquisa foram obtidos sinais de ECG do banco de dados MIT-BIH Arritmias (MOODY; MARK, 2001) e (PŁAWIAK, 2018). Foi utilizado também os sinais de ECG do banco de dados PHYSIONET para treinar e avaliar a robustez do modelo de classificação proposto, esse material pode ser encontrado no endereço www.physionet.org (GOLDBERGER et al., 2000).

4.1.1 MIT-BIH Database Arritmias

Características da base de dados:

1. Sinais de ECG de 45 pacientes.
2. Foram utilizados 5 conjuntos de dados do MIT-BIH: Ritmo sinusal normal, fibrilação atrial, batimento atrial prematuro, contração ventricular prematura e bloqueio dos batimentos.
3. Todos os sinais de ECG foram registrados com frequência de amostragem de 360Hz.

4. Para a análise, foram selecionados aleatoriamente 62 sinais de cada patologia em estudo, cada sinal com 10 segundos de duração, totalizando 3600 amostras. (PLAWIAK, 2018)

O banco de dados de arritmia do MIT-BIH contém 48 registros de ECG de 47 indivíduos com 30 minutos cada, amostrados em 360 Hz com resolução de 11 bits em uma faixa de 10 mV (PLAWIAK, 2018).

Por ser o banco de dados de sinais ECG com um grau de limpeza muito bom, além da alta qualidade dos dados, coletados em ambientes clínicos (ZAHID et al., 2021), esta base de dados tem sido amplamente utilizada como referência para a avaliação de algoritmos de detecção do pico R.

4.1.2 PHYSIONET Database

Neste trabalho, também foi usado o conjunto de dados do *PHYSIONET/Computing in Cardiology Challenge 2017* para treinar e avaliar o modelo. Neste conjunto de dados as gravações tiveram duração variando entre 9 e 61 segundos com frequência de amostragem de 300 Hz (KLEYKO; OSIPOV; WIKLUND, 2020).

4.2 DATA AUGMENTATION (DA)

Observa-se que quando usadas para trabalhar com séries temporais, as redes neurais profundas dependem muito da amplitude, consistência e tamanho dos conjuntos de dados usados no treinamento. Dessa forma, uma solução aplicável consiste em aumentar o número de dados usando técnicas de *Data Augmentation (DA)*, gerando assim novos dados sintéticos a partir dos dados originais aumentando dessa forma a quantidade de sinais para treinamento (TALAVERA et al., 2022), (FAWAZ et al., 2018).

Neste projeto, o aumento da base de dados (DA) de cada sinal escolhido para compor o conjunto de dados utilizados no treinamento e validação do modelo começou com a multiplicação dos dados originais por (-1) , para criar uma versão invertida dos sinais, tanto para o banco de dados do MIT-BIH quanto para o banco de dados do PHYSIONET. Cada classe do conjunto de dados a partir do MIT-BIH database possui 124 sinais. Após a anexação dos dados originais à versão invertida desses dados, foi gerado um conjunto de dados com 248 sinais por classe Figura 4.1. Em seguida, foi aplicado um deslocamento circular de tamanho k usando a função *circshift* (ZHANG; CAO; WU, 2020). O *circshift* consiste em um deslocamento circular do vetor baseado em um valor k predefinido.

O valor k foi definido de forma aleatória dentro do intervalo (1 a 600). Uma das vantagens dessa técnica é que dado o valor de K , o método pode gerar sinais de ECG usando deslocamento circular separadamente, o que é benéfico para a rede aprender novas informações.

Após a aplicação do *circshift* os sinais são concatenados, somando no total 496 sinais de ECG, isso equivale a *858.080* (oitocentos e cinquenta e oito mil e oitenta amostras) por classe, somando para os cinco conjuntos de dados *4.290.400* (quatro milhões duzentos e noventa mil e quatrocentas) amostras do banco de dados do *MIT-BIH*.

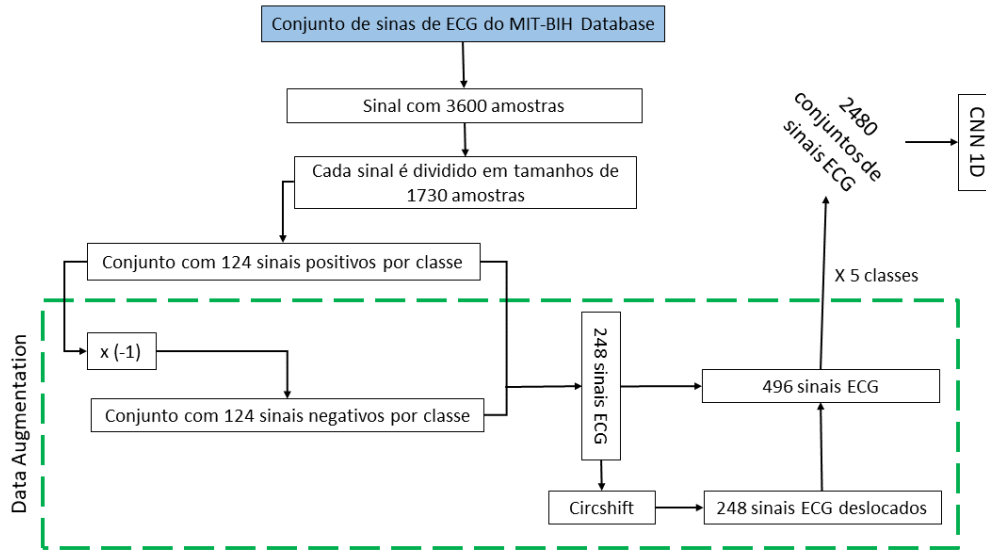


Figura 4.1 Data Augmentation nos dados do MIT-BIH Database

Em relação aos dados gerados pelo LPC, primeiro são gerados os batimentos cardíacos pelo algoritmo, em seguida os mesmos passam pelo mesmo processo que os dados brutos do banco de dados do *MIT-BIH*, Figura 4.2. É multiplicado por (-1) , para criar uma versão invertida dos batimentos, tanto para o banco de dados do MIT-BIH quanto para o banco de dados do *PHYSIONET*.

Cada classe do conjunto de dados a partir do MIT-BIH database possui 124 sinais que após a anexação aos dados invertidos, cria 248 conjuntos de 15 batimentos, em seguida é aplicado o *circshift* que realiza uma rotação dos dados. Esses dados rotacionados são então anexados novamente aos dados anteriores perfazendo um total de 496 conjuntos de 15 batimentos para cada classe, isso produz um banco de dados com 7.440 (sete mil quatrocentos e quarenta) batimentos cardíacos. Considerando que são cinco classes chega-se ao total de 37.200 (trinta e sete mil e duzentos) batimentos cardíacos.

No tratamento aplicado nos dados a partir do *PHYSIONET database* em que cada sinal tem o tamanho de 9000 (nove mil) amostras, foi o mesmo aplicados nos dados brutos de ECG e os dados gerados pelo LPC do banco de dados do MIT-BIH.

Foi criado um conjunto de dados com 1240 (um mil duzentos e quarenta) sinais por classe, chegando a 2.145.200 (dois milhões cento e quarenta e cinco mil e duzentas) amostras, somando para esse conjunto de dados 6.435.600 (seis milhões quatrocentas e trinta e cinco mil e seiscentas) amostras do banco de dados do *PHYSIONET* Figura 4.3.

Em relação aos dados gerados pelo algoritmo LPC, para os dados do banco de dados do *PHYSIONET* Figura 4.4, após a anexação dos dados originais com os dados invertidos pela multiplicação por (-1) , e a aplicação do *circshift* e anexação dos dados rotacionados com os dados anteriores, chega-se a um total de 1240 conjuntos com 15 batimentos por classe, isso produz um banco de dados com 18.600 (dezoito mil e seiscentos) batimentos

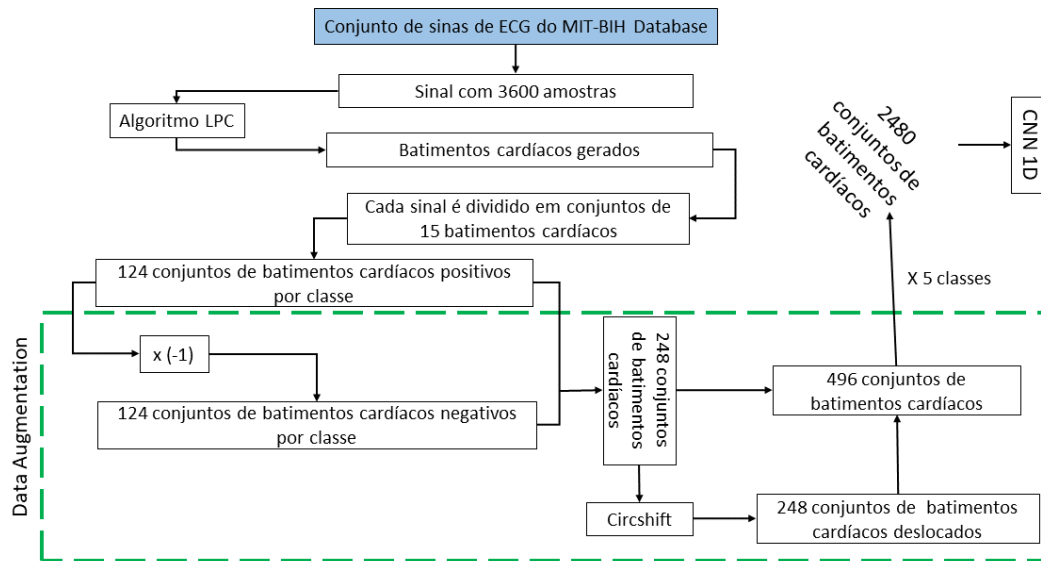


Figura 4.2 Data Augmentation nos dados do MIT-BIH Database

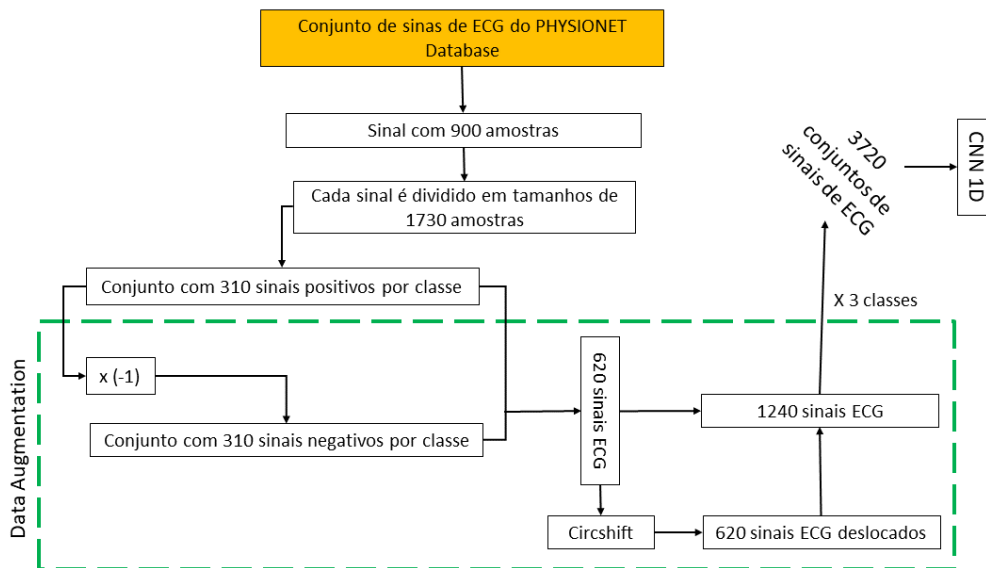


Figura 4.3 Data Augmentation nos dados do PHYGONET Database

cardíacos. Levando-se em conta que são três classes chega-se ao total 3720 conjuntos com 15 batimentos, gerando um total de 55.800 (cinquenta e cinco mil e oitocentos) batimentos cardíacos.

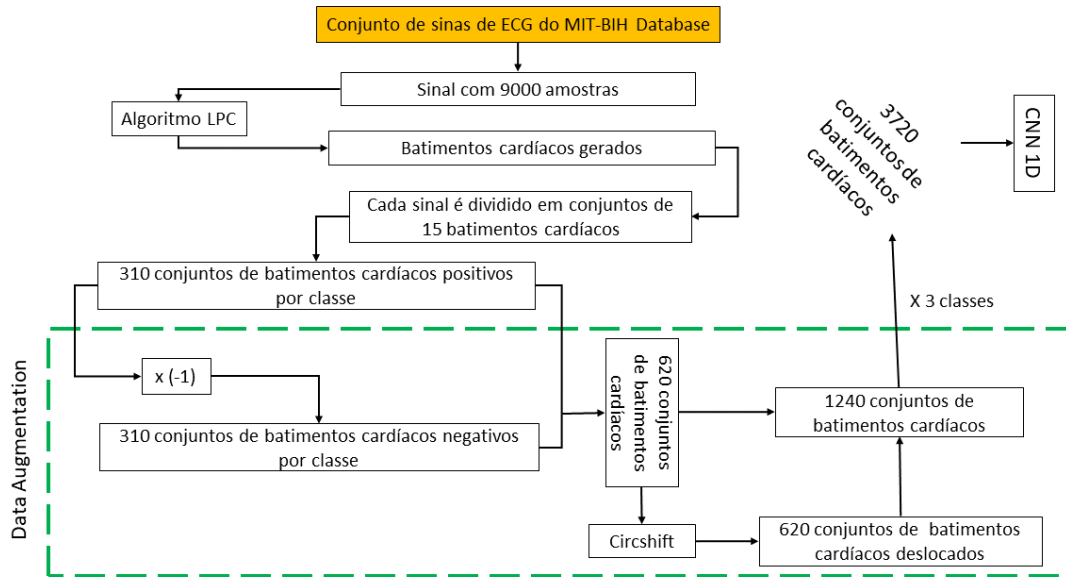


Figura 4.4 Data Augmentation nos dados do PHYSIONET Database

Após o tratamento realizado nos dados tanto do banco de dados do MIT-BIH e no PHYSIONET, essas informações são inseridas nas suas redes neurais convolucionais CNN 1D, respectivamente, para treinamento do modelo. Em seguida essas características são introduzidas no classificador que irão apresentar as probabilidades das classes classificadas, Figura 1.3.

Para ajudar na referência da técnica Data Augmentation (DA) a Figura 4.5, retirada de (TALAVERA et al., 2022), mostra os algoritmos básicos de DA que são técnicas aplicadas na manipulação de dados para gerar novas amostras de dados sintéticos usando amostras existentes e transformando as amostras originais sem perder informações importantes do sinal.

4.3 DETERMINAÇÃO DE HIPER-PARÂMETROS

Os hiper-parâmetros são variáveis fixas que podem ser alteradas diretamente nas arquiteturas até chegar as condições de desempenho desejadas para modelo. Um exemplo de um hiper-parâmetro é a quantidade de camadas totalmente conectadas.

Normalmente, os hiper-parâmetros são influenciados pela arquitetura e o tamanho da base de dados em estudo (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). Para cada par (arquitetura/base de dados) são escolhidos um conjunto de hiper-parâmetros. Isso ocorre porque a escolha desses hiper-parâmetros acontece de forma muito subjetiva. Os

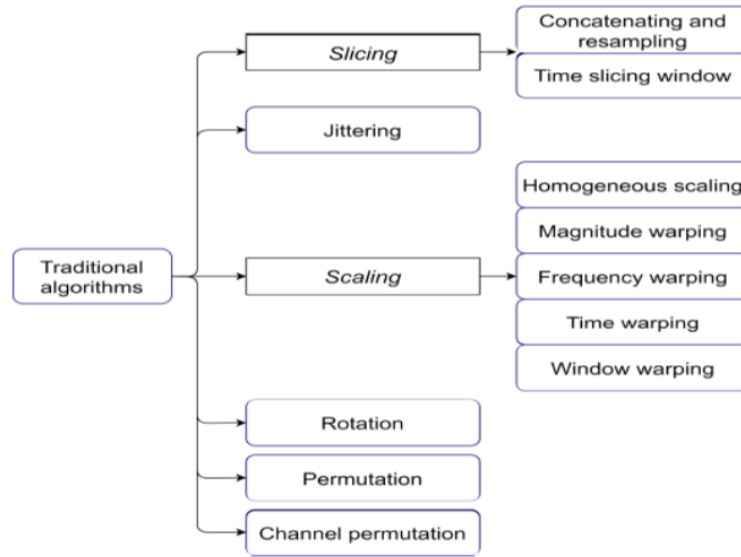


Figura 4.5 Data Augmentation

filtros para uma camada convolucional, por exemplo, pode variar em função da quantidade de sinais de um conjunto de dados durante a etapa de treinamento de forma diferente para cada arquitetura. Isso quer dizer que o tamanho e a quantidade de filtros (*kernels*), o *stride* (passo) e o *padding* (preenchimento) para a camada de convolução são hiperparâmetros que influenciam diretamente o treinamento do modelo.

O resumo da arquitetura básica do projeto está descrito na Tabela 4.1. Para chegar à arquitetura da rede final para o modelo proposto, foram realizados diversos testes com arquiteturas diferentes conforme descrito na Tabela 4.2.

4.4 RESULTADOS

Nesta seção são mostrados os resultados encontrados durante as etapas de treinamento e de validação do modelo proposto. Inicialmente, foi considerado apenas o modelo CNN 1D sem a introdução do LPC com o intuito de estabelecer parâmetros de comparação que justifiquem a sua utilização na melhoria da classificação das patologias em estudo nesse projeto. O treinamento foi realizado com as seguintes opções:

- Mini lotes de tamanho 32;
- Número de épocas igual a 60;
- Taxa inicial de treinamento igual a 0,0029;
- Frequência de validação igual a 16;
- Algoritmo de treinamento *Adam*.

Tabela 4.1 Arquitetura da Rede Neural Convolutacional 1D final

AA

Nome	Camadas	Input ECG	Input LPC
Input	Entrada	1	1
Conv1	Convolução	1	2
BatchNormalization	Normalização	1	2
LeakyRelu	Ativação	1	2
MaxPooling	MaxPooling	1	2
FullConnected	Totalmente conectadas	1	1
	Camadas totalmente conectadas		
	Camadas totalmente conectadas		
	softmax		
	Classificação		

Para medir o desempenho inicial do modelo proposto é utilizado as métricas: Precisão (Pr) e Sensibilidade (Sen). A precisão representa o número de previsões corretas em relação ao número total de previsões feitas pelo modelo para aquela classe, Equação 4.1. A sensibilidade é dada pela frequência com que o modelo classifica corretamente exemplos de uma determinada classe, Equação 4.2.

$$Pr = \frac{C}{V} \quad (4.1)$$

$$Sen = \frac{C}{H} \quad (4.2)$$

em que C é a quantidade de sinais classificados corretamente para cada classe, V é a soma dos valores que aparecem na coluna referente à classe classificada e H , é a soma dos valores que aparecem na linha referente à classe classificada. Para medir a acurácia geral do modelo foi utilizada a Equação 4.3.

$$Ac = \frac{D}{N} \quad (4.3)$$

sendo D o somatório dos valores que aparecem na diagonal principal, e N são todos os valores que aparecem na matriz.

Os sinais classificados corretamente para cada classe aparecem na diagonal principal da matriz de confusão. Para facilitar a compreensão, considere como exemplo na matriz da Figura 4.6, a Fibrilação Atrial (AFB), o valor 116 que aparece na célula (11) na diagonal principal refere-se à quantidade de sinais de ECG classificada corretamente como sendo Fibrilação Atrial. Foram classificados erroneamente 20 sinais como Batimento Atrial Prematuro (APB), 31 sinais como Ritmo Sinusal Normal (NSRI), 18 sinais como

Matriz de confusão de Validação

True Class	AFB	116	20	31	18	3	61.7%	38.3%
	APB	20	82	33	28	22	44.3%	55.7%
	NSR	30	30	121	20	1	59.9%	40.1%
	PVC	22	18	27	112	19	56.6%	43.4%
	RBB	6	30	11	14	158	72.1%	27.9%
		59.8%	45.6%	54.3%	58.3%	77.8%		
		40.2%	54.4%	45.7%	41.7%	22.2%		
		AFB	APB	NSR	PVC	RBB		
		Predicted Class						

Figura 4.6 Desempenho do modelo CNN 1D

sendo contração ventricular prematura (PVC) e 3 sinais foram marcados como sendo bloqueio do batimento do ramo direito (RBBB), resultando em uma sensibilidade (recall) de 61,70% para fibrilação atrial (AFB). Ou seja, $C = 116$ e $H = 116 + 20 + 31 + 18 + 3 = 188$. Logo podemos calcular a sensibilidade,

$$\text{Sen} = 116/188 = 0,6170 \times 100 = 61,70\%,$$

conforme pode ser visto na informação que aparece na lateral direita da matriz de confusão na faixa em azul. Esse mesmo procedimento é feito para o cálculo da precisão, cujas informações aparecem no quadro na parte inferior da matriz na faixa em azul. Ou seja, $C = 116$ e $V = 116 + 20 + 30 + 22 + 6 = 194$,

$$\text{Pr} = 116/194 = 0,5980 \times 100 = 59,80\%.$$

A matriz de confusão derivada do conjunto de dados de validação indica 59,8% e 61,7% para a Fibrilação atrial (AFB), 45,6% e 44,3% para o Batimento atrial prematuro (APB), 54,3% e 59,9% para o Ritmo sinusal normal (NSR), 58,3% e 56,6% para a Contração ventricular prematura (PVC) e 77,8% e 72,1% para o Bloqueio do Batimento do Ramo Direito (RBBB) para precisão e recall, respectivamente. A acurácia de validação do modelo utilizando apenas a rede CNN 1D é de 59,38%, conforme Figura 4.7.

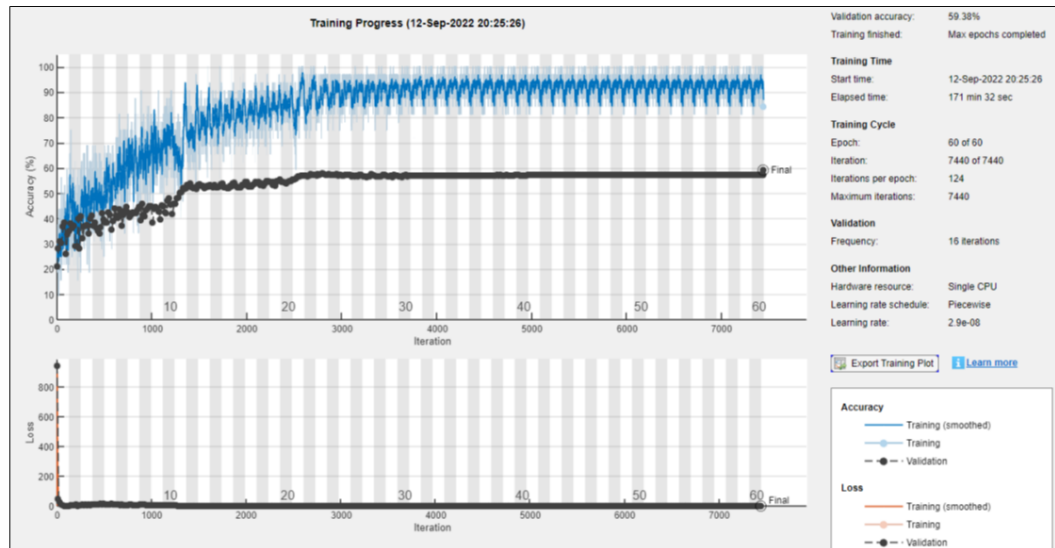


Figura 4.7 Desempenho do treinamento do modelo com dados do MIT-BIT sem o LPC

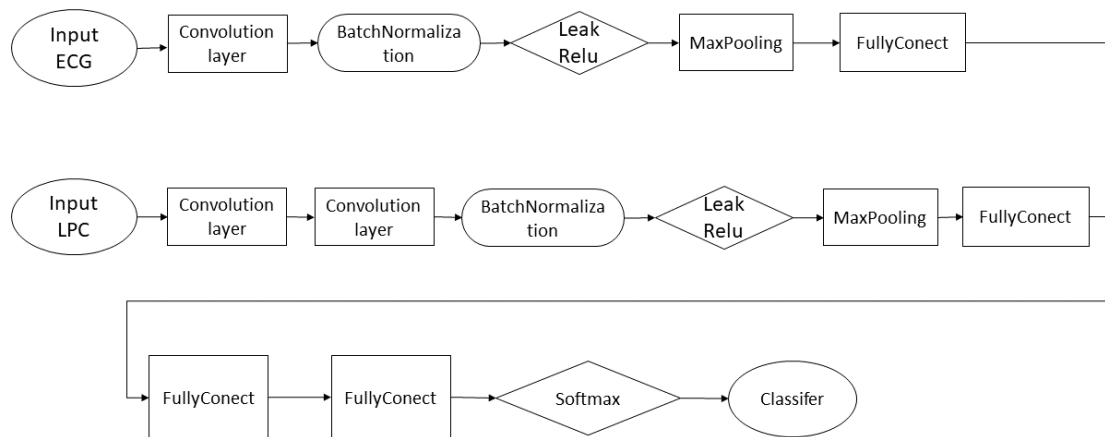
4.4.1 Modelo de Classificação CNN 1D/LPC

Nesta seção, os resultados do modelo de classificação combinando o algoritmo LPC e a rede neural convolucional CNN 1D são apresentados e discutidos. A Tabela 4.2 mostra comparações de resultados para duas configurações de arquiteturas dentre as que foram testadas para que fosse possível chegar a uma versão de arquitetura satisfatória. Considerando que existem muitas variáveis que podem alterar o desempenho do modelo durante o treinamento, os testes foram feitos mudando-se alguns parâmetros, com por exemplo, o número de camadas totalmente conectadas. Esses parâmetros foram sendo ajustados até chegar à arquitetura cujo desempenho mostrou-se satisfatório.

Uma ilustração do diagrama em blocos do modelo CNN 1D desenvolvido é mostrada na Figura 4.8. Nessa configuração cada sinal da entrada ECG (*Input ECG*) passa por 1 camada convolucional (*Convolution Layer*) que realiza a tarefa de extrair características do sinal, 1 camada para normalização em lotes (*Batch Normalization Layer*) do sinal afim de melhorar e diminuir o tempo de treinamento da rede, 1 camada de ativação (*Leak relu Layer*), 1 camada (*Max Pooling Layer*) e 1 camada totalmente conectada (*Fully Connected*) de forma ordenada. Nesta parte da arquitetura, os dados são tratados para extração de características morfológicas de cada sinal. Na outra parte da arquitetura (*Input LPC*), são inseridos os batimentos cardíacos estimados pelo algoritmo LPC. O bloco convolucional *Input LPC* é composto por duas camadas de convolução e uma camada totalmente conectada, além de duas camadas de ativação *Leak Relu*, duas camadas *Batch*

Tabela 4.2 Comparação das arquiteturas testadas

Nome	FullConnected	Acc(%)	Precisão(%)	Recall(%)
Arquit 1	(LPC) 200 Neurônios	68,18	67,40	67,96
	(Sinais brutos) 200 Neurônios			
Arquit 2	(LPC) 256 Neurônios	72,72	72,76	72,70
	(Sinais brutos) 256 Neurônios			
Arquit final	(LPC) 180 Neurônios	93,35	93,12	93,08
	(Sinais brutos) 128 Neurônios			

**Figura 4.8** Modelo da rede neural convolucional 1D

Normalization Layer e duas camadas *Maxpooling*. Nesse bloco, o algoritmo LPC calcula a diferença entre os intervalos RR para estimar os batimentos cardíacos de cada classe que em seguida são introduzidos na camada de convolução.

No final da rede encontram-se duas camadas totalmente conectadas com 35 e 5 neurônios respectivamente, seguidas de uma camada *Softmax Layer* e a camada *Classification Layer*.

Para cada uma das camadas convolucionais 1D foram utilizados 32 e 16 filtros para extrair mais recursos do sinal de entrada. A quantidade de filtros varia em função da complexidade de cada pesquisa. Entretanto, o aumento da quantidade de filtros traz um aumento do custo computacional e demanda tempo para o treinamento dos modelos, o que em alguns casos não justifica. Cada filtro tem um tamanho de 3x1 e passo 1.

Nas Tabelas 4.3 e 4.4 são listadas as cardiopatias analisadas neste estudo, o número de sinais coletados para cada conjunto de dados e a divisão dos sinais em conjuntos de treinamento e validação.

Tabela 4.3 Distribuição dos sinais cardíacos para treinamento e validação - MIT

Percentual		80 %	20 %
Classes	Número de sinais	Treinamento	Validação
Fibrilação Atrial	62	392	104
Batimento atrial prematuro	62	398	98
Ritmo Sinusal Norma	62	396	100
Contração Ventricular Prematura	62	399	97
RBBB	62	399	97

No modelo proposto é utilizado um conjunto de dados com o mesmo número de sinais cardíacos (2480 sinais), do total de classes estudadas (AFB, APB, NSR, PVC e RBBB) escolhido aleatoriamente do conjunto de dados de arritmias do MIT-BIH, tanto para o algoritmo LPC, quanto para sinal de ECG. Entretanto, antes de passar pelas redes neurais, o conjunto de dados é dividido em conjunto de treinamento e validação, Tabela 4.3.

Foi utilizado também um conjunto de dados com o mesmo número de sinais cardíacos (3720 sinais), do total de classes estudadas (Normal, Arritmia e outros) escolhido aleatoriamente do conjunto de dados de arritmias do *PHYSIONET*, tanto para o algoritmo LPC, quanto para o sinal bruto de ECG. Entretanto, antes de passar pelas redes neurais, o conjunto de dados é dividido em conjunto de treinamento e validação, Tabela 4.4.


O equilíbrio entre os dados é um aspecto muito importante, ou seja, o número de sinais correspondentes para cada fisiologia cardíaca não deve ser significativamente diferente entre o número de sinais de ECG para cada classe. Isso pode causar uma interferência e comprometer a eficiência de reconhecimento de distúrbios cardíacos. Dessa forma, utilizou-se um número proporcional de sinais de ECG para cada classe.

O sistema de classificação demonstra ter uma eficiência satisfatória para os sinais treinados e validados. A acurácia de validação do sistema é de 93,35%, Figura 4.9, e

Tabela 4.4 Distribuição dos sinais cardíacos para treinamento e validação - PHYSIONET

Percentual		80 %	20 %
Classes	Número de sinais	Treinamento	Validação
Normal	62	996	244
Arritmia	62	992	248
Outros	62	985	251

a acurácia do conjunto de validação também foi de 93,35%, Figura 4.10, calculada a partir da equação 4.3 para os dados do MIT. A evolução do treinamento realiza 3968 iterações e termina após 64 épocas sendo 62 iterações por época. Podemos constatar que a combinação do algoritmo LPC com a rede neural convolucional (CNN) 1D permite que a rede produza uma boa precisão diagnóstica.

**Figura 4.9** Desempenho de validação de treinamento do modelo CNN/LPC.

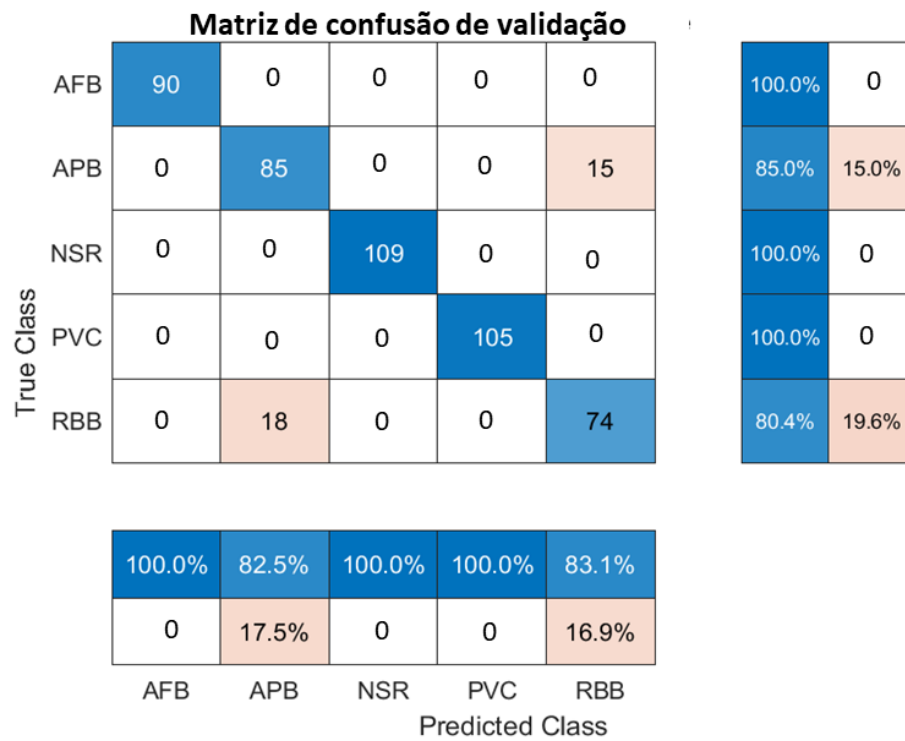
Na Tabela 4.5 são mostrados os resultados experimentais encontrados com o modelo completo (LPC/CNN 1D), utilizando os dados do MIT-BIH, em que são mostradas a acurácia geral do modelo, a precisão e o *recall* para cada uma das classes, os resultados encontrados são bastante satisfatórios.

Na Tabela 4.6, são apresentados os resultados obtidos na matriz de confusão, Figura 4.10 para o modelo CNN/LPC do conjunto de dados do MIT-BIH.

Na Tabela 4.7 é apresentada uma comparação entre os resultados obtidos para os modelos CNN e CNN/LPC dos treinamentos realizados com os dados do MIT-BIH. Os

Tabela 4.5 Análise de desempenho do modelo LPC-CNN

Classes	Acurácia(%)	Precisão(%)	Recall(%)
AFIB	93,35	100	100
APB	93,35	83,50	85,00
NSR	93,35	100	100
PVC	93,35	100	100
RBBBB	93,35	83,10	80,40

**Figura 4.10** Desempenho de validação do modelo com dados do MIT-BIH**Tabela 4.6** Resultados da matriz de confusão derivada do conjunto de dados de validação LPC-CNN 1D

Métrica	AFB(%)	APB(%)	NSR(%)	PVC(%)	RBBBB(%)
Precisão	100	82,5	100	100	83,1
Recall	100	85	100	100	80,4

resultados do desempenho do modelo mostra uma melhora significativa de até 34,16% para a sensibilidade.

Tabela 4.7 Análise de desempenho do modelo CNN 1D e do modelo completo LPC-CNN 1D

Métrica	CNN 1D (%)	LPC-CNN 1D (%)	Melhora(%)
Acurácia média	59,38	93,35	33,97
Precisão média	59,16	93,12	33,96
Recall média	58,92	93,08	34,16

Considerando a base *Physionet Challenge 2017 database*, foram obtidos os resultados mostrados nas Figuras 4.11 e 4.12. Na Figura 4.11 é mostrado o desempenho do treinamento feito com os dados da base *Physionet*, alcançando uma acurácia de validação de 99,87%.

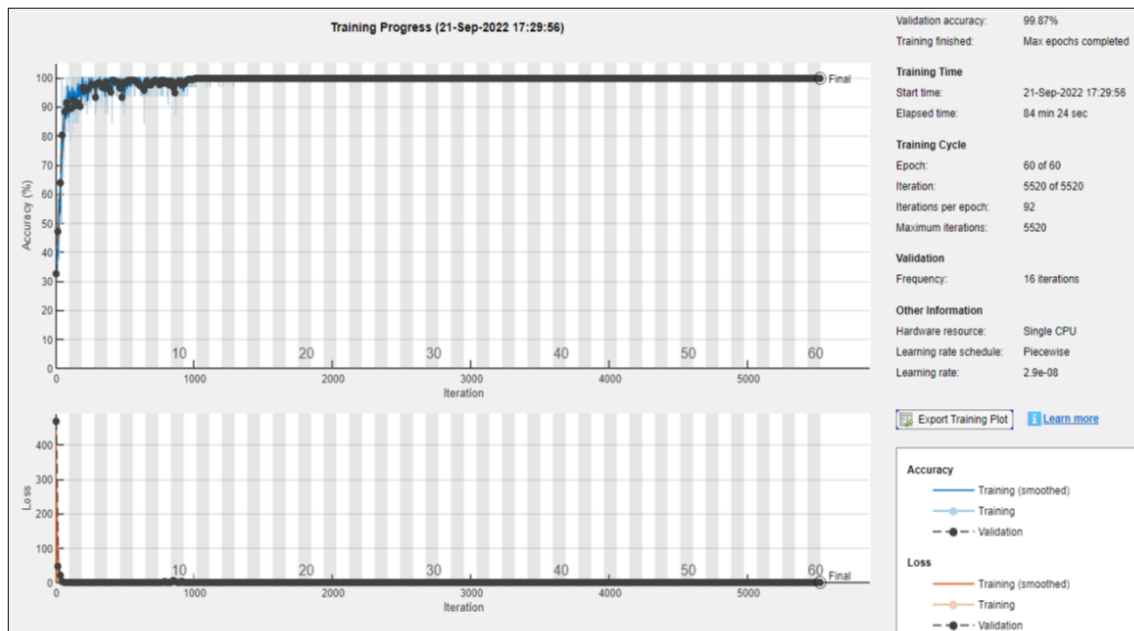


Figura 4.11 Desempenho de validação do treinamento do modelo CNN/LPC usando a base de dados da PHYSIONET.

Os resultados experimentais mostram a eficácia da técnica do LPC em melhorar a precisão da classificação do modelo para os dados do *Physionet* que trazem resultados melhores do que os encontrados com o banco de dado MIT-BIH.

Em comparação com o estado da arte, a Tabela 4.8 faz uma comparação dos resultados encontrados com o modelo proposto em relação a outros trabalhos realizados. Os

Matriz de Confusão de Validação

True Class	ARRITMIA	236	0	0	100.0%	0
	NORMAL	0	242	0	100.0%	0
	OUTROS	1	0	264	99.6%	0.4%
		99.6%	100.0%	100.0%		
		0.4%	0	0		
		ARRITMIA	NORMAL	OUTROS		
		Predicted Class				

Figura 4.12 Desempenho do modelo CNN 1D/LPC com dados da base PHYSIONET

resultados mostram que o modelo tem um bom desempenho para classificação de ECG com boa precisão geral, quando se utiliza os dados do *Physionet*. Para os resultados encontrados com os dados do *MIT-BIH*, utilizando os mesmos parâmetros, trazem resultados que são potencialmente eficazes para auxiliar profissionais de saúde na realização de diagnósticos rápido e seguro de arritmias.

Tabela 4.8 Comparação entre o modelo CNN/LPC e outras propostas.

Referência	B. Dados	Classes	Classificador	Acc	Precisão	Recall	Conv	FullConnect
Houssein 2021	MIT-BIH	4	CNN-MPA	99,32	98,68	98,61	4	2
Acharya 2017	PTB		CNN-WT	93,53	98,03	93,71	4	3
Plawiak 2017	MIT-BIH	17	SVM,KNN PNN,RBFNN	98,85		90,20		4
Kiranyaz 2015	MIT-BIH	17	CNN	99,00	93,90		3	2
Li 2020	PHYSIONET	2	CNN	86,8		87	3	1
Nurmaini 2019	MIT-BIH	10	DNNs	99,73	93,60	91,20	6	3
Romdhane 2020	MIT-BIH	5	CNN Focal Loss	98,41	98,37	98,41	6	2
ZAHID 2021	MIT-BIH		CNN 1D		99,82	99,85		
Modelo Proposto	MIT-BIH PHYSIONET	5	CNN 1D/LPC	93,35 99,87	93,12 99,87	93,08 99,87	3	4

CONCLUSÃO

Nesta pesquisa, um novo método de medição da frequência cardíaca foi proposta utilizando o método Coeficientes de Predição Linear (LPC). O algoritmo LPC foi projetado para estimar os batimentos cardíacos de nove tipos de patologias cardíacas a partir de um limiar de decisão. A proposta foi testada sobre sinais de ECG do banco de dados de arritmia do MIT-BIH e os resultados obtidos foram bastantes consistentes e promissores.

Ainda durante este estudo, foi desenvolvido e testado um modelo de classificação de arritmias cardíacas, combinando uma rede neural convolucional 1D com o algoritmo LPC. O modelo utilizou os dados do algoritmo LPC para extrair as características dinâmicas dos sinais de ECG na *InputLPC* (entrada LPC), enquanto na *InputECG* (entrada ECG) o modelo extrai as características morfológicas dos sinais. Em seguida, essas informações são concatenadas e inseridas no classificador.

Nos treinamentos realizados no modelo com os dados MIT-BIH apenas com a rede neural, sem a combinação com o algoritmo LPC, o modelo obteve uma performance de 59,38% de acurácia, sendo 59,16% na precisão e 58,92% na sensibilidade (*Recall*).

Nos treinamentos realizados com o modelo completo (a CNN 1D - LPC) houve uma melhora significativa no desempenho do modelo, obtendo 93,35% de acurácia, sendo 93,12% na precisão e 93,08% na sensibilidade (*Recall*). Esses resultados mostraram uma melhoria no desempenho quando combinou uma rede neural convolucional (CNN) 1D com o algoritmo LPC.

Os resultados encontrados nos treinamento realizados com os dados do PHYSIONET o modelo obteve uma melhora expressiva de 99,87% de acurácia, sendo 99,87% na precisão e 99,87% na sensibilidade (*Recall*). O modelo completo nessa pesquisa, utilizou uma CNN com 3 camadas convolucionais, treinado com dados do MIT-BIH e Physionet Challenge 2017 disponíveis para uso público.

Considerando que modelos desenvolvidos com CNN 1D conseguem alcançar grandes velocidades em tempo real em um computador padrão, que lhe permite uso, especialmente em dispositivos móveis de baixa potência, como monitores Holter, podendo ser usado como um detector de pico R.

Pesquisas futuras pretendem explorar outras técnicas de aprendizado profundo, tais como, Aprendizagem Por Reforço (Reinforcement Learning), Redes Adversárias Generativas (GANs – Generative Adversarial Networks). Explorar técnicas robustas de quantização e compressão de modelos. Melhorar o desempenho do modelo, aumentar a velocidade de treinamento e reduzir a complexidade computacional.

REFERÊNCIAS BIBLIOGRÁFICAS

- ACHARYA, U. R. et al. Application of deep convolutional neural network for automated detection of myocardial infarction using ecg signals. *Information Sciences*, Elsevier, v. 415, p. 190–198, 2017.
- ALASKAR, H. Convolutional neural network application in biomedical signals. *J Comput Sci Inform Tech*, v. 6, n. 2, p. 45–59, 2018.
- ARAÚJO, J. M. et al. Melhoria da performance em reconciliação de dados pela eliminação de outliers com pré-filtro por predição linear. *VIII Semetro. João Pessoa, PB, Brazil, June 17 – 19*, 2009.
- ARUN, A. Ecg beat calculation 2020 (www.mathworks.com/matlabcentral/fileexchange/24628-ecg-beat-calculation). *MATLAB Central File Exchange*. Retrieved August 12, 2020, 2020.
- ATAL, D. K.; SINGH, M. Arrhythmia classification with ecg signals based on the optimization-enabled deep convolutional neural network. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 196, p. 105607, 2020.
- BERALDO, O. A. *Processamento Digital do Sinal de Eletrocardiograma para Aplicação em Experimentos de Fisiologia Cardíaca*. Tese (Doutorado) — Universidade de São Paulo, 2017.
- BHYRI, C.; HAMDE, S.; WAGHMARE, L. Ecg feature extraction and disease diagnosis. *Journal of medical engineering & technology*, Taylor & Francis, v. 35, n. 6-7, p. 354–361, 2011.
- CAMPITELLI M. A., . *Compressão de sinais ECG utilizando DWT com quantização não-linear e por sub-bandas*. Dissertação (Mestrado) — Dissertação de Mestrado, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 88 p, 2015.
- CHEN, Y.; WEI, S.; ZHANG, Y. Classification of heart sounds based on the combination of the modified frequency wavelet transform and convolutional neural network. *Medical & Biological Engineering & Computing*, Springer, v. 58, n. 9, p. 2039–2047, 2020.
- DAS, T. K.; CHOWDHARY, C. L.; GAO, X. Chest x-ray investigation: a convolutional neural network approach. In: TRANS TECH PUBL. *Journal of Biomimetics, Biomaterials and Biomedical Engineering*. [S.l.], 2020. v. 45, p. 57–70.

- DUNNMON, J. A. et al. Assessment of convolutional neural networks for automated classification of chest radiographs. *Radiology*, Radiological Society of North America, v. 290, n. 2, p. 537, 2019.
- FAWAZ, H. I. et al. Data augmentation using synthetic data for time series classification with deep residual networks. *arXiv preprint arXiv:1808.02455*, 2018.
- GACEK, A.; PEDRYCZ, W. *ECG signal processing, classification and interpretation: a comprehensive framework of computational intelligence*. [S.l.]: Springer Science & Business Media, 2011.
- GOES, J. V. S. et al. Avanços recentes em aprendizagem de máquina usando fonocardiogramas na detecção de cardiopatias. *Journal of Health Informatics*, v. 12, 2020.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. *circulation*, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. (<http://www.deeplearningbook.org>).
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. [S.l.]: Bookman Editora, 2007.
- HEATON, J. *Ian goodfellow, yoshua bengio, and aaron courville: Deep learning*. [S.l.]: Springer, 2018.
- HENNING, T. A. Validação do método lpc para vocoder musical e análise dos efeitos de quantização com ponto fixo. *Universidade Federal do Rio Grande do Sul, Escola de Engenharia - Departamento de Engenharia Elétrica*, p. 79, 2017.
- HIGUTI, R. T.; KITANO, C. Sinais e sistemas. *ELE*, 2003.
- HIGUTI, R. T.; KITANO, C. Sinais e sistemas, princípios de comunicações. *Faculdade de Engenharia de Ilha Solteira - Departamento de Engenharia Elétrica*, 2003.
- HUANG, Y.; SONG, I. A better online method of heart diagnosis. In: *Proceedings of the 3rd International Conference on Biomedical Signal and Image Processing*. [S.l.: s.n.], 2018. p. 81–86.
- IZCI, E. et al. Cardiac arrhythmia detection from 2d ecg images by using deep learning technique. In: *IEEE. 2019 Medical Technologies Congress (TIPTEKNO)*. [S.l.], 2019. p. 1–4.
- KIRANYAZ, S. et al. 1d convolutional neural networks and applications: A survey. *arXiv preprint arXiv:1905.03554*, 2019.
- KIRANYAZ, S.; INCE, T.; GABBOUJ, M. Real-time patient-specific ecg classification by 1-d convolutional neural networks. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 63, n. 3, p. 664–675, 2015.

- KLEYKO, D.; OSIPOV, E.; WIKLUND, U. A comprehensive study of complexity and performance of automatic detection of atrial fibrillation: Classification of long ecg recordings based on the physionet computing in cardiology challenge 2017. *Biomedical Physics & Engineering Express*, IOP Publishing, v. 6, n. 2, p. 025010, 2020.
- KOVÁCS, Z. L. *Redes Neurais Artificiais*. [S.l.]: Editora Livraria da Física, 2002.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105.
- LEÓN, A. A. S.; ALVAREZ, J. R. N. 1d convolutional neural network for detecting ventricular heartbeats. *IEEE Latin America Transactions*, IEEE, v. 17, n. 12, p. 1970–1977, 2019.
- LI, D. et al. Classification of ecg signals based on 1d convolution neural network. In: IEEE. *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)*. [S.l.], 2017. p. 1–6.
- LI, F. et al. Classification of heart sounds using convolutional neural network. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 11, p. 3956, 2020.
- LIMA, J. S.; SILVA, F. G. S.; ARAÚJO, J. M. An lpc-basead approach to heart rhythm estimation. *XXVII Congresso Brasileiro de Engenharia Biomédica (CBEB 20200)*, 2020.
- LUZ, E. J. d. S. Classificação automática de arritmias: um novo método usando classificação hierárquica. Programa de Pós-Graduação em Ciência da Computação. Departamento de Ciência, 2012.
- MADAN, P. et al. Hybrid deep learning based approach for ecg heartbeat arrhythmia classification. 2021.
- MAKHOUL, J. Linear prediction: A tutorial review. *Proceedings of the IEEE, Abril 1975*, 561 - 580, 1975.
- MAKHOUL, J. Linear prediction: A tutorial review. *Proceedings of the IEEE*, IEEE, v. 63, n. 4, p. 561–580, 1975.
- MARVI, H.; ESMAILEYAN, Z.; HARIMI, A. Estimation of lpc coefficients using evolutionary algorithms. *Journal of AI and Data mining*, Shahrood University of Technology, v. 1, n. 2, p. 111–118, 2013.
- MONTES, G. C.; LATTARI, L. G.; COELHO, A. M. Redes neurais convolucionais otimizadas para a detecção de supernovas. In: SBC. *Anais do XV Brazilian e-Science Workshop*. [S.l.], 2021. p. 1–8.
- MOODY, G. B.; MARK, R. G. The impact of the mit-bih arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, IEEE, v. 20, n. 3, p. 45–50, 2001.

NETO, J. V. et al. Boxplot: um recurso gráfico para a análise e interpretação de dados quantitativos. *Revista Odontológica do Brasil Central*, v. 26, n. 76, 2017.

NOMAN, F. et al. Short-segment heart sound classification using an ensemble of deep convolutional neural networks. In: IEEE. *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.], 2019. p. 1318–1322.

NURMAINI, S. et al. An automated ecg beat classification system using deep neural networks with an unsupervised feature extraction technique. *Applied sciences*, Multidisciplinary Digital Publishing Institute, v. 9, n. 14, p. 2921, 2019.

OKIDA, C. M.; MARAR, J. F.; QUEIROZ, R. A. B. de. Investigação do método de predição linear para extração de características de gêneros musicais.

OLIVEIRA, A. T.

Detecção do complexo QRS em sinais cardíacos utilizando FPGA. — Dissertação (Mestrado) — Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, 2009., 2009.

OLIVEIRA, A. T.

iClassificação automática de arritmias cardíacas usando uma combinação de redes neurais / Alexandre Tomazati Oliveira — Dissertação (Mestrado) - Universidade Estadual de Campinas, 1978-OL4c Ol – Campinas, SP : [s.n.], 2019, 2019.

OLIVEIRA, G. M. M. d. et al. Estatística cardiovascular–brasil 2020. *Arquivos brasileiros de Cardiologia*, SciELO Brasil, v. 115, p. 308–439, 2020.

OLIVEIRA, G. M. M. d. et al. Estatística cardiovascular – brasil 2020. *Sociedade Brasileira de Cardiologia (SBC)*, p. 132, 2020.

OLIVEIRA, G. M. M. d. et al. Estatística cardiovascular–brasil 2021. *Arquivos Brasileiros de Cardiologia*, SciELO Brasil, v. 118, p. 115–373, 2022.

OLIVEIRA, P. F.; CÂMARA, C. E. Análise de desempenho de um algoritmo desenvolvido para solução de deep learning utilizando redes neurais convolucionais para análise de contraste de imagens. *Revista de Ubiquidade*, v. 2, n. 1, p. 84–105, 2019.

O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.

PICON, A. et al. Mixed convolutional and long short-term memory network for the detection of lethal ventricular arrhythmia. *PloS one*, Public Library of Science San Francisco, CA USA, v. 14, n. 5, p. e0216756, 2019.

PLAWIAK, P. Novel methodology of cardiac health recognition based on ecg signals and evolutionary-neural system. *Expert Systems with Applications*, Elsevier, v. 92, p. 334–349, 2018.

- PRÉCOMA, D. B. et al. Atualização da diretriz de prevenção cardiovascular da sociedade brasileira de cardiologia-2019. *Arquivos Brasileiros de Cardiologia*, SciELO Brasil, v. 113, n. 4, p. 787–891, 2019.
- RAZA, A. et al. Heartbeat sound signal classification using deep learning. *Sensors*, MDPI, v. 19, n. 21, p. 4819, 2019.
- ROCHA, R. M. et al. *Manual de Prevenção Cardiovascular*. [S.l.]: Planmark editora Ltda, 2017.
- RODRIGUES, L. C. F. et al. Detecção e classificação de arritmias em eletrocardiogramas usando transformadas wavelets, máquinas de vetores de suporte e rede bayesiana. Universidade Presbiteriana Mackenzie, 2012.
- ROMDHANE, T. et al. Electrocardiogram heartbeat classification based on a deep convolutional neural network and focal loss. *Computers in Biology and Medicine*, v. 123, p. 103866, 07 2020.
- SELIG, F. A. *Panorama e Estratégias no Diagnóstico e Tratamento de Cardiopatias Congênitas no Brasil*. [S.l.]: SciELO Brasil, 2021. 1176–1177 p.
- SHAKER, A. M. et al. Heartbeat classification using 1d convolutional neural networks. In: SPRINGER. *International Conference on Advanced Intelligent Systems and Informatics*. [S.l.], 2019. p. 502–511.
- SINGH, S. A.; MEITEI, T. G.; MAJUMDER, S. Short ppg classification based on deep learning. In: *Deep Learning Techniques for Biomedical and Health Informatics*. [S.l.]: Elsevier, 2020. p. 141–164.
- SINGHAL, S.; KUMAR, H.; PASSRICHA, V. Prediction of heart disease using cnn.
- SUTERIO, V. *Detecção de Cardiopatias por Eletrocardiograma utilizando Redes Neurais Artificiais*. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2017.
- TALAVERA, E. et al. Data augmentation techniques in time series domain: A survey and taxonomy. *arXiv preprint arXiv:2206.13508*, 2022.
- UNNIKRISHNAN, B. et al. Semi-supervised and unsupervised methods for heart sounds classification in restricted data environments. *arXiv preprint arXiv:2006.02610*, 2020.
- WOLK, K.; WOLK, A. Early and remote detection of possible heartbeat problems with convolutional neural networks and multipart interactive training. *IEEE Access*, IEEE, v. 7, p. 145921–145927, 2019.
- XIANG, Y. et al. Ecg-based heartbeat classification using two-level convolutional neural network and rr interval difference. *IEICE Transactions on Information and Systems*, E101.D, n. 4, p. 1189–1198, 2018.

XU, B. et al. Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*, 2015.

ZAHID, M. U. et al. Robust r-peak detection in low-quality holter ecgs using 1d convolutional neural network. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 69, n. 1, p. 119–128, 2021.

ZHANG, K.; CAO, Z.; WU, J. Circular shift: an effective data augmentation method for convolutional neural network on image classification. In: IEEE. *2020 IEEE International Conference on Image Processing (ICIP)*. [S.l.], 2020. p. 1676–1680.