

Detecção de Insuficiência Cardíaca Congestiva em Sinais de ECG Utilizando Redes Neurais Profundas LSTM e CNN

Luiz Otavio Ribeiro

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para
obtenção do Grau de Mestre em Engenharia Eletrotécnica e de Computadores.

Trabalho orientado por:

Prof. João Paulo Teixeira

Prof. André Eugenio Lazzaretti

Bragança

Outubro, 2024

Detecção de Insuficiência Cardíaca Congestiva em Sinais de ECG Utilizando Redes Neurais Profundas LSTM e CNN

Luiz Otavio Ribeiro

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para
obtenção do Grau de Mestre em Engenharia Eletrotécnica e de Computadores.

Trabalho orientado por:

Prof. João Paulo Teixeira

Prof. André Eugenio Lazzaretti

Bragança

Outubro, 2024

Dedicatória

Dedico a todos os cidadãos brasileiros que sonharam, construíram e colaboram na manutenção e aperfeiçoamento do Sistema Único de Saúde (SUS). Através das ações do SUS, a vida do meu pai foi resgatada da insuficiência cardíaca congestiva por meio de um transplante de coração. Dedico este trabalho também a minha falecida avó, Maria Tereza, que sempre foi uma grande entusiasta dos meus estudos.

Agradecimentos

Agradeço a todos os membros da minha família por incentivar meus estudos e, especialmente, pelo suporte incondicional. Ao meu amigo Gustavo Kumasawa que me inspirou a alcançar objetivos ambiciosos e a minha namorada Tereza Pluskalová que tornou os meus dias em Portugal muito mais coloridos. Agradeço também as instituições IPB e UTFPR, que me proporcionaram esta oportunidade do programa de dupla diplomação, e aos camaradas do café Manifesto que sempre forneceram a energia que precisava durante os estudos. Por fim, agradeço a arte produzida por Paul David Hewson, David Howell Evans, Adam Charles Clayton e Lawrence Joseph Mullen Jr que sempre me serviu de guia e inspiração para realizar meus sonhos.

Resumo

A Insuficiência Cardíaca Congestiva (ICC) é uma condição crônica em que o coração não bombeia sangue eficientemente. Esta patologia causa fadiga, dispneia, edemas, náuseas e problemas de memória, afetando a qualidade de vida dos pacientes. As causas incluem doenças das artérias coronárias, cardiomiopatia, hipertensão arterial e miocardites. O diagnóstico é realizado com base no histórico do paciente, exames físicos, ecocardiograma, eletrocardiograma e outros métodos. Com a finalidade de aprimorar as ferramentas de diagnóstico, o presente trabalho propõe um modelo de inteligência artificial baseado em *deep learning* para classificar sinais de ECG patológicos positivos para ICC. Os modelos selecionados foram LSTM e CNN. O treinamento foi realizado com um *dataset* personalizado criado a partir das bases de dados públicas BIDMC Congestive Heart Failure e PTB Diagnostic ECG da Physionet. Foram selecionados dados de ECG de 28 pessoas, entre 22 e 71 anos, das quais 14 possuem ICC severa (classe NYHA 3 e 4) e 14 amostras de controle, que não apresentam anormalidades no ECG. A arquitetura da base de dados foi projetada para que o *input* das redes neurais fossem sinais de ECG puros, sem qualquer tipo de filtragem ou extração de características. Os resultados obtidos demonstraram uma precisão de 98,21% para o modelo CNN e 92,26% para o modelo LSTM.

Palavras-chave: Inteligência Artificial, Insuficiência Cardíaca Congestiva, Deep Learning, Eletrocardiograma (ECG), .

Abstract

Congestive Heart Failure (CHF) is a chronic condition in which the heart does not pump blood efficiently. This pathology causes fatigue, dyspnea, edema, nausea, and memory problems, affecting patients' quality of life. The causes include coronary artery disease, cardiomyopathy, arterial hypertension, and myocarditis. The diagnosis is based on the patient's medical history, physical exams, echocardiogram, electrocardiogram, and other methods. Aiming to improve diagnostic tools, this study proposes an artificial intelligence model based on deep learning to classify pathological ECG signals indicative of CHF. The selected models were LSTM and CNN. The training was conducted with a personalized dataset created from the public databases BIDMC Congestive Heart Failure and PTB Diagnostic ECG from Physionet. ECG data from 28 individuals, aged 22 to 71, were selected, including 14 with severe CHF (NYHA class 3 and 4) and 14 control samples without ECG abnormalities. The database architecture was designed so that the input to the neural networks was raw ECG signals, without any filtering or feature extraction. The results showed an accuracy of 98.21% for the CNN model and 92.26% for the LSTM model.

Keywords: Artificial Intelligence, Congestive Heart Failure, Deep Learning, Electrocardiogram (ECG)

Conteúdo

1	Introdução	1
1.1	Insuficiência Cardíaca Congestiva	2
1.1.1	Causas	3
1.1.2	Sintomas	3
1.1.3	Tratamento	4
1.2	Eletrocardiograma	5
1.2.1	ECG característico da ICC	8
1.3	Justificativa	9
1.4	Objetivos	10
1.5	Estrutura do Documento	10
2	Estado da Arte	13
2.1	Métodos Genéricos para Extração de Características	13
2.2	Métodos de Aprendizado de Máquina	14
2.2.1	Algoritmos de Aprendizado Supervisionado	14
2.2.2	Redes Neurais	15
2.3	Detecção de Patologias em Biossinais Utilizando Redes Neurais	16
2.4	Detecção de ICC em Sinais de ECG Utilizando <i>Deep Learning</i>	17
3	Materiais e Métodos	21
3.1	Base de Dados	21
3.1.1	BIDMC Congestive Heart Failure Database	21

3.1.2	PTB Diagnostic ECG Database	22
3.2	Artificial Neural Network	23
3.2.1	Convolutional Neural Networks (CNN)	26
3.2.2	Recurrent Neural Network	30
3.3	Linguagem de Programação e IDE's	33
4	Desenvolvimento	35
4.1	Visão Geral	35
4.2	Construção do <i>Dataset</i> Customizado	37
4.2.1	Seleção de Amostras a partir dos Sinais de ECG	40
4.3	Pré Processamento	43
4.3.1	Corrigindo a Amostragem	44
4.3.2	Normalização	45
4.3.3	Estrutura Final	46
4.3.4	Repartição - Treino e Teste	46
4.4	Arquitetura LSTM	47
4.5	Arquitetura CNN 1D	49
5	Resultados e Discussões	53
5.1	Métricas de Avaliação	53
5.2	LSTM	54
5.3	CNN 1D	55
5.4	Comparação Estado da Arte	57
6	Conclusão	59
A	Outro(s) Apêndice(s)	A1

Lista de Tabelas

4.1	Dados dos sinais de ECG coletados de indivíduos diagnosticados com ICC, obtidos a partir da BIDMC Congestive Heart Failure Database.	39
4.2	Dados dos sinais de ECG coletados de indivíduos saudáveis, extraídos da PTB Diagnostic ECG Database.	39
4.3	Pares patológicos e de controle formados com base em género e faixa etária.	40
5.1	Comparação das métricas de performance entre os modelos LSTM e CNN .	57
5.2	Comparação dos resultados com os métodos do estado da arte para a classificação de ICC	58

Lista de Figuras

1.1	Exemplo de um eletrocardiógrafo. Fonte: [6]	6
1.2	Representação das 12 derivações ECG. Fonte: [7]	7
1.3	Ondas, complexos e segmentos do sinal ECG. Fonte: [8]	8
3.1	Representação do neurónio artificial. Fonte: [43]	24
3.2	Representação de uma ANN genérica multi-camada. Fonte: [45]	26
3.3	Ilustração da rede neural CNN. Fonte: [46]	26
3.4	Ilustração da RNN comparado a <i>feedforward</i> . Fonte: [49]	30
3.5	Ilustração da célula LSTM. Fonte: [51]	31
4.1	Diagrama da Solução	36
4.2	Comparação entre uma amostra de ECG patológica e uma saudável: (a) sinal de ECG de um paciente com ICC e (b) sinal de ECG de um controle saudável.	44
4.3	Representação das repartições do <i>dataset</i> . Fonte: [59]	47
4.4	Código fonte da arquitetura LSTM	48
4.5	Código fonte da arquitetura CNN-1D	50
4.6	Representação das dimensões e operações da CNN-1D	51
5.1	Matriz de Confusão para o modelo LSTM	55
5.2	Matriz de Confusão para o modelo CNN	56
5.3	Comparação dos valores de perda por época para os modelos LSTM e CNN	57
A.1	Lista dos 30 sinais derivados de cada um dos 14 pacientes da BIDMC	A1

A.2 Lista dos 30 sinais derivados de cada um dos 14 indivíduos da PTB A2

Capítulo 1

Introdução

Patologias cardíacas estão entre as doenças que mais causam mortes humanas em todo o mundo. Estima-se que 19,8 milhões de pessoas morreram por doenças cardiovasculares em 2022, representando um aumento de quase 60% desde 1990 [1]. A taxa de mortalidade de quem possui esta doenças é consideravelmente relevante e, mesmo que o indivíduo não venha a sofrer o óbito, a sua qualidade de vida pode ser reduzida ao extremo a depender da gravidade.

A causa destas doenças varia de caso a caso, mas geralmente estão atreladas a hábitos/estilo de vida ou questões genéticas. Segundo dados da Organização Pan-Americana de Saúde (OPAS), o número de mortes por doenças cardíacas aumentou em mais de 2 milhões desde o ano 2000 para quase 9 milhões em 2019 [2].

Como forma de atenuar os problemas causados por essas doenças, diversas tecnologias foram desenvolvidas e implementadas na área da medicina, desde equipamentos que medem a frequência cardíaca até dispositivos sofisticados como Máquinas de Circulação Extracorpórea (CEC), que substituem as funções do coração durante cirurgias cardíacas de alta complexidade.

No tocante ao diagnóstico, uma série de dispositivos eletrônicos adquirem informações que auxiliam médicos a detectar anomalias e gerar diagnósticos. Um exemplo disto é o eletrocardiograma, dispositivo que mede a diferença de potencial elétrico gerada pelo coração durante seu ciclo de contração e relaxamento.

Estes procedimentos geram uma quantidade significativa de dados que descrevem patologias e diversos outros comportamentos cardíacos. Mesmo com o avanço significativo da tecnologia aplicado a medicina nas últimas décadas, há ainda uma lacuna a ser preenchida no que diz respeito ao processamento e análise destes valiosos dados. A inteligência artificial se apresenta como um instrumento muito útil para aprimorar a tecnologia nesta área, pois é uma excelente ferramenta para analisar e encontrar padrões em eletrocardiogramas e outros biosinais no geral.

No entanto, apesar da notável capacidade da inteligência artificial em detectar padrões em sinais como o ECG, é fundamental destacar alguns pontos críticos. Os resultados gerados pelos modelos dependem diretamente do contexto dos dados utilizados no treinamento, tornando a quantidade, qualidade e representatividade desses dados fatores desafiadores que podem impactar significativamente o desempenho e a confiabilidade do modelo.

Outro aspecto crucial é a interpretabilidade dos resultados, ou seja, a capacidade de compreender quais parâmetros e características foram considerados pela rede neural para produzir os resultados. Modelos como LSTM e CNN extraem características abstratas dos sinais, mas não é possível garantir que essas características correspondam a variações fisiológicas reconhecidas pela área médica. Essa limitação representa um desafio significativo, dificultando tanto a validação científica quanto a confiança clínica, uma vez que não se pode assegurar que as informações extraídas estejam diretamente relacionadas a fatores fisiológicos relevantes para a classificação.

1.1 Insuficiência Cardíaca Congestiva

A Insuficiência Cardíaca Congestiva (ICC) é uma doença crônica e progressiva que compromete a capacidade do coração de bombear sangue de maneira eficiente para o restante do corpo. Como resultado, os portadores desta condição experimentam uma redução no fluxo sanguíneo para os órgãos e tecidos, o que afeta diretamente o funcionamento dessas regiões. Para compensar essa deficiência, o coração muitas vezes tenta aumentar

seu esforço de bombeamento, o que pode levar à hipertrofia ventricular e ao aumento da pressão dentro do coração. Essa situação impõe uma carga significativa sobre o sistema cardiovascular, agravando ainda mais a condição do paciente.

Dados da Escola de Medicina da Universidade de Yale estimam que cerca de 6 milhões de estadunidenses são portadores de ICC [3]. Projeções mais amplas indicam que o número de pessoas com insuficiência cardíaca em geral poderá alcançar 8,7 milhões em 2030, 10,3 milhões em 2040 e impressionantes 11,4 milhões em 2050 [4], evidenciando o aumento contínuo da prevalência dessa condição, especialmente em países com populações mais envelhecidas.

1.1.1 Causas

A incapacidade do coração de bombear sangue adequadamente deriva de mudanças fisiológicas no sistema cardiovascular causadas por diferentes situações. A causa mais comum da ICC é a Doença Arterial Coronariana (DAC), que ocorre quando as artérias que fornecem sangue ao coração ficam estreitadas ou bloqueadas. Os fatores de risco para a doença arterial coronariana incluem níveis elevados de colesterol e/ou triglicerídeos no sangue, hipertensão arterial, dieta inadequada, estilo de vida sedentário, diabetes, tabagismo, excesso de peso e estresse.

Além da doença arterial coronariana, várias outras condições podem danificar o músculo cardíaco, levando à ICC. Entre essas, destacam-se infecções, doenças autoimunes e alguns tratamentos, como a quimioterapia. Essas condições podem comprometer a estrutura e a função do coração, resultando em sua incapacidade de bombear sangue de forma eficiente e atender às necessidades do corpo.

1.1.2 Sintomas

Os sintomas da ICC são variados e distintos, uma vez que diversas partes do corpo são afetadas pela falta de sangue oxigenado. No entanto, os sintomas mais frequentes são:

- **Dispneia (falta de ar):** Causada pelo baixo nível de oxigênio nos tecidos, especialmente durante atividades físicas, devido a incapacidade do coração fornecer a quantidade necessária de sangue oxigenado para os músculos;
- **Fadiga persistente:** A sensação constante de cansaço e fraqueza provocada pela falta de oxigênio e pela baixa troca de nutrientes nos músculos e órgãos;
- **Inchaço e ganho de peso:** Retenção de líquidos no corpo, especialmente nas pernas, tornozelos e pés, devido à baixa capacidade dos rins de filtrar e excretar o líquido adequadamente. Esse acúmulo de líquidos pode resultar em sobrepeso para o paciente.
- **Náusea:** Causada pela congestão nos órgãos internos devido à redução do fluxo sanguíneo e ao acúmulo de fluidos. Pode ser acompanhada de falta de apetite.
- **Confusão mental:** Em casos mais avançados, a confusão mental pode estar presente acompanhado da perda da capacidade de foco devido a quantidade insuficiente de oxigênio no cérebro.

Esses sintomas podem variar em gravidade dependendo do estágio da doença e de outros fatores como a presença de outras condições médicas.

1.1.3 Tratamento

A Insuficiência Cardíaca Congestiva (ICC) é uma condição crônica e progressiva, o que significa que, na maioria dos casos, não pode ser completamente curada [5]. Por isso, o objetivo principal do tratamento é aliviar os sintomas, melhorar a função cardíaca, prevenir complicações e estabilizar a condição do paciente.

O tratamento inicial da ICC geralmente envolve medicamentos que ajudam a aliviar os sintomas e facilitar o trabalho do coração.

- **Medicamentos para Relaxar os Vasos Sanguíneos:** Estes medicamentos ajudam a diminuir a pressão sobre o coração ao relaxar os vasos sanguíneos. Isso faz

com que o coração trabalhe com mais facilidade.

- **Beta-Bloqueadores:** Estes medicamentos diminuem a frequência cardíaca e a pressão arterial, o que reduz o esforço que o coração precisa fazer e melhora sua eficiência.
- **Diuréticos:** Estes são usados para remover o excesso de água e sal do corpo. Isso ajuda a reduzir o inchaço e a falta de ar, que são comuns em quem tem ICC.

Se esses medicamentos não forem suficientes para controlar a ICC, podem ser necessárias opções mais avançadas. Entre elas estão:

- **Dispositivos de Assistência Ventricular (VADs):** Estes são dispositivos mecânicos implantados no coração para ajudar a bombear o sangue de maneira mais eficiente. Eles podem ser uma solução para pacientes com ICC grave.
- **Transplante de Coração:** Em casos extremos, substituir o coração doente por um saudável de um doador pode ser a melhor solução. Isso pode oferecer uma nova chance de vida e melhorar significativamente a qualidade de vida.

A escolha do tratamento depende da gravidade da condição e da saúde geral do paciente. Cada opção tem suas próprias vantagens e desafios, e a decisão é feita com base em uma avaliação cuidadosa feita pelo médico e pelo paciente.

1.2 Eletrocardiograma

O Eletrocardiograma (ECG) é um dos métodos mais amplamente utilizados para avaliar as condições do coração. Com um sinal de ECG, é possível diagnosticar uma variedade de condições cardíacas, incluindo arritmias, infartos do miocárdio, bloqueios de condução e hipertrofias. Sua utilização é essencial tanto em situações de emergência quanto em exames de rotina, proporcionando uma avaliação não invasiva e rápida da função cardíaca.

O sinal de ECG registra a diferença de potencial elétrico gerada pela atividade do miocárdio durante o ciclo cardíaco na pele do sujeito, oferecendo uma representação gráfica dessas variações. Essa representação gráfica possibilita uma avaliação visual detalhada por médicos e profissionais de saúde.

Para captar um sinal de ECG, utiliza-se um dispositivo chamado eletrocardiógrafo, representado na Figura 1.1. Os eletrodos são colocados na pele em pontos específicos do corpo, geralmente nos membros e no tórax, para captar os sinais elétricos. O ECG padrão de 12 derivações demonstrado na Figura 1.2 inclui:




Figura 1.1: Exemplo de um eletrocardiógrafo. Fonte: [6]

- **Derivações dos membros:** I, II, III, aVR, aVL, aVF.
- **Derivações precordiais:** V1 a V6.

Cada uma dessas derivações fornece uma perspectiva diferente da atividade elétrica do coração, permitindo uma análise abrangente de sua função.

O traçado do ECG consiste em várias ondas, segmentos e intervalos, cada um refletindo eventos específicos no ciclo cardíaco. A Figura 1.3 representa um ciclo de ECG com as anotações das respectivas ondas, segmentos e intervalos.




Figura 1.2: Representação das 12 derivações ECG. Fonte: [7]

- **Onda P:** Representa a despolarização das aurículas.
- **Complexo QRS:** Indica a despolarização dos ventrículos e é composto pelas ondas Q, R e S.
- **Onda T:** Reflete a repolarização dos ventrículos.
- **Segmento PR:** Representa o tempo entre o final da despolarização auricular (onda P) e o início da despolarização ventricular (início do complexo QRS).
- **Segmento ST:** Período entre o final da despolarização ventricular e o início da repolarização.
- **Intervalo PR:** Tempo entre o início da despolarização atrial e o início da despolarização ventricular.
- **Intervalo QT:** Período desde o início da despolarização ventricular até o final da repolarização.

Através destas informações fornecidas pelo ECG, é possível identificar diversos tipos de comportamento do coração. Por exemplo, casos de arritmia cardíaca estão associados a intervalos irregulares entre ondas R.

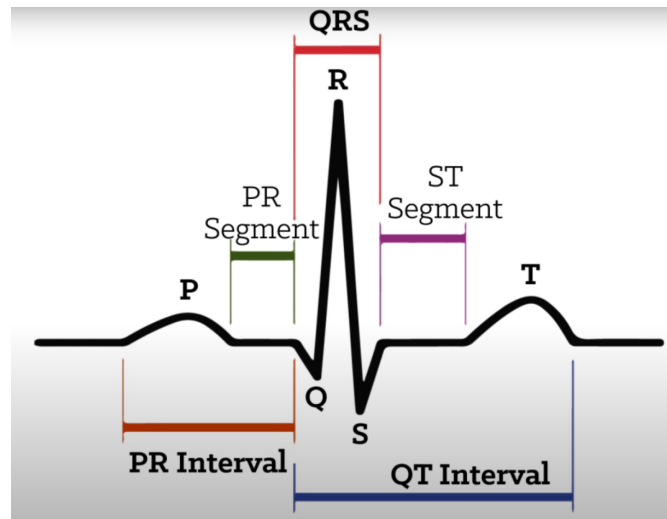


Figura 1.3: Ondas, complexos e segmentos do sinal ECG. Fonte: [8]

1.2.1 ECG característico da ICC

O sinal ECG de uma pessoa que possui ICC pode variar significativamente, em dependência das causas da doença. Isto porque o músculo cardíaco pode ser afetado de diferentes formas e apresentar comportamentos distintos caso a caso. Serão apresentadas principais alterações que podem ocorrer em cada parte do sinal, considerando diferentes causas.

- **Onda P:** Anormalidades da onda P estão associadas a distúrbios na condução interatrial e aumento do volume atrial esquerdo. Em pacientes com insuficiência cardíaca, há função sistólica e diastólica anormal, o que pode resultar em aumento do volume atrial esquerdo e propagação não homogênea do impulso sinusal [9].
- **Complexo QRS:** Uma característica associada ao complexo QRS está no prolongamento da duração desta fase nos pacientes que possuem ICC [10]. Um intervalo de $\geq 0,12$ segundos é considerado bloqueio completo de ramo ou um atraso na condução intraventricular [11]. Este prolongamento pode indicar sinais de hipertrofia ventricular, uma vez que o aumento da massa muscular pode prolongar a despolarização.
- **Onda T:** Pode haver inversão da onda T (especialmente em derivações precordiais),

onda T achatada e alterações na morfologia. A inversão da onda T pode estar associada a hipertrofia ventricular [12], uma das características comuns associadas a ICC.

- **Segmento PR:** O prologamento do segmento PR não é necessariamente um indicativo de doença cardíaca, especialmente em pessoas mais velhas. No entanto, estudos mais recentes apontam que o alargamento deste segmento indica aumento no risco do indivíduo possuir alguma patologia cardíaca, incluindo ICC [13].
- **Segmento ST:** O segmento ST pode apresentar certo nível de depressão. Isto está relacionado a pacientes que possuem isquemia miocárdica, condição em que o sangue não irriga propriamente o músculo cardíaco devido a obstruções arteriais [14]. Esta condição pode ser uma das causas da ICC.

1.3 Justificativa

O diagnóstico da Insuficiência Cardíaca Congestiva (ICC) é um processo complexo, realizado por médicos que consideram uma variedade de exames e testes. Para aprimorar as ferramentas de detecção e auxiliar os profissionais de saúde, propõe-se a implementação de um modelo de inteligência artificial capaz de detectar automaticamente a presença de características associadas à ICC em sinais ECG.

Este método pode tornar-se valioso no diagnóstico, especialmente em exames de *Holter*, nos quais dezenas de horas de sinais ECG são gravados. A avaliação manual desses sinais pelo médico pode ser extremamente trabalhosa e demorada. A capacidade da inteligência artificial de processar grandes quantidades de dados de forma eficiente torna este método uma solução altamente útil, facilitando a detecção rápida e precisa de condições patológicas e, conseqüentemente, melhorando o atendimento ao paciente.

1.4 Objetivos

O objetivo deste trabalho é a avaliação da efetividade dos modelos de *deep learning* Long Short-Term Memory (LSTM) e Convolutional Neural Network (CNN) para detecção de ICC em sinais de ECG. Os dados utilizados são provenientes de bases de dados públicas e previamente classificadas por profissionais da saúde.

O modelo deve ser capaz de receber um sinal ECG sem qualquer tipo de pré-processamento ou extração de características e classificá-lo como patológico/não patológico baseado nos dados de treinamento.

1.5 Estrutura do Documento

A estrutura deste documento está dividida nos seguintes capítulos.

O capítulo 1 contém a introdução, justificativa e os objetivos do trabalho. Há também uma descrição da patologia a ser detectada, quais as principais causas, sintomas e o tratamento adequado. Por fim, o capítulo descreve o sinal ECG considerando o método de aquisição do sinal, as componentes do ECG e como elas se modificam de acordo com o ICC.

O capítulo 2 contém o estado da arte de trabalhos relacionados que consistem na utilização de *deep learning* para detecção de patologias cardíacas em sinais ECG. São explorados também trabalhos que utilizam sinais de ECG puros, sem extração de características, e outras metodologias para detecção da ICC.

O capítulo 3 explora as tecnologias e metodologias utilizadas no desenvolvimento do trabalho. Há uma descrição detalhada dos modelos LSTM/CNN e como estes atuam na classificação dos sinais ECG sem pré processamento.

O capítulo 4 aborda a arquitetura da solução de um modo geral, incluindo como foi construída a base de dados através da BIDMC Congestive Heart Failure e PTB Diagnostic ECG da Physionet. São expostos os parâmetros do treinamento e os métodos para avaliação dos modelos.

O capítulo 5 apresenta os resultados e as discussões das classificações realizadas pelos modelos treinados. Será feita uma comparação detalhada com os resultados obtidos em estudos semelhantes, destacando os aspectos que influenciaram esses resultados. Além disso, serão identificadas possíveis oportunidades para aprimorar os resultados.

O capítulo 6 conclui o trabalho avaliando o impacto do trabalho proposto e a eficácia da solução proposta para detecção da ICC. Há também uma análise crítica dos pontos de melhoria e o que pode ser aperfeiçoado em trabalhos futuros.

Capítulo 2

Estado da Arte

Este capítulo tem como objetivo revisar a literatura científica existente relacionada a este trabalho. Serão abordados desde os métodos clássicos de reconhecimento de padrões até as abordagens mais recentes, incluindo as técnicas de classificação associadas. Também serão explorados estudos que utilizam inteligência artificial para a detecção de patologias em biosinais, com ênfase na aplicação de deep learning para a detecção da ICC.

2.1 Métodos Genéricos para Extração de Características

Diversos métodos matemáticos e estatísticos genéricos, entre outras aplicações, são amplamente utilizados para a detecção de padrões em sinais temporais, cada um com suas abordagens específicas.

Entre os mais notáveis, destaca-se a Análise de Fourier [15], que, através da decomposição do sinal em suas componentes de frequência, permite a identificação de frequências dominantes que podem estar associadas a patologias específicas.

A Transformada de Wavelet [16] permite analisar sinais temporais em termos de tempo e frequência simultaneamente. Essa abordagem pode ser especialmente útil para sinais não estacionários, como o ECG, que possuem variações de frequência ao longo do tempo.

A Transformada de Hilbert também é um dos métodos clássicos mais populares empregados na extração de características. Através da envoltória e da fase instantânea calculadas por este método, é possível isolar e destacar eventos específicos do sinal de ECG. Um exemplo disso é o trabalho de [17], que utiliza a Transformada de Hilbert para detecção do complexo QRS.

Estes são alguns dos métodos clássicos para extração de características. A vantagem desses métodos é que possuem uma ampla base científica e, em termos de diagnóstico do sinal de ECG, é possível mensurar como cada característica extraída contribui para a classificação.

2.2 Métodos de Aprendizado de Máquina

Esta seção tem como objetivo apresentar uma revisão das principais ferramentas de aprendizado de máquina aplicáveis à classificação de sinais de ECG, abrangendo desde algoritmos clássicos até arquiteturas baseadas em redes neurais.

2.2.1 Algoritmos de Aprendizado Supervisionado

No que diz respeito à classificação, diversas metodologias de aprendizado de máquina podem ser empregadas. Entre os métodos clássicos, podemos citar o Support Vector Machine (SVM), que busca encontrar uma linha ou plano que separa as diferentes categorias de dados da melhor forma possível, maximizando a distância entre elas. Quando os dados não podem ser divididos de forma simples, o SVM usa uma técnica chamada *kernel trick*, que transforma os dados em um formato mais adequado, permitindo que sejam separados de maneira eficaz [18]. Um exemplo de aplicação do SVM pode ser encontrado no trabalho [19], em que é feita a detecção de patologias através da voz.

Outro exemplo é o K-Nearest Neighbors (KNN) [20]. Este método de classificação identifica os k vizinhos mais próximos de um ponto de dados desconhecido, com base em uma medida de distância, como a distância euclidiana. A classe do ponto de dados é determinada pela classe majoritária entre os seus vizinhos mais próximos. Esse método

é eficaz para problemas onde a relação entre as características dos dados é localmente agrupada, como em tarefas de reconhecimento de padrões. Um exemplo de aplicação que utiliza KNN pode ser encontrado no trabalho [21], em que o modelo é empregado para avaliar o crescimento anormal de células cancerígenas no sangue.

A Árvore de Decisão [22] é um método de aprendizado supervisionado em que o processo de classificação é representado por uma estrutura hierárquica em forma de árvore. Cada nó interno da árvore corresponde a uma decisão com base em uma característica dos dados, e as arestas representam os possíveis resultados dessa decisão. Os “nós folha” da árvore indicam a classe ou o valor predito para o dado. A Árvore de Decisão é intuitiva e fácil de interpretar, pois o caminho da raiz até a folha pode ser seguido como uma série de decisões claras, o que ajuda a explicar como o resultado foi alcançado. O trabalho [23] utiliza este método para analisar o genes associados a doença de Alzheimer.

Estes exemplos citados se enquadram como algoritmos de aprendizado supervisionado e, geralmente, apresentam melhores resultados de classificação quando é performada a extração de características nos dados originais [24].

2.2.2 Redes Neurais

As redes neurais são ferramentas poderosas no aprendizado de máquina, capazes de modelar relações complexas e não-lineares através de seus neurônios. Dependendo da arquitetura, elas têm a capacidade de realizar a extração automática de características, ajustando-se dinamicamente aos dados de entrada.

Iniciando com os exemplos, temos a rede Multi-Layer Perceptron (MLP), composta por camadas densas, nas quais cada neurônio de uma camada está totalmente conectado aos neurônios da camada seguinte. Esse tipo de rede é amplamente utilizado em problemas de classificação e regressão, oferecendo como uma de suas vantagens a capacidade de treinar modelos com dados brutos, dependendo do contexto [25]. Isso representa uma mudança significativa em relação aos algoritmos da Seção 2.2.1, que dependem da extração de características para alcançar um bom desempenho.

As redes Long Short-Term Memory (LSTM) são uma variante das Recurrent Neural Networks (RNN), em que as saídas dos neurônios dependem tanto das entradas quanto de estados anteriores. Essas redes se destacam no processamento de dados sequenciais e temporais. Com seus mecanismos de memória, como células de estado e portas de esquecimento, as LSTMs conseguem modelar relações de longo prazo nas sequências. Assim como as MLPs, as LSTMs não dependem de engenharia manual para extração de características, obtendo bons resultados com dados brutos. A Subseção 3.2.2.1 contém informações detalhadas da arquitetura deste rede,

Outro exemplo é a Convolutional Neural Network (CNN), que possui uma arquitetura voltada para dados estruturados espacialmente, como imagens, mas também é adaptável para dados unidimensionais, o que a torna adequada também para séries temporais. As camadas convolucionais realizam extração hierárquica de características diretamente dos dados brutos, identificando padrões relevantes em diferentes escalas. Essa capacidade elimina a necessidade de extrair manualmente características.

Uma característica importante a ser considerada em todas essas redes neurais é que, quando realizam a extração automática de características, não é possível determinar com precisão se as características extraídas correspondem exatamente àquelas que se pretende identificar. Em resumo, os resultados gerados pela rede carecem de explicabilidade e transparência, o que pode representar um desafio para a implementação desses modelos em contextos críticos, como no diagnóstico médico.

2.3 Detecção de Patologias em Biossinais Utilizando Redes Neurais

O conceito de inteligência artificial é amplo, e diversas técnicas podem ser empregadas para a classificação de patologias usando biossinais. No trabalho desenvolvido por [26], a arquitetura CNN é utilizada para classificar diferentes tipos de infarto do miocárdio. De forma semelhante, [27] utiliza redes LSTM para classificar laringite crônica,

enquanto [28] aplica Multi Layer Perceptron (MLP) para classificar sinais de eletroencefalograma (EEG). No trabalho de [29], redes LSTM combinadas com um AutoEncoder (AE) são usadas para classificar arritmias cardíacas.

Pesquisas adicionais incluem o estudo de [30], que se concentra na classificação de componentes do sinal de ECG, como o complexo QRS, ondas P e ondas T. Por outro lado, [31] destaca o uso de ANN para classificar arritmias cardíacas. No estudo realizado por [32], Generative Adversarial Network (GAN) são empregadas para gerar sinais de ECG sintéticos para melhorar os dados de treinamento, e [33] aplica Multi Layer Perceptron (MLP) para detectar fibrilação atrial, extraindo parâmetros de Jitter e Shimmer.

2.4 Detecção de ICC em Sinais de ECG Utilizando *Deep Learning*

A detecção da ICC em sinais de ECG pode ser abordada de diversas maneiras, variando desde a escolha do modelo até as técnicas de pré-processamento dos dados para o treinamento. Para delimitar o escopo desta seção, focaremos exclusivamente nos trabalhos que utilizaram técnicas de *deep learning* para a classificação da ICC em sinais de ECG.

No trabalho de [34], é utilizada uma arquitetura baseada em CNN e LSTM para diagnóstico da ICC. A entrada da rede proposta é composta por intervalos RR de centenas de *heartbeats*. O primeiro processamento destes sinais é feito pela rede CNN, que extrai características abstratas de cada um dos sinais através das camadas convolucionais e operações *pooling*. Posteriormente, os dados são processados pela rede LSTM que captura as dependências temporais dos dados de saída da CNN. A saída da LSTM é aplicada no “método de atenção” para determinar a importância de cada uma das sequências geradas. Por fim, é feita a classificação binária. Esta proposta gerou resultados com precisão de 99,52%, sensibilidade de 99,31%, especificidade de 99,28%, F-Score de 98,94% e AUC de 99,9%.

Na pesquisa conduzida por [35], é proposto o uso de *Recurrent Neural Networks* (RNN)

baseados em LSTM para a classificação de ICC. A metodologia consiste em filtrar os sinais utilizando a transformada Wavelet, particionar os sinais em pequenos intervalos de 1 até 4 segundos de duração. Foram treinados 24 modelos LSTM com diferentes hiperparâmetros e a melhor classificação resultou em uma acurácia de 99.86%, sensibilidade 99.85%, especificidade 99.85%, precisão 99.87%, e F1-score de 99.86%.

O trabalho [36] utiliza uma estrutura CNN 1D com filtro Gabor para classificar sinais ECG de 4 diferentes classes: saudáveis, ICC, infarto do miocárdio e doença arterial coronariana. A entrada da rede são sinais ECG com duração de 2 segundos que passam por um filtro Gabor e depois são aplicados a rede CNN. A acurácia obtida na classificação foi de 98,74%.

A pesquisa conduzida por [37] propõe uma abordagem de *deep learning* para a identificação automatizada de ICC e arritmias. A proposta consiste em um algoritmo que combina (CNN) com a Transformada Gabor Não Estacionária de Q Constante (CQ-NSGT) para transformar sinais ECG unidimensionais em representações tempo-frequência bidimensionais, que são analisadas por um modelo pré-treinado, AlexNet. A técnica é comparada com a Transformada Wavelet Contínua (CWT), demonstrando a eficácia do CQ-NSGT. Os testes com dados reais de ECG alcançaram uma acurácia de 98,82%, sensibilidade de 98,87%, especificidade de 99,21% e precisão de 99,20%, evidenciando a eficácia do sistema no diagnóstico de ECG.

No trabalho [38] é utilizada a metodologia CNN 1D para a classificação da ICC. Os dados de entrada são *heartbeats*, ou seja, o tamanho da amostra é um ciclo ECG e não uma janela pré determinada. Para coletar o *heartbeat*, o sinal foi colhido em torno do pico R: 235 ms antes do pico e 390 ms depois. Com esta metodologia, o resultado obtido foi de 97,8% de acurácia (considerando todos as amostras). Este trabalho também cita a maior eficiência deste método se comparado a extração de características HRV (Heart Rate Variability).

Apesar de não ser um método de *deep learning*, vale a pena a citação de outro trabalho devido ao sucesso em classificar 100% dos casos. Trata-se do trabalho de [39], no qual é feita extração de características com o método de autoregressão BURG. Com as

características extraídas, é realizada a classificação através do modelo Random Forest. A acurácia obtida foi de 100%.

Nenhum dos estudos referenciados compara diretamente o desempenho de diferentes redes neurais utilizando a mesma arquitetura e conjunto de dados. Cada um se concentra em um único modelo, como CNN, LSTM ou uma combinação deles, sem compará-los em condições idênticas. Este trabalho aborda essa lacuna ao analisar duas redes diferentes no mesmo conjunto de dados e arquitetura, a fim de determinar qual delas é mais eficaz na classificação de ICC. A comparação oferece insights sobre os pontos fortes e fracos de cada modelo, proporcionando uma compreensão mais clara de qual deles apresenta melhor desempenho para essa tarefa.

Capítulo 3

Materiais e Métodos

Neste capítulo serão apresentados os materiais e métodos utilizados para o desenvolvimento do trabalho. As bases de dados utilizadas são públicas e estão disponíveis no site da Physionet, o software para treinar os modelos foi desenvolvido em Python na plataforma Google Colab e as arquitetura utilizadas foram o LSTM e CNN. Os pacotes e frameworks utilizados incluem: `wfdb`, `numpy`, `pandas`, `matplotlib`, `pywt`, `scipy`, `spectrum`, `sklearn`, `tensorflow`, entre outros.

3.1 Base de Dados

Foram utilizadas duas bases de dados da Physionet [40] para esta solução, ambas públicas e previamente classificadas.

3.1.1 BIDMC Congestive Heart Failure Database

Das diversas bases analisadas, a BIDMC Congestive Heart Failure apresentou a maior quantidade de dados ECG, diversidade de idade e género e qualidade nos sinais.

A BIDMC Congestive Heart Failure Database inclui gravações de ECG de longo prazo de 15 pessoas (11 homens, com idades entre 22 e 71 anos, e 4 mulheres, com idades entre 54 e 63 anos) com ICC severa (classe NYHA 3 e 4). Este grupo de sujeitos fazia parte

de um grupo de estudo maior que recebia terapia médica convencional antes de receber o agente inotrópico oral milrinona. É importante reforçar que os sinais de ECG presentes nesta base de dados são de antes da administração da milrinona. O grupo de sujeitos foi tratado inicialmente com terapia médica convencional e somente depois foi introduzido o tratamento com a milrinona. Mais informações a respeito do estudo original podem ser encontradas em [41].

As gravações individuais têm cerca de 20 horas de duração cada e contêm dois sinais de ECG, cada um amostrado a 250 amostras por segundo com resolução de 12 bits em um intervalo de ± 10 milivolts. As gravações analógicas originais foram feitas no Hospital Beth Israel de Boston usando gravadores de ECG ambulatoriais. Para cada gravação há um arquivo de cabeçalho com extensão .hea que contém idade, gênero e gravidade da patologia do paciente (NYHA 3 ou NYHA 4). O paciente “chf06” não possui informação de idade.

3.1.2 PTB Diagnostic ECG Database

Devido ao fato da base de dados patológica BIDMC não possuir sinais de controle, foi necessário buscar sinais ECG saudáveis em outra base de dados. A PTB Diagnostic ECG Database foi selecionada pois contém na sua extensa base de dados um grupo de sinais de controle equivalentes em idade e gênero com a base de dados patológica. Este balanceamento é importante para que não haja enviesamento no treinamento do modelo.

A PTB Diagnostic ECG Database contém 549 registros de 290 sujeitos (com idades entre 17 e 87 anos, média de 57,2; 209 homens, média de 55,5 anos, e 81 mulheres, média de 61,6 anos; as idades não foram registradas para 1 mulher e 14 homens). Cada sujeito é representado por um a cinco registros. Cada registro inclui 15 sinais medidos simultaneamente: as 12 derivações convencionais (i, ii, iii, avr, avl, avf, v1, v2, v3, v4, v5, v6) junto com as 3 derivações Frank (vx, vy, vz). Cada sinal é digitalizado a 1000 amostras por segundo, com resolução de 16 bits em um intervalo de $\pm 16,384$ mV. Em alguns casos isolados, algumas gravações estão com taxas de amostragem de até 10 kHz.

Estes ECGs foram obtidos utilizando um gravador desenvolvido pelo Physikalisch-Technische Bundesanstalt (PTB) que contam com 16 canais de entrada (14 para ECGs, 1 para respiração, 1 para tensão de linha), uma tensão de entrada de ± 16 mV com compensação de offset de até ± 300 mV. A resolução da conversão A/D é de 16 bits e a amostragem é feita de maneira síncrona em todos os canais. Com relação à tensão de ruído, máximo de $10 \mu\text{V}$ (pp), ou $3 \mu\text{V}$ (RMS) com curto-circuito de entrada. A base de dados conta também com registros da resistência da pele e do nível de ruído durante a coleta dos dados [42].

Assim como na BIDMC Congestive Heart Failure Database, esta base de dados também conta com arquivos de cabeçalho (.hea) na maioria dos registros de ECG. Nestes arquivos encontra-se um resumo clínico detalhado, incluindo idade, gênero, diagnóstico e, quando aplicável, dados sobre histórico médico, medicação e intervenções, patologia da artéria coronária, ventriculografia, ecocardiografia e hemodinâmica. 22 dos sujeitos não possuem resumo clínico. Os critérios para a seleção dos indivíduos que foram utilizados no escopo deste trabalho são apresentados no Seção 4.2.

3.2 Artificial Neural Network

Os algoritmos de classificação baseiam-se em ANNs, que são inspiradas na estrutura e funcionamento do sistema nervoso biológico. Essas redes consistem em unidades de processamento chamadas neurónios artificiais, organizadas em camadas interconectadas.

O neurónio artificial representado na Figura 3.1 é a unidade básica de processamento em uma rede neural, operando matematicamente para processar informações e auxiliar na tomada de decisões em modelos de aprendizado de máquina. Cada neurónio é composto por três componentes principais:

- **Pesos Sinápticos:** Esses pesos determinam a importância de cada entrada. Se uma entrada é mais relevante para a tarefa, seu peso será maior. Os pesos são ajustados durante o treinamento com a finalidade de diminuir o erro na saída.




Figura 3.1: Representação do neurónio artificial. Fonte: [43]

- **Somador:** O somador realiza a agregação ponderada das entradas, multiplicando cada entrada pelo seu peso correspondente e somando os resultados. O resultado produzido nesta etapa serve de *input* para a função de ativação.
- **Função de Ativação:** O resultado da soma ponderada passa por uma função de ativação que introduz não-linearidade, permitindo à rede modelar relações complexas. Esta função gera uma saída que pode servir de entrada para camadas superiores da rede, formando assim um sistema que aprende representações mais complexas e abstratas dos dados de entrada.

A Equação 3.1 mostra a representação matemática do neurónio, onde y representa a saída, f é a função de ativação e u representa o potencial de ativação. A Equação 3.2 representa o potencial da ativação, onde w_i são os pesos sinápticos associados às entradas x_i e b é o viés. Este parâmetro permite deslocar a função de ativação para a direita ou para a esquerda no espaço de entrada trazendo mais flexibilidade à rede neuronal. O ajuste do viés b e dos pesos sinápticos w_i é realizado durante o treinamento por meio de algoritmos de otimização como o Gradient Descent (GD) e o Stochastic Gradient Descent (SGD) [44].

$$y = f(u) \tag{3.1}$$

$$u = \sum_{i=1}^n w_i x_i + b \quad (3.2)$$

Em uma ANN os neurónios são interconectados e atuam em conjunto para modelar a rede. Eles são organizados em grupos chamados camadas, cada uma com uma função específica. Tipicamente, as ANNs são compostas por três tipos principais de camadas:

- **Camada de Entrada:** A camada de entrada é responsável por receber e estruturar os dados brutos de entrada. Cada neurónio na camada de entrada corresponde a uma característica ou dimensão do vetor de entrada. Isso garante que cada característica do dado seja apresentada de forma ordenada e clara para a rede neural.
- **Camadas Ocultas/Escondidas:** As camadas ocultas são intermediárias entre a camada de entrada e a camada de saída. Cada neurónio em uma camada oculta recebe uma soma ponderada das entradas da camada anterior, que é então transformada pela função de ativação. Em redes neurais mais complexas, pode haver múltiplas camadas ocultas.
- **Camada de Saída:** A camada de saída recebe os valores processados pelas camadas ocultas, com cada neurónio conectado a todos os neurónios da camada anterior. Cada neurónio realiza uma soma ponderada das entradas e aplica uma função de ativação adequada para gerar a previsão final. A função de ativação e o número de neurónios dependem do tipo de tarefa; por exemplo, em uma classificação binária, a saída geralmente tem um único neurónio com função de ativação sigmoide.

A Figura 3.2 representa a estrutura genérica de uma ANN multi-camada. Cada modelo pode apresentar características distintas, como o fluxo de propagação e a quantidade de camadas ocultas, permitindo a criação de diversas arquiteturas personalizadas. Essas variações tornam possível adaptar cada rede neural de maneira mais eficaz a diferentes tipos de dados, maximizando seu desempenho em tarefas específicas.




Figura 3.2: Representação de uma ANN genérica multi-camada. Fonte: [45]

3.2.1 Convolutional Neural Networks (CNN)

As CNNs são uma classe de redes neurais que se destacam por sua capacidade de extrair e aprender características de dados com estrutura espacial ou temporal, utilizando operações de convolução. Em uma rede CNN a informação flui de forma unidirecional, sem retornar a camadas anteriores (Figura 3.3), conseqüentemente uma das características desta rede é a ausência de ciclos ou loops nas conexões. Embora as CNNs sejam amplamente conhecidas por seu sucesso em tarefas de visão computacional, elas também podem ser eficazes em outras aplicações, como a análise e classificação de sinais temporais.

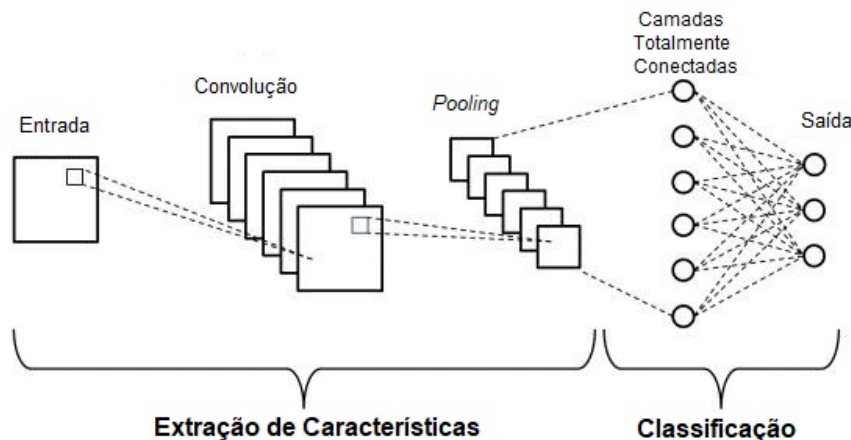


Figura 3.3: Ilustração da rede neural CNN. Fonte: [46]

A arquitetura de uma CNN é composta por uma série de camadas que processam a entrada em estágios progressivamente mais complexos, extraindo e combinando características. As principais camadas de uma CNN são:

1. Camadas Convolucionais

A camada convolucional aplica filtros (ou kernels) sobre a entrada, realizando a operação de convolução para extrair características locais. No caso de um sinal temporal bidimensional como o ECG, a convolução é feita ao longo do eixo temporal do sinal e é expressa pela Equação 3.3.

$$\text{Feature Map}_j = \sum_{i=1}^k W_{j,i} \cdot X_{t+i-1} + b_j \quad (3.3)$$

Na equação dada, $W_{j,i}$ são os pesos do filtro para a j -ésima característica, X_{t+i-1} são as amostras do sinal na janela de convolução e b_j é o viés para a j -ésima característica. Esta equação genérica representa a convolução unidimensional, que é o foco desta pesquisa. Para entradas que consistem em imagens ou dados com múltiplas dimensões, o princípio da equação é o mesmo, sendo ajustado de acordo com as dimensões dos dados de entrada.

2. Camadas de *Pooling*

Após a convolução, a camada de *pooling* reduz a quantidade de dados dos mapas de características, agregando informações e diminuindo a complexidade computacional [47]. O *pooling* é tipicamente realizado usando operações como *average pooling* (Equação 3.4) ou *max pooling* (Equação 3.5).

$$\text{Pooling}_j = \frac{1}{f} \sum_{i=t}^{t+f} X_i \quad (3.4)$$

onde $X_{t:t+f}$ é a região de *pooling* do índice t até $t + f$, e f é o tamanho do filtro de *pooling*. O filtro de *pooling* é uma janela de tamanho fixo que percorre os dados de entrada, agrupando conjuntos de valores que serão aplicados ao *average pooling*.

O resultado é a média aritmética dos valores na região $X_{t:t+f}$, obtida dividindo a soma dos valores pelo tamanho f .

$$\text{Pooling}_j = \max(X_{t:t+f}) \quad (3.5)$$

onde $X_{t:t+f}$ é a região de *pooling* que vai do índice t até $t + f$. O operador \max seleciona o valor máximo nessa região. Pooling_j representa o valor de *pooling* para a j -ésima região em ambas equações.

Em resumo, estas operações atuam para redução do número de amostras ao passo em que extraem as características mais importantes do sinal, facilitando a detecção de padrões de maior nível e reduzindo o risco de *overfitting*.

3. Camadas Densas

Após a extração e redução das características, as camadas densas conectam todas as unidades da camada anterior para realizar a classificação final. No caso de um sinal ECG, essa camada pode ser projetada para distinguir entre condições patológicas e não patológicas.

As camadas densas geralmente utilizam funções de ativação não lineares, como Rectified Linear Unit (ReLU) (Equação 3.6) ou, para a camada de saída, funções como softmax (Equação 3.7) para classificação multiclasse ou sigmoide (Equação 3.8) para classificação binária:

$$f(x) = \max(0, x) \quad (3.6)$$

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (3.7)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (3.8)$$

4. Treinamento - *Backpropagation* e otimização

Uma vez geradas as predições, o resultado na saída da rede é comparado com o valor verdadeiro conhecido utilizando uma função de custo (*loss function*). O objetivo desta operação é quantificar a diferença da predição da rede e o valor real, mensurando o erro. A Equação 3.9 descreve a função de custo utilizada neste trabalho: *binary cross-entropy*.

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (3.9)$$

- L é a perda média da entropia cruzada binária.
- N é o número total de exemplos no conjunto de dados.
- y_i é o rótulo verdadeiro (0 ou 1) para o i -ésimo exemplo.
- \hat{y}_i é a predição do modelo para o i -ésimo exemplo (probabilidade prevista).

Uma vez que o erro/perda foi quantificado, os pesos da rede são ajustados a fim de aprimorar as previsões e diminuir a perda. Isto é feito por meio do processo de *backpropagation* e otimização. O algoritmo de *backpropagation* calcula o gradiente do erro em relação a cada peso da rede e propaga o erro a partir da camada de saída até as camadas iniciais [48]. Basicamente, ele determina como cada peso contribuiu para o erro total.

Com os gradientes calculados, os pesos são ajustados na direção oposta ao gradiente, para reduzir o erro. Esse ajuste é controlado por uma taxa de aprendizado α que determina o tamanho dos passos dados na direção da minimização do erro. Este processo se repete por várias interações denominadas épocas até que a perda atinja o mínimo valor.

É importante ressaltar que os pesos do modelo devem ser ajustados com cautela para evitar um ajuste excessivo aos dados de treinamento, o que reduz sua capacidade de generalizar para dados inéditos. Este efeito, conhecido como *overfitting*, prejudica o desempenho do modelo em novos cenários.

3.2.2 Recurrent Neural Network

A RNN é uma classe de redes neurais projetada para lidar com dados sequenciais, onde a ordem das entradas é importante e as dependências temporais precisam ser capturadas. Ao contrário da CNN, que processa os dados de maneira sequencial, as RNNs possuem conexões cíclicas (Figura 3.4), o que permite a esta arquitetura manter uma memória interna de estados anteriores.




Figura 3.4: Ilustração da RNN comparado a *feedforward*. Fonte: [49]

3.2.2.1 Long Short-Term Memory (LSTM)

A LSTM é um tipo especializado de RNN projetada para lidar com sequências de dados e manter informações contextuais ao longo do tempo [50]. Estas redes possuem notória eficácia para tarefas como modelagem de séries temporais, tradução automática, reconhecimento de fala e processamento de linguagem natural, sendo capazes de lidar com sequências de comprimento variável e aprender representações abstratas e complexas.

Embora ofereçam excelentes resultados, principalmente em cenários com dados sequenciais complexos, as LSTMs são mais lentas para treinar e podem ter um custo computacional elevado devido ao grande número de parâmetros e complexidade no cálculo das portas.

A arquitetura da rede é composta de unidades chamadas células LSTM (Figura 3.5), que têm uma estrutura interna projetada para manter, esquecer ou atualizar informações

ao longo de seqüências temporais. Para uma melhor compreensão, a explicação será dividida nos seguintes tópicos: estados, *gates* e atualização de estados.




Figura 3.5: Ilustração da célula LSTM. Fonte: [51]

1. Estados da Célula e Estado Oculto

O Estado da Célula (c_t) é responsável por armazenar a informação ao longo do tempo. As informações do estado, a depender das condições dos *gates*, são esquecidas ou propagadas para outras células permitindo a rede capturar dependências de longo prazo. Já o Estado Oculto (h_t) representa a saída da célula em cada passo de tempo, que também serve como entrada para a próxima célula ou para a camada de saída.

2. Gates

Os *gates* são funções sigmoide que controlam quais informações devem ser esquecidas, armazenadas ou passadas para o próximo estado. Elas modulam o fluxo de informações dentro da célula. Existem 3 tipos de portas:

Porta de Esquecimento (f_t): Determina quais informações do estado da célula anterior (c_{t-1}) devem ser esquecidas. Isto é feito através de uma “máscara de esquecimento” (com valores entre 0 e 1, após a sigmoide), que é usada posteriormente para modificar o estado da célula. A máscara é calculada através da Equação 3.10:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.10)$$

onde W_f são os pesos, h_{t-1} é o estado oculto anterior, x_t é a entrada atual, b_f é o viés, e σ é a função sigmoide.

Porta de Entrada (i_t): Decide quais novas informações serão armazenadas no estado da célula e tem o valor de sua máscara dado pela Equação 3.11. O princípio de funcionamento desta máscara é semelhante ao da máscara da porta de esquecimento, mas com a diferença de que esta máscara indica quais dados serão armazenados no estado da célula.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.11)$$

Uma nova memória candidata (\tilde{c}_t), descrita pela Equação 3.12, é criada por meio da função tangente hiperbólica (\tanh). O termo (c_t) pode ser encarado como um espécie de *input* que traz novas informações derivadas da entrada atual (x_t) e do estado oculto anterior (h_{t-1}). Posteriormente a memória candidata será aplicada na máscara de entrada para determinar quais informações serão efetivamente adquiridas pela célula.

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.12)$$

Porta de Saída (o_t): Controla quais partes do estado da célula devem ser passadas adiantes como saída no estado oculto. Valendo-se do mesmo princípio das portas de esquecimento e entrada, a máscara da porta de saída pode ser calculada pela Equação 3.13:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.13)$$

Percebe-se portanto que, as portas de esquecimento e entrada são responsáveis por “filtrar” informações para atualizar o estado da célula. Já a porta de saída, filtra quais informações do estado atual da célula são repassadas ao estado oculto.

3. Atualização de Estados

O novo Estado da Célula c_t , calculado através da Equação 3.14, é uma combinação do estado anterior c_{t-1} (modulado pela porta de esquecimento f_t) e da nova memória candidata \tilde{c}_t (modulada pela porta de entrada i_t).

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (3.14)$$

O novo Estado Oculto h_t reflete tanto o estado interno da célula c_t quanto a decisão da porta de saída o_t , usando uma função não linear (tanh) descrita na Equação 3.15.

$$h_t = o_t \cdot \tanh(c_t) \quad (3.15)$$

3.3 Linguagem de Programação e IDE's

O código para o desenvolvimento da solução foi escrito em Python na plataforma Google Colab. Este ambiente foi escolhido para tirar proveito do armazenamento e processamento em nuvem. O treinamento dos modelos ANN são processos custosos do ponto de vista computacional. Com o Google Colab é possível realizar estes processos em servidores na rede da nuvem e não na máquina local, o que aumenta a capacidade de processamento e praticidade.

No que diz respeito aos *frameworks*, para manipulação e visualização de dados foram utilizados os pacotes `WFDB`, `Pandas` e `matplotlib`. Para o pré processamento dos dados e métricas de validação foi utilizado o `sklearn`. Para a arquitetura dos modelos utilizou-se o `TensorFlow`.

Capítulo 4

Desenvolvimento

Neste capítulo será apresentado os métodos utilizados para o desenvolvimento e testes da solução proposta. Será descrito como os materiais e métodos do Capítulo 3 foram empregados para a classificação dos sinais.

A proposta original do projeto refere-se a “implementação de sistemas de classificação baseados em aprendizagem profunda (Redes Convolucionais e Redes LSTM) no processo de classificação de sinais ECG. Serão usadas bases de dados de ECG públicas e classificadas previamente.” A classificação é proposta para **detecção de patologias** e a patologia selecionada foi a ICC.

4.1 Visão Geral

A solução da proposta está representada graficamente na Figura 4.1. De maneira geral, a solução pode ser dividida em 4 blocos:

- **Seleção dos Dados Públicos (PhysioNet):** Esta etapa consiste na escolha de bases de dados públicas com sinais de ECG previamente classificados por especialistas em saúde;
- **Construção do *Dataset* Customizado:** Após a seleção das bases de dados, é construído um *dataset* customizado que consolida os dados patológicos e de controle




Figura 4.1: Diagrama da Solução

em um único *dataset*;

- **Pré Processamento:** Os dados são pré-processados para preparar o *dataset* para o treinamento. Esta etapa inclui o ajuste da frequência de amostragem, normalização das amplitudes dos sinais de ECG e das idades dos pacientes, bem como a divisão do *dataset* em conjuntos de treinamento e teste;
- **Desenvolvimento e Classificação dos Modelos:** São detalhadas as arquiteturas dos modelos LSTM e CNN utilizados para a classificação dos sinais de ECG. É descrito como os dados passam pelo processo de treinamento e classificação em cada modelo, possibilitando a uma posterior comparação de seus desempenhos.

4.2 Construção do *Dataset* Customizado

O *dataset* customizado foi construído utilizando dados da BIDMC Congestive Heart Failure Database e PTB Diagnostic ECG Database descritas na Seção 3.1. A decisão de criar uma base de dados customizada foi baseada nas seguintes premissas:

- A BIDMC Congestive Heart Failure Database, identificada pelo autor como a base de dados mais robusta para ICC, não possui sinais de controle (ECG não patológico);
- A PTB Diagnostic ECG Database não possui sinais rotulados como “Insuficiência Cardíaca Congestiva”. A classificação é “Cardiomiopatia/Insuficiência Cardíaca”, sem possibilidade de distinção entre as duas classes.

Estas características foram determinantes para criação do *dataset* em questão. Além disso, outras vantagens foram identificadas:

- **Balanceamento:** Os sinais de ECG variam de maneira significativa de acordo com a idade e gênero da pessoa [52]. Com um *dataset* customizado, é possível escolher sinais de controle que sejam equivalentes em termos de idade e gênero aos sinais patológicos. Esta prática permite balancear os dados de entrada da rede e diminuir o risco de enviesar o treinamento;

- **Seleção:** É possível verificar alguns requisitos do ECG antes de incorporá-lo ao *dataset*. Descontinuidade, razão sinal ruído elevada são exemplos de características que podem desqualificar o sinal para o treinamento, especialmente neste trabalho em que os sinais brutos são a entrada da rede, sem extração de características;
- **Dimensionalidade:** Com um *dataset* customizado é possível definir a extensão e dimensionalidade das entradas. Por exemplo, é possível particionar um sinal de muitas horas em pequenas partições de segundos. Esta prática aumenta o volume de dados e facilita a detecção de características;
- **Taxa de amostragem:** Os dados públicos utilizados neste trabalho possuem diferentes taxas de amostragem. Os sinais de ECG patológicos, provenientes da BIDMC Congestive Heart Failure Database, possuem uma taxa de amostragem de 250 Hz. Por sua vez, os sinais de controle da PTB Diagnostic ECG Database possuem uma taxa de amostragem de 1 KHz. Com o *dataset* proposto, é possível ajustar a taxa de amostragem a um mesmo valor para todos os sinais.

Ao todo, o *dataset* proposto é constituído por dados de 28 indivíduos: 14 diagnosticados com ICC, provenientes do banco de dados BIDMC (Tabela 4.1), e 14 indivíduos para controle extraídos da base PTB (Tabela 4.2).

Como descrito na Subseção 3.1.1, a BIDMC possui dados de 15 indivíduos, no entanto, não foi possível utilizar os dados de um destes indivíduos devido a ausência da informação de idade. Portanto, assim que se chegou ao número de 14 indivíduos.

A Subseção 3.1.2 indica que a PTB conta com 52 indivíduos para sinais de controle. Destes 52, foram selecionadas manualmente 14 indivíduos que correspondem, em termos de idade e género, aos indivíduos patológicos provenientes da BIDMC. Este processo de pareamento garante que, para cada sinal com ICC, haja um sinal de ECG saudável correspondente com as mesmas características fisiológicas. As correspondências detalhadas entre os sinais patológicos e os de controle estão apresentadas na Tabela 4.3.

Uma vez definidos os dados dos indivíduos a serem utilizados, a extração das informações dos arquivos *.ecg*, que contêm a amplitude das amostras ao longo do tempo,

BIDMC Congestive Heart Failure Database						
Nome	Idade	género	Amostragem	Nº de Amostras	Duração	Classificação
chf01	71	Homem	250 Hz	17994491	19h:59m:37s	ICC
chf02	61	Mulher	250 Hz	17793024	19h:46m:12s	ICC
chf03	63	Homem	250 Hz	17998848	19h:59m:55s	ICC
chf04	54	Homem	250 Hz	17998848	19h:59m:55s	ICC
chf05	59	Mulher	250 Hz	17802240	19h:46m:48s	ICC
chf07	48	Homem	250 Hz	17998848	19h:59m:55s	ICC
chf08	51	Homem	250 Hz	17998848	19h:59m:55s	ICC
chf09	63	Mulher	250 Hz	17796577	19h:46m:26s	ICC
chf10	22	Homem	250 Hz	17995711	19h:59m:42s	ICC
chf11	54	Mulher	250 Hz	17998848	19h:59m:55s	ICC
chf12	61	Homem	250 Hz	17842176	19h:49m:28s	ICC
chf13	63	Homem	250 Hz	17996694	19h:59m:46s	ICC
chf14	61	Homem	250 Hz	17998848	19h:59m:55s	ICC
chf15	53	Homem	250 Hz	17993443	19h:59m:33s	ICC

Tabela 4.1: Dados dos sinais de ECG coletados de indivíduos diagnosticados com ICC, obtidos a partir da BIDMC Congestive Heart Failure Database.

PTB Diagnostic ECG Database						
Nome	Idade	género	Amostragem	Nº de Amostras	Duração	Classificação
117/s0291lre	37	Homem	1 KHz	115200	01m:55s	Controle
121/s0311lre	69	Mulher	1 KHz	115200	01m:55s	Controle
122/s0312lre	68	Homem	1 KHz	115200	01m:55s	Controle
131/s0273lre	26	Homem	1 KHz	115200	01m:55s	Controle
172/s0304lre	50	Homem	1 KHz	115200	01m:55s	Controle
173/s0305lre	57	Mulher	1 KHz	115200	01m:55s	Controle
229/s0452_re	55	Homem	1 KHz	120012	02m:00s	Controle
239/s0467_re	59	Homem	1 KHz	120012	02m:00s	Controle
243/s0472_re	52	Mulher	1 KHz	120012	02m:00s	Controle
246/s0478_re	54	Homem	1 KHz	120012	02m:00s	Controle
248/s0481_re	64	Homem	1 KHz	120012	02m:00s	Controle
252/s0487_re	54	Homem	1 KHz	120012	02m:00s	Controle
266/s0502_re	68	Homem	1 KHz	120012	02m:00s	Controle
267/s0504_re	67	Mulher	1 KHz	120012	02m:00s	Controle

Tabela 4.2: Dados dos sinais de ECG coletados de indivíduos saudáveis, extraídos da PTB Diagnostic ECG Database.

Pares Baseados em género e Idade				
Nome (ICC)	Nome (Controle)	Idade (ICC)	Idade (Controle)	género
chf01	122/s0312lre	71	68	Homem
chf02	267/s0504_re	61	67	Mulher
chf03	248/s0481_re	63	64	Homem
chf04	252/s0487_re	54	54	Homem
chf05	173/s0305lre	59	57	Mulher
chf07	117/s0291lre	48	37	Homem
chf08	172/s0304lre	51	50	Homem
chf09	121/s0311lre	63	69	Mulher
chf10	131/s0273lre	22	26	Homem
chf11	246/s0478_re	54	54	Mulher
chf12	239/s0467_re	61	59	Homem
chf13	266/s0502_re	63	68	Homem
chf14	243/s0472_re	61	52	Mulher
chf15	229/s0452_re	53	55	Homem

Tabela 4.3: Pares patológicos e de controle formados com base em género e faixa etária.

foi realizada na plataforma Google Colab utilizando o comando `wfdb.rdsamp` do pacote WaveForm Data Base (WFDB) para Python. Este comando retorna todo o conteúdo do arquivo `.ecg`, incluindo as derivações do sinal quando disponíveis. Além disso, as informações de género e idade foram extraídas dos arquivos `.hea`. Com os dados extraídos desta maneira, é possível manipulá-los de acordo com as necessidades específicas da análise.

4.2.1 Seleção de Amostras a partir dos Sinais de ECG

Os sinais ECG dos 28 indivíduos selecionados foram particionados em 840 amostras (cada indivíduo contribuiu com 30 amostras com duração de 3 segundos cada), 420 patológicos e 420 de controle. O Apêndice A mostra as tabelas que representam as 840 amostras. Todas as amostras contém exclusivamente o sinal de ECG considerando o *lead 1*.

A opção por sinais de curta duração se dá a partir das seguintes razões:

- **Detecção em único ciclo ECG:** A Subseção 1.2.1 nos mostra que o complexo QRS, ondas P, T e os segmentos PR e ST, fornecem os indícios para a detecção de

ICC. Portanto, sinais que tenham pelo menos um ciclo são elegíveis para classificação, o que elimina a necessidade de uma amostra de longa duração;

- **Justificação Científica:** Diversos trabalhos correlacionados utilizam a mesma abordagem e concluem que amostras de curta duração apresentam os melhores resultados. O trabalho [53] utiliza CNN para a classificação de diferentes tipos de taquicardia. São utilizados segmentos de ECG com 2 e 5 segundos e o modelo forneceu uma acurácia de 92,5% e 94,9%, respectivamente. No artigo [54] é proposta a classificação de *heartbeats* centralizadas no pico R. A acurácia girou em torno de 94.03% e 89.07% para diferentes níveis de ruído e pré processamento. Para o LSTM, a investigação feita por [55] também utiliza amostras com cerca de 0,8 segundos.

Portanto, esta abordagem com amostras de curta duração, que contenham de 1 até 3 ou 4 ciclos, apresenta-se como uma alternativa promissora para a arquitetura do *dataset*. É importante ressaltar que esta abordagem é válida para o caso da ICC. Para outras patologias, como arritmias, que requerem a análise do sinal ao longo de períodos prolongados, amostras de curta duração podem não ser a melhor estratégia.

Adicionalmente, outros fatores foram considerados para definir a duração da amostra:

- **Aumento do Conjunto de Dados:** Ao dividir os 28 sinais em 840 amostras de menor duração, o número de amostras aumenta significativamente e ajuda o modelo a generalizar de forma mais eficiente;
- **Homogeneidade:** A escolha de uma duração fixa para os todos os sinais trás homogeneidade as entradas da rede, aspecto fundamental para extrair características durante o treinamento, uma vez que todos as amostras devem ter a mesma duração para o modelo proposto;
- **Representatividade:** É possível selecionar amostras de modo que fiquem mais “representativos”. Isto é, é possível extrair amostras de partes completamente diferentes do sinal original. Esta característica é válida para os sinais da BIDMC que possuem cerca de 20 horas.

No que diz respeito a quantidade de 840 amostras, a limitação se dá por conta de dois fatores principais: curta duração dos sinais de controle da PTB e o critério de equivalência em género e faixa etária entre as amostras patológicas e de controle.

Para a classe patológica, a BIDMC fornece sinais de ECG com duração média de 20 horas, mas são apenas de 14 indivíduos. Já para as amostras de controle, a PTB fornece sinais de ECG de 52 indivíduos mas com duração de 2 minutos em média. Estas características resultam na seguinte situação: não é possível ampliar o número de amostras sem abrir mão do critério de paridade de género e faixa etária entre as classes, uma vez que a PTB possui todos os indivíduos necessários para balancear (em termos de género e faixa etária) as classes patológica e de controle.

Como tentativa de contornar este problema, foi estudada a possibilidade de substituir os dados de controle da PTB por dados de uma outra base de dados que permitisse ampliar as amostras, respeitando as premissas de género e faixa etária entre as duas classes. Infelizmente, não foi identificada uma única base de dados que cumprisse os seguintes requisitos ao mesmo tempo:

- Gravações de longa duração (ao menos com duração superior a PTB);
- 14 sinais equivalentes em género e idade a base BIDMC;
- Sinais utilizáveis (sem longas descontinuidades e com baixa razão sinal ruído).
- Classificação realizada por médico/profissional da saúde.
- Base de dados pública e/ou acessível.

Naturalmente, diversas bases de dados possuíam pelo menos uma ou mais destas características. No entanto, como supracitado, nenhuma cumpriu com todos os requisitos ao mesmo tempo. Sendo assim, optou-se por não misturar sinais de diferentes bases numa mesma classe devido a seguinte circunstâncias:

- Padronização da amostragem para cada sinal;

- Necessidade de filtros personalizados;
- Diferentes resoluções na captura do ECG.

Considerando estas questões, a base de dados da PTB se apresentou como a melhor solução. Ela cumpre com todos os requisitos estabelecidos e fornece a razoável quantidade de 420 sinais de controle balanceados em gênero e faixa etária com a classe patológica.

4.2.1.1 Verificação dos Sinais ECG Elegíveis Para se Tornarem Amostras

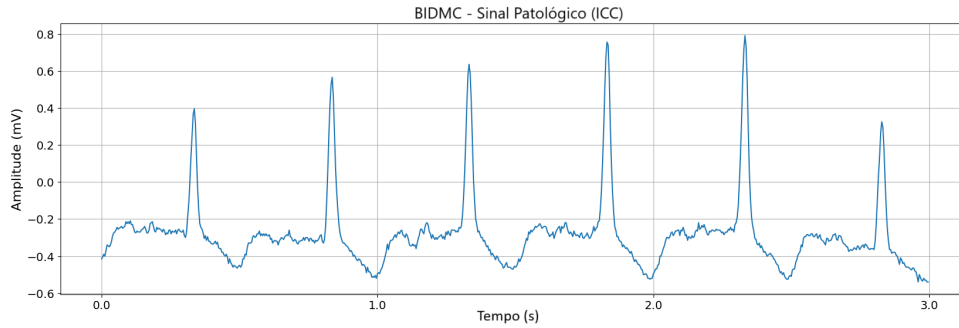
Para definir quais intervalos do sinal seriam utilizados como amostras, foi realizada uma inspeção visual dos sinais de ECG, classificando-se como elegíveis os intervalos contínuos e com baixa razão sinal ruído. A inspeção manual foi adotada como uma verificação adicional, pois além de descontinuidades e ruídos, pode ocorrer que algum eletrodo esteja mal posicionado ou com polaridade invertida durante a gravação, comprometendo a fidelidade do sinal.

O processo de verificação foi feito de maneira visual através do *plot* gerado pela biblioteca `matplotlib` para Python. A inspeção dos sinais de ECG provenientes da base de dados PTB foi relativamente tranquila, uma vez que os sinais têm curta duração e baixo nível de ruído. Em contrapartida, os sinais provenientes da BIDMC possuem 20 horas de gravação contínua, o que tornou o processo de seleção das faixas utilizáveis mais trabalhoso.

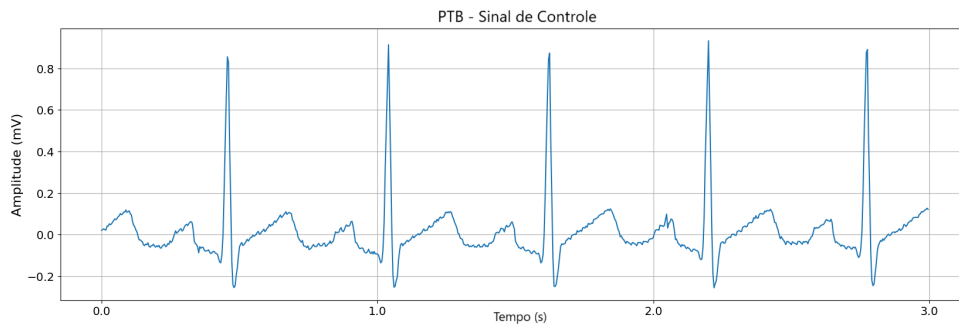
A Figura 4.2 representa graficamente de um par de amostras (uma patológica e outra de controle) selecionadas sob os critérios estabelecidos.

4.3 Pré Processamento

Com as amostras devidamente selecionadas e armazenadas no formato *dataframe*, podemos começar a etapa de pré processamento. Ao analisar as Tabelas 4.1 e 4.2, é possível constatar a diferença da taxa de amostragem entre as duas classes. A classe patológica possui uma taxa de amostragem de 250 Hz e a classe de controle tem uma taxa de amostragem de 1 KHz.



(a) Amostra de ECG patológica proveniente da BIDMC.



(b) Amostra de ECG de controle proveniente da PTB.

Figura 4.2: Comparação entre uma amostra de ECG patológica e uma saudável: (a) sinal de ECG de um paciente com ICC e (b) sinal de ECG de um controle saudável.

4.3.1 Corrigindo a Amostragem

Para resolver a questão da amostragem, foi aplicado um *undersampling* de 4 nas amostras da classe de controle, uniformizando todas as amostras de ambas as classes a uma taxa de 250 Hz. A decisão de realizar *undersampling* nas amostras de 1 KHz ao invés de realizar o *oversampling* nas amostras de 250 Hz foi baseada no custo computacional associado ao treinamento dos sinais de ECG com a taxa de amostragem de 1 KHz e, principalmente, no Teorema de Nyquist (Equação 4.1). Este teorema diz que “Para reconstruir um sinal analógico contínuo a partir de suas amostras digitais sem perda de informação, a taxa de amostragem (f_s) deve ser pelo menos o dobro da maior frequência (f_{max}) presente no sinal” [56].

$$f_s \geq 2f_{max} \quad (4.1)$$

De acordo com [57] e [58], a faixa de amostragem ideal para sinais de ECG está entre 250 e 500 Hz, o que representa a menor taxa possível para preservar todas as características fundamentais do sinal. Assim, considerando essa faixa e o custo computacional do treinamento com altas taxas de amostragem, optou-se por 250 Hz.

4.3.2 Normalização

Os dados de ECG podem apresentar diversas variações, sejam decorrentes de características fisiológicas, sejam resultantes do processo de aquisição. O uso de sinais de ECG provenientes de duas bases de dados distintas pode introduzir variações que enviesam o modelo. Além disso, como as amplitudes do sinal variam conforme as condições fisiológicas e a presença de patologias, o processo de normalização torna-se essencial.

Além das características associadas ao ECG, a normalização dos dados introduz características de forma uniforme, auxiliando os modelos — especialmente aqueles com pesos ajustados por gradiente — a convergirem mais rapidamente. Dados normalizados também reduzem a probabilidade de *overfitting* e facilitam a comparação entre diferentes modelos.

O método utilizado foi a normalização Min-Max. O cálculo para normalização das amplitudes do ECG através deste método é dado pela Equação 4.2, onde X_{norm} representa o valor normalizado, X é o valor a ser normalizado, X_{min} é o valor de amplitude mínima dos dados originais e X_{max} é o valor de amplitude máxima dos dados originais.

$$X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (4.2)$$

O resultado gerado por esta equação é um número entre 0 e 1 proporcional a amplitude original do sinal ECG. Ou seja, o número 0 corresponde ao menor valor de amplitude do ECG no *dataset* e 1 corresponde ao maior valor. As demais amplitudes tem valores maiores que 0 e menores que 1 proporcionais ao seu valor original.

4.3.3 Estrutura Final

Com as amostras selecionados e devidamente normalizadas, é preciso estruturar os dados para que eles sejam processados de maneira correta na entrada do modelo. Os dados foram organizados da seguinte forma:

- 1 estrutura tridimensional com formato (840, 750, 1): Esta é a estrutura que carrega os valores de amplitude do ECG. São 840 amostras, 750 passos de tempo (3 segundos) e 1 canal;
- 1 estrutura bidimensional com formato (840, 1): Esta é a estrutura que carrega os *labels* de cada um dos 840 sinais. O número 0 é o *label* de uma amostra de controle e o número 1 representa uma amostra patológica de ICC;
- 1 estrutura bidimensional com formato (840, 2): Esta estrutura carrega a idade e o gênero de cada uma das amostras. O número 0 corresponde a uma amostra de um indivíduo do sexo masculino e o número 1 corresponde a uma amostra do sexo feminino. Os dados de idade passaram por processo de normalização.

É fundamental destacar que o índice de cada amostra é consistente em todas as estruturas. Ou seja, cada amostra possui um único índice, e a ordem desses índices é rigorosamente mantida para evitar a mistura dos dados.

4.3.4 Repartição - Treino e Teste

O *dataset* foi dividido em 80% para treinamento e 20% para teste, valores considerados padrão para redes neurais. Como o *dataset* está organizado em três estruturas independentes, utilizou-se a função `train_test_split` do pacote `scikit-learn` para gerar índices aleatórios de treino e teste. Com esses índices, foram criadas novas estruturas para treinamento e teste, onde cada uma dessas estruturas contém os dados correspondentes do *dataset* original, conforme os índices atribuídos.

A Figura 4.3 ilustra a divisão do *dataset*. Observe que, dentro do conjunto de treinamento, os dados são divididos novamente durante o processo de treinamento para permitir

a validação do modelo. O conjunto de dados final foi dividido em 80% para treinamento e 20% para teste, com 20% do conjunto de treinamento alocados para validação.




Figura 4.3: Representação das repartições do *dataset*. Fonte: [59]

4.4 Arquitetura LSTM

A estrutura principal da rede (Figura 4.4) é composta por três camadas LSTM bidirecionais, com 100 células LSTM em cada direção. As camadas LSTM bidirecionais processam a sequência de dados tanto no sentido direto quanto no reverso, permitindo que a rede capte tanto dependências passadas quanto futuras no sinal de ECG.

A primeira camada aplica 100 unidades LSTM em ambos os sentidos, retornando sequências completas para a próxima camada. A segunda camada repete a mesma estrutura da primeira e, por fim, a terceira camada processa a sequência final e retorna um vetor de saída que concentra toda a informação temporal relevante em um único vetor.

Entre cada uma das camadas LSTM, uma camada *Dropout* com uma taxa de 30% é aplicada. O objetivo do *dropout* é prevenir o *overfitting* durante o treinamento, “desligando” aleatoriamente 30% das unidades, o que força a rede a generalizar melhor os dados.

```

# 3 Camadas LSTM bidirecionais com 100 células em cada direção.
x = Bidirectional(LSTM(100, return_sequences=True))(input_ecg)
x = Dropout(0.3)(x)
x = Bidirectional(LSTM(100, return_sequences=True))(x)
x = Dropout(0.3)(x)
x = Bidirectional(LSTM(100))(x)
x = Dropout(0.3)(x)

# Concatenação do vetor X gerado na camada recorrente com gênero e idade.
x = Concatenate()([x, input_features])

# Camada densa com ativação sigmóide para classificação binária.
output = Dense(2, activation='sigmoid')(x)

```

Figura 4.4: Código fonte da arquitetura LSTM

É importante reforçar que as camadas LSTM **processam somente as amplitudes do ECG com relação ao tempo**. Após o processamento das amplitudes nas camadas recorrentes, é feita a concatenação das informações de idade e gênero de cada um dos indivíduos para que as características fisiológicas dos pacientes sejam associadas ao vetor de características temporais. Esta operação pode ser verificada na Figura 4.4 através do comando `Concatenate`.

O vetor resultante da concatenação é passado para uma camada densa com duas unidades e ativação *sigmoide*. Esta camada é responsável pela classificação final e retorna a probabilidade de uma determinada amostra pertencer a classe patológica ou não patológica. O limiar indica qual a probabilidade necessária para uma amostra ser considerada como patológica ou não patológica e, para esta arquitetura, foi considerado o valor de 0,5. Isto é, se uma amostra foi classificada com uma probabilidade maior que 50% de pertencer a uma determinada classe, a saída considera a amostra como realmente pertencente a esta classe em questão.

A função de perda `binary_crossentropy` foi utilizada para calcular o erro entre as previsões e os rótulos reais. Esta função foi selecionada pois é projetada especialmente para problemas de classificação binária. Foi escolhida a validação simples (não cruzada, por conta dos recursos computacionais) feita com 20% dos dados de treinamento. O

algoritmo de treino selecionado foi o Adaptive Moment Estimation (Adam) pois apresenta uma alta eficácia na correção dos pesos considerando o custo computacional.

O *batch size* selecionado foi de 256. Este valor foi escolhido após um treinamento individual para os valores de 32, 64, 128 e 256. A escolha do valor de 256 se deu pela excessiva oscilação de aprendizado do modelo para os valores de 32, 64 e 128.

Foram selecionadas 150 épocas para o treinamento e o critério de parada (*early stop*) foi configurado com uma paciência de 30 épocas considerando o valor da perda. Em suma, após 30 épocas sem progresso no aprendizado do modelo (quantificado pelo valor de perda em cada época), o treinamento é interrompido.

Considerando a chance do modelo aumentar o valor da perda nas 30 últimas épocas, isto é, piorar antes de ser interrompido, foi adicionado o *callback* `ModelCheckpoint`. A configuração deste *callback* com o parâmetro `save_best_only=True` salva o modelo com a menor perda observada durante todo o treinamento. Isto garante que a melhor versão do modelo é guardada.

4.5 Arquitetura CNN 1D

A estrutura principal da CNN consiste em 3 camadas convolucionais de uma dimensão (1D) que processam as amplitudes do ECG pelo tempo. A Figura 4.5 mostra o código da arquitetura da rede.

A primeira camada convolucional aplica 64 filtros, cada um com um tamanho de kernel de 3 unidades, utilizando a função de ativação `ReLU`. O kernel, que é uma matriz de pesos, desliza sobre o sinal de ECG, realizando multiplicações ponto a ponto com a parte do sinal que está sob ele. O tamanho de 3 unidades foi escolhido para aumentar a capacidade do modelo em extrair características locais entre valores consecutivos. Isto permite que as camadas subsequentes combinem os padrões dos valores consecutivos em características mais abstratas.

A função de ativação `ReLU`, definida na Equação 3.6, transforma valores negativos em zero e mantém valores positivos inalterados. Sua importância reside na capacidade

```

# Primeira Camada Convolutcional
x = Conv1D(filters=64, kernel_size=3, activation='relu')(input_ecg)
x = MaxPooling1D(pool_size=2)(x)
x = Dropout(0.3)(x)
# Segunda Camada Convolutcional
x = Conv1D(filters=128, kernel_size=3, activation='relu')(x)
x = MaxPooling1D(pool_size=2)(x)
x = Dropout(0.3)(x)
# Terceira Camada Convolutcional
x = Conv1D(filters=256, kernel_size=3, activation='relu')(x)
x = MaxPooling1D(pool_size=2)(x)
x = Dropout(0.3)(x)
# Operação de vetorização Flatten
x = Flatten()(x)

# Concatenação do vetor X gerado pelas camadas convolutcionais com os valores de idade e gênero.
x = Concatenate()([x, input_features])

# Camada densa com ativação sigmóide para classificação binária.
output = Dense(2, activation='sigmoid')(x)

```

Figura 4.5: Código fonte da arquitetura CNN-1D

de introduzir não linearidade nas redes neurais, o que é essencial para que os modelos aprendam representações complexas dos dados. Além disso, a ReLU é computacionalmente eficiente e ajuda a mitigar o problema do desaparecimento do gradiente, que pode ocorrer com outras funções de ativação, permitindo assim que as redes neurais aprendam de forma mais rápida e eficaz.

Logo após a operação convolutcional, é aplicado o *MaxPooling* com um tamanho de *pool* igual a 2, o que permite reduzir a dimensionalidade dos dados, retendo apenas as características mais relevantes. A operação de *MaxPooling* consiste em dividir a entrada em regiões menores e selecionar o valor máximo de cada uma delas, contribuindo para a extração das características mais significativas e a diminuição da complexidade computacional.

Antes de prosseguir para a segunda camada convolutcional, é realizado um *dropout* de 30% das unidades, ajudando a prevenir o *overfitting*. No contexto da rede convolutcional, o *dropout* consiste em atribuir um valor de 0 a 30% dos resultados obtidos até então, promovendo a generalização do modelo ao reduzir a dependência entre as unidades.

A segunda camada convolutcional possui a mesma estrutura da primeira, com a única

diferença de que são aplicados 128 filtros em vez dos 64 utilizados anteriormente. O *Max-Pooling* permanece com um tamanho de *pool* igual a 2, o que significa que essa operação seleciona o maior valor entre dois valores, armazenando apenas as características mais proeminentes do sinal. O *dropout* é mantido em 30%, ajudando a prevenir o *overfitting*.

Por fim, a terceira camada convolucional mantém a mesma estrutura das camadas anteriores, com a exceção do número de filtros, que agora é de 256. Essa alteração possibilita uma extração ainda mais rica e detalhada das características dos sinais de ECG, construindo sobre as abstrações já desenvolvidas nas camadas anteriores e refinando a capacidade da rede de identificar padrões significativos nos dados.

A Figura 4.6 representa as operações realizadas e a dimensão dos dados após cada uma delas.




Figura 4.6: Representação das dimensões e operações da CNN-1D

A representação é feita da esquerda para a direita e começa com uma amostra sendo aplicada na primeira operação convolucional 1D de 64 filtros. A amostra, que possui 750 passos de tempo, após passar pelos 64 filtros, fica com uma dimensão de 64 por 748. O sinal “perde” dois passos de tempo devido ao tamanho do *kernel*, que processa 3 passos de tempo na operação convolucional. Em outras palavras, é feita uma convolução com os passos de tempo 1, 2 e 3; posteriormente com os passos 2, 3, 4 e assim por diante até chegar aos passos 748, 749, 750 totalizando 748 resultados da convolução.

A Equação 4.3 (genérica) fornece a quantidade de dados que se obtêm após uma operação de convolução. A Equação 4.4 demonstra a quantidade de dados gerados por

cada um dos 64 filtros na convolução da primeira camada. O `stride`, que determina o número de valores da sequência que o filtro deve pular antes de aplicar uma nova convolução, é definido como 1 neste trabalho.

$$\text{Saída} = \frac{\text{Entrada} - \text{tamanho do filtro}}{\text{stride}} + 1 \quad (4.3)$$

$$\text{Saída} = \frac{750 - 3}{1} + 1 = \frac{747}{1} + 1 = 748 \quad (4.4)$$

Após passar pelas três camadas convolucionais, a saída é achatada por meio da camada `Flatten`, que converte a estrutura em uma representação unidimensional, preparando-a para a entrada em uma camada densa. Com o vetor de características formado, os valores de idade e gênero associados ao sinal que gerou esse vetor são concatenados a ele. Por fim, essa combinação serve como entrada para a camada densa, que utiliza a função de ativação sigmoide para realizar a classificação binária, determinando se o sinal é considerado patológico ou não.

Assim como na arquitetura LSTM, foi utilizado o algoritmo de treino Adam, juntamente com a função de perda `binary_crossentropy`. O tamanho do lote (*batch size*) foi definido como 256, e o treinamento foi realizado por 150 épocas, com uma estratégia de paciência de 30 épocas para evitar o sobreajuste. Além disso, foi implementado o `ModelCheckpoint` para salvar a melhor versão do modelo, garantindo que a versão final retenha a melhor performance alcançada durante o treinamento.

Capítulo 5

Resultados e Discussões

Neste capítulo, são apresentados e discutidos os resultados dos modelos LSTM e CNN para a classificação binária de sinais de ECG. O objetivo desta seção é avaliar o desempenho dos modelos propostos, destacando sua capacidade de generalização, precisão e limitações na distinção entre as classes. Também são comparados os desempenhos das arquiteturas LSTM e CNN, levando em consideração métricas como acurácia, sensibilidade, especificidade, precisão e F1-Score, bem como o impacto do pré-processamento dos dados e da escolha de hiperparâmetros nos resultados obtidos.

A análise dos resultados inclui considerações sobre os erros de classificação e os sinais que apresentaram maior dificuldade para os modelos. Esse aprofundamento busca fornecer uma visão das condições em que os modelos podem falhar, além de explorar possíveis melhorias na arquitetura e nos parâmetros de treinamento. Por fim, os métodos e resultados são comparados com os trabalhos do estado da arte, ressaltando a contribuição deste trabalho e a visão do autor sobre as abordagens mais eficazes para a classificação.

5.1 Métricas de Avaliação

As métricas de avaliação para comparar as classificações geradas pelos modelos serão a perda (utilizando o erro médio relativo, MRE), acurácia, sensibilidade, especificidade, precisão e F1-Score. A perda MRE indica o erro médio relativo entre as previsões e os

valores reais, quanto menor o erro, melhores são as previsões. A acurácia, por sua vez, fornece a proporção de previsões corretas entre todas as previsões feitas, oferecendo uma visão geral da performance dos modelos.

O valor do MRE é dado pela Equação 5.1, onde y_i é o valor real (ou alvo) para a amostra i . O valor \hat{y}_i é o valor predito pela rede neural para a amostra i e o N é o número total de amostras no conjunto de dados.

$$\text{MRE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \quad (5.1)$$

Para que seja possível avaliar a performance do modelo entre as classes, é contemplado também as métricas de avaliação sensibilidade e especificidade, que medem a capacidade do modelo para identificar corretamente as instâncias positivas e negativas, respectivamente.

Será considerado também a precisão, que representa a proporção de previsões positivas que realmente são positivas (considerando ambas as classes). Por fim, o F1-Score fornecerá uma média harmônica entre precisão e sensibilidade, equilibrando a exatidão das previsões e a abrangência dos verdadeiros positivos. Combinadas, essas métricas ajudam a entender os pontos fortes e limitações dos modelos.

5.2 LSTM

O modelo LSTM, embora apresente resultados sólidos, obteve desempenho inferior ao modelo CNN considerando a classificação dos dados do conjunto de teste. Ele apresentou uma perda de 0,2367 e uma acurácia de 92,26%. A sensibilidade do modelo foi de 92,21%, indicando que detectou 92,21% dos casos patológicos, um valor 3,89% menor em comparação com o CNN. A especificidade foi de 92,31%, enquanto a precisão atingiu 91,03%, e o F1-score foi de 0,9161, sugerindo um comprometimento mais acentuado entre sensibilidade e precisão em relação ao CNN.

A matriz de confusão do modelo LSTM (Figura 5.1) revela uma maior incidência de

falsos negativos em comparação com o CNN. Das 91 amostras da classe de controle, 84 foram corretamente classificadas, com um número de 7 falsos positivos. Nas 77 amostras da classe patológica, 71 foram corretamente identificadas, enquanto 6 foram incorretamente classificadas como controle.




Figura 5.1: Matriz de Confusão para o modelo LSTM

5.3 CNN 1D

Considerando a classificação dos dados do conjunto de teste, o modelo CNN obteve o melhor desempenho, com uma acurácia de 98,21% e perda de 0,0977. A sensibilidade do modelo foi de 96,10%, indicando que identificou corretamente 96,10% dos casos patológicos. Demonstrou especificidade perfeita (100%), o que significa que classificou corretamente todos os casos não patológicos. A precisão também foi de 100%, destacando que todas as instâncias previstas como patológicas estavam corretas. O F1-score, que equilibra precisão e sensibilidade, atingiu 0,9801, o que mostra a capacidade do modelo de manter alta precisão e sensibilidade.

A matriz de confusão do modelo de CNN é apresentada na Figura 5.2. Dos 91 casos não patológicos, todos foram corretamente classificados, sem falsos positivos. Por outro lado, dos 77 casos patológicos, 74 foram corretamente classificados, e apenas três foram mal classificados, resultando em uma taxa de falsos negativos baixa.




Figura 5.2: Matriz de Confusão para o modelo CNN

A Tabela 5.1 apresenta uma comparação abrangente entre os principais parâmetros de desempenho de cada uma das redes, destacando as diferenças em métricas como acurácia, sensibilidade, especificidade, precisão, F1-Score e a taxa de perda. Essa comparação facilita a análise detalhada do comportamento de cada modelo e ajuda a identificar quais características influenciam mais na classificação dos sinais de ECG.

Por fim, a Figura 5.3 apresenta a comparação dos valores de perda dos modelos LSTM e CNN ao longo das épocas de treinamento. Observa-se que a CNN apresenta uma maior estabilidade na previsão e generalização dos dados, com valores de perda constantemente menores ao longo do treinamento. Em contrapartida, o modelo LSTM demonstra uma

Métrica	CNN 1D	LSTM
Perda	0,0977	0,2367
Acurácia (%)	98,21%	92,26%
Sensibilidade (%)	96,10%	92,21%
Especificidade (%)	100%	92,31%
Precisão (%)	100%	91,03%
F1-Score	0,9801	0,9161
Verdadeiros Positivos (VP)	74	71
Falsos Negativos (FN)	3	6
Verdadeiros Negativos (VN)	91	84
Falsos Positivos (FP)	0	7

Tabela 5.1: Comparação das métricas de performance entre os modelos LSTM e CNN

variabilidade significativamente maior e uma menor capacidade de convergir para uma perda próxima de zero, refletindo desafios em alcançar uma generalização consistente.

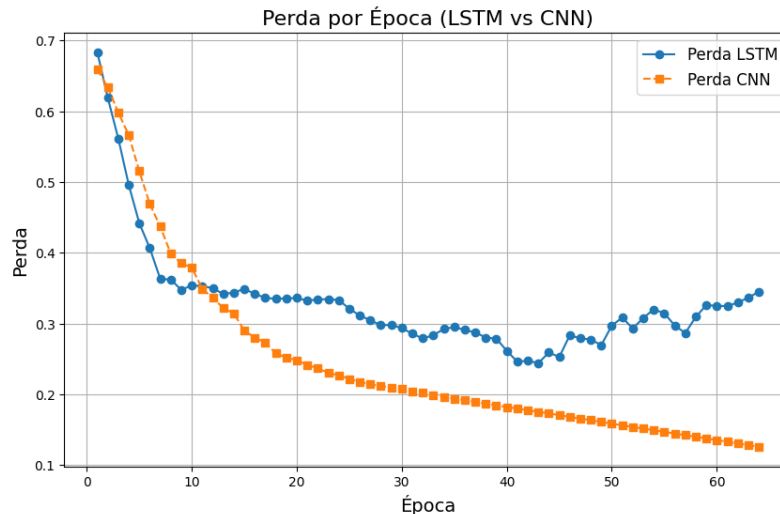


Figura 5.3: Comparação dos valores de perda por época para os modelos LSTM e CNN

5.4 Comparação Estado da Arte

A Tabela 5.2 compara os resultados desta investigação com os de trabalhos semelhantes da literatura, com foco em modelos de deep learning para a classificação de ICC.

Como mostrado na Tabela 5.2, o modelo CNN proposto alcançou uma acurácia de

Método	Acur.	Sens.	Espec.	Prec.	F1 Score
Proposed CNN	98.21%	96.10%	100.00%	100.00%	0.9801
Proposed LSTM	92.26%	92.21%	92.31%	91.03%	0.9161
[34] (CNN+LSTM)	99.52%	99.31%	99.28%	-	0.9894
[35] (Wavelet + LSTM)	99.86%	99.85%	99.85%	99.87%	0.9986
[36] (Gabor + CNN)	98.74%	-	-	-	-
[37] (CNN + CQ-NGST)	98.82%	98,87%	99,21%	99,20%	-
[38] (CNN)	97.80%	-	-	-	-
[39] (BURG + Random Forest)	100%	-	-	-	-

Tabela 5.2: Comparação dos resultados com os métodos do estado da arte para a classificação de ICC

98,21%, o que é comparável a outros métodos de estado da arte, como [36], com 98,74%, e [38], com 97,80%. No entanto, a sensibilidade do nosso modelo CNN (96,10%) é ligeiramente inferior aos 99,31% reportados em [34], mas demonstra uma excelente especificidade e precisão de 100,00%. O modelo LSTM em nosso trabalho alcançou uma acurácia de 92,26%, que é inferior aos modelos baseados em LSTM de [35], mas ainda assim demonstra uma especificidade razoável (92,31%) e precisão (91,03%).

Os resultados indicam que, enquanto nosso modelo baseado em CNN apresenta um desempenho competitivo, especialmente em especificidade e precisão, o modelo LSTM poderia se beneficiar de uma otimização adicional. Comparado a [35], onde vários modelos LSTM foram treinados e ajustados, uma maior afinação de hiperparâmetros ou a adição de camadas poderia melhorar o desempenho do nosso modelo LSTM. A rede CNN, mesmo apresentando resultados a nível do estado da arte, também poderia se beneficiar de uma maior afinação dos hiperparâmetros.

Capítulo 6

Conclusão

Este estudo demonstrou que as técnicas de deep learning são robustas e eficazes na detecção de patologias em sinais de ECG. A CNN superou a LSTM em todas as métricas para a detecção de ICC, especialmente quando consideradas as amostras utilizadas neste estudo (3 segundos), destacando sua superior capacidade de classificar a ICC a partir dos dados de ECG.

Esse resultado ocorre porque a força da LSTM em capturar dependências de longo prazo não é totalmente aproveitada com amostras mais curtas de 3 segundos. Ao mesmo tempo, a CNN se destaca com entradas menores, extraindo efetivamente características temporais por meio de camadas convolucionais. Como resultado, a CNN faz melhor uso do comprimento reduzido da amostra, levando a um desempenho superior na detecção de ICC nesse contexto.

As acurácias de classificação neste e em estudos relacionados geralmente variam de 97% a 99%, em grande parte devido à natureza dos sinais de ECG, que podem ser divididos em muitos segmentos menores. Embora alguns segmentos possam ser classificados incorretamente, a maioria é identificada corretamente. A implementação de limiares com base na classificação de múltiplos segmentos pode melhorar a acurácia geral, permitindo uma inferência mais confiável sobre todo o sinal, aumentando assim a confiança diagnóstica e auxiliando na tomada de decisões clínicas.

As limitações do trabalho ficam por conta da explicabilidade dos resultados de ambas as redes. Apesar de as classificações apresentarem uma alta acurácia, não é possível explicar quais parâmetros a rede utilizou para realizar as classificações. Em termos científicos, isto é um problema relevante, uma vez que não é possível mensurar o quanto as características clínicas, que caracterizam a ICC, pesaram no momento da classificação.

Uma estratégia para aumentar a explicabilidade é utilizar, na entrada da rede, algumas características dos dados de ECG, como a duração do complexo QRS. Como a ICC pode vir a impactar significativamente este parâmetro, é possível verificar a sua influência nas classificações. Intervalos longos do complexo QRS devem estar associados à classe patológica, por exemplo.

É possível também utilizar ferramentas mais sofisticadas para a análise das classificações, como o Local Interpretable Model-Agnostic Explanations (LIME) e o Shapley Additive Explanations (SHAP). Esses métodos ajudam a entender quais características dos sinais contribuíram no processo de classificação.

O LIME gera perturbações pontuais em um intervalo específico dos dados de entrada e, através de um modelo local, observa como essas mudanças afetam o resultado na saída. Este método é compatível tanto com as redes LSTM quanto CNN, de modo que o mesmo método pode ser empregado em ambos os modelos, favorecendo uma eventual comparação. O grande desafio deste método é a possibilidade de as perturbações geradas nos dados serem irreais em termos fisiológicos, mas isto pode ser mitigado caso as perturbações sejam aplicadas de forma contextual, respeitando características reais do ECG.

Já o SHAP utiliza a teoria dos valores de Shapley para atribuir a cada característica da entrada sua contribuição relativa à previsão, permitindo tanto a análise global da importância das características quanto explicações locais específicas. No entanto, pode se tornar uma abordagem complexa ao lidar com sinais brutos de ECG, uma vez que o SHAP trata cada ponto individualmente, ignorando relações temporais complexas e interdependências inerentes aos sinais de ECG, como as interações entre diferentes ondas. Outro obstáculo está na interpretação: a atribuição ponto a ponto dos valores de Shapley pode dificultar a tradução dos resultados para informações clinicamente relevantes, exigindo

técnicas adicionais para agregar ou contextualizar as contribuições em termos fisiológicos. Mesmo com a complexidade associada, é um caminho em direção à explicabilidade.

Portanto, é possível concluir que este trabalho possui algumas questões a serem aperfeiçoadas no tocante ao diagnóstico. No entanto, para ambientes ambulatoriais em que a agilidade na triagem é crucial, o modelo desenvolvido neste trabalho se enquadra melhor, uma vez que não fornece um diagnóstico definitivo, mas sim uma averiguação inicial de que há chances de o paciente estar sofrendo de ICC.

Trabalhos futuros poderiam explorar as seguintes abordagens para aprimorar o desempenho e a precisão dos modelos de classificação de sinais ECG:

- **Uso de Arquiteturas Híbridas CNN-LSTM:** Investigar o uso da CNN combinada com redes (LSTM) para melhorar a captura de padrões espaciais e temporais. Essa combinação pode maximizar as vantagens das CNNs em extrair características de baixo nível dos sinais ECG e das LSTMs em modelar as dependências temporais dos dados, especialmente em sinais cardíacos longos.
- **Uso de ECG com 12 Derivações:** No trabalho proposto, além do gênero e idade, foram utilizadas apenas as amplitude da derivação I do ECG. Em trabalhos futuros, é possível incorporar as amplitudes de outras variações, que também podem ser muito úteis na detecção de patologias.
- **Fragmentação em Amostras de Diferentes Escalas:** Dividir os sinais em amostras de curta, média e longa duração permite explorar diferentes aspectos das sequências com maior precisão. Segmentos pequenos são especialmente úteis para capturar detalhes de curto prazo, como características específicas de batimentos cardíacos individuais, enquanto segmentos de duração média e longa permitem uma análise aprofundada de padrões que se manifestam em períodos mais extensos, como as variações e tendências gerais do ritmo cardíaco ao longo do tempo.
- **Eliminação de Viés com Foco em Batimentos Cardíacos Isolados:** Para as

amostras de curta duração, a implementação de uma segmentação que isole os batimentos cardíacos individuais pode ser considerada extremamente vantajosa. Essa abordagem minimiza o viés decorrente das variações no ritmo cardíaco que podem surgir em janelas de tempo fixo, como 1, 2 ou 3 segundos. Ao assegurar que cada amostra de curta duração contenha apenas um ciclo cardíaco, eliminamos a possibilidade de incluir múltiplos picos R, que poderiam distorcer a análise em função da variabilidade do ritmo cardíaco. Essa estratégia promove uma avaliação mais precisa e consistente das características dos batimentos cardíacos, facilitando a detecção de anomalias e a extração de informações críticas.

- **Aplicação de Limiares para Inferência de Classe:** As acurácias de classificação neste e em estudos relacionados variam de 97% a 99%, principalmente devido à natureza dos sinais de ECG, que podem ser divididos em segmentos menores. Embora alguns segmentos possam ser classificados incorretamente, a esmagadora maioria é identificada corretamente. Implementar limiares baseados na classificação de múltiplos segmentos pode aumentar a acurácia geral, proporcionando inferências mais confiáveis sobre o sinal completo e aprimorando a confiança diagnóstica. Por exemplo, se 98% das amostras de um sinal de longa duração forem classificadas em uma determinada classe, é possível considerar que esse sinal pertence à classe em questão, uma vez que a maioria das amostras indica essa classificação.
- **Avaliação do Impacto de Diferenças Populacionais:** Considerar variações populacionais nos sinais ECG, tais como idade, género e histórico de saúde, para criar modelos mais robustos e adaptáveis a pacientes de diferentes perfis. Caso sejam coletados dados que representam abrangentemente todas as faixa etárias, os modelos generalizam melhor e podem prever dados com maiores variações de idade.
- **Interface para Utilização Prática dos Modelos:**

Ressalta-se que os modelos deste trabalho foram treinados considerando apenas género, idade e as amplitudes do ECG pelo tempo. Não houve extração de características e, para

o modelo CNN, foi o suficiente para classificar as amostras com uma precisão de 98,21%. Isto significa que, para patologias que sejam detetáveis em apenas um ciclo cardíaco como a ICC, a extração de características não é fundamental.

Por fim, é essencial desenvolver plataformas que integrem modelos de previsão para aplicações práticas na área da saúde. Isso permite que médicos e profissionais de saúde utilizem esses modelos, que muitas vezes ficam restritos a ambientes computacionais de alta complexidade. Ao facilitar a interação com essas tecnologias, uma plataforma modular que suporte diversos modelos pode trazer avanços significativos no auxílio ao diagnóstico e na tomada de decisões clínicas.

Bibliografia

- [1] Gregory A. Roth. «New Study Reveals Latest Data on Global Burden of Cardiovascular Disease». Em: *Journal of the American College of Cardiology* (dez. de 2023). Acesso em: 30/10/2024, <https://www.acc.org/About-ACC/Press-Releases/2023/12/11/18/48/New-Study-Reveals-Latest-Data-on-Global-Burden-of-Cardiovascular-Disease>. URL: <https://www.acc.org/About-ACC/Press-Releases/2023/12/11/18/48/New-Study-Reveals-Latest-Data-on-Global-Burden-of-Cardiovascular-Disease>.
- [2] Organização Mundial da Saúde. *OMS revela principais causas de morte e incapacidade em todo o mundo entre 2000 e 2019*. Acesso em: 30/10/2024. Dez. de 2020. URL: <https://www.who.int/news/item/10-12-2020-global-health-estimates-2019>.
- [3] Yale School of Medicine. *Congestive Heart Failure (CHF) Overview*. Acessado em: 2024-12-08. 333 Cedar St., New Haven, CT 06510, 2024. URL: <https://www.yalemedicine.org/conditions/congestive-heart-failure>.
- [4] Biykem Bozkurt et al. «HF STATS 2024: Heart Failure Epidemiology and Outcomes Statistics An Updated 2024 Report from the Heart Failure Society of America». Em: *Journal of Cardiac Failure* (2024). Accessed: 2024-12-08. ISSN: 1071-9164. DOI: 10.1016/j.cardfail.2024.07.001. URL: <https://doi.org/10.1016/j.cardfail.2024.07.001>.
- [5] J.J.V. McMurray et al. «ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure 2012: The Task Force for the Diagnosis and Treatment

- of Acute and Chronic Heart Failure 2012 of the European Society of Cardiology. Developed in collaboration with the Heart Failure Association (HFA) of the ESC». Em: *European Heart Journal* 33.14 (jul. de 2012). Erratum in: *Eur Heart J*. 2013 Jan;34(2):158. PMID: 22611136, pp. 1787–1847. DOI: 10.1093/eurheartj/ehs104. URL: <https://doi.org/10.1093/eurheartj/ehs104>.
- [6] Alfamed. *ECG Compassus 3000*. Acesso em: 30 jul. 2024. 2024. URL: <https://alfamed.com/produtos/ecg-compassus-3000/>.
- [7] The Wright Initiative. *What is EKG in Medical Terms?* Acesso em: 30 jul. 2024. 2024. URL: <https://thewrightinitiative.com/misc/what-is-ekg-in-medical-terms.html>.
- [8] ResearchGate. *ECG training based on heartbeat*. Acesso em: 30 jul. 2024. 2024. URL: https://www.researchgate.net/figure/ECG-training-based-on-heartbeat-9_fig1_373118975.
- [9] Sapan N. Talati et al. «Change in P Wave Duration on Electrocardiogram Correlates with Effective Treatment of Heart Failure». Em: *Electrophysiology, Arrhythmias* 15.6 (ago. de 2009), S60. DOI: 10.1016/j.cardfail.2009.06.238. URL: <https://doi.org/10.1016/j.cardfail.2009.06.238>.
- [10] Ravi Dhingra et al. «Electrocardiographic QRS Duration and the Risk of Congestive Heart Failure». Em: *Hypertension* 47.5 (2006), pp. 861–867. DOI: 10.1161/01.HYP.0000217141.20163.23. eprint: <https://www.ahajournals.org/doi/pdf/10.1161/01.HYP.0000217141.20163.23>. URL: <https://www.ahajournals.org/doi/abs/10.1161/01.HYP.0000217141.20163.23>.
- [11] Thomas Cascino e Michael J. Shea. *Eletrocardiografia (ECG)*. Revisado/Corrigido: jul. 2021. 2021. URL: <https://www.msmanuals.com/pt-pt/profissional/doen%C3%A7as-cardiovasculares/exames-e-procedimentos-cardiovasculares/eletrocardiografia>.

- [12] Peter Ofman et al. «T-wave inversion and diastolic dysfunction in patients with electrocardiographic left ventricular hypertrophy». Em: *Journal of Electrocardiology* 45.6 (2012), pp. 764–769. ISSN: 0022-0736. DOI: <https://doi.org/10.1016/j.jelectrocard.2012.06.001>. URL: <https://www.sciencedirect.com/science/article/pii/S0022073612001999>.
- [13] Larry R. Jackson II e Francis Ugowe. «Epidemiology and Outcomes Associated with PR Prolongation». Em: *Cardiac Electrophysiology Clinics* 13.4 (dez. de 2021). Copyright ©2021 Elsevier Inc. All rights reserved., pp. 661–669. ISSN: 1877-9190. DOI: 10.1016/j.ccep.2021.06.007. URL: <https://www.sciencedirect.com/science/article/pii/S1877918221000642>.
- [14] Payal Kohli e Anna Smith Haghighi. *What does ST depression on an ECG result mean?* Medically reviewed by Dr. Payal Kohli, M.D., FACC — Written by Anna Smith Haghighi — Updated on June 27, 2023. 2023. URL: <https://www.healthline.com/health/st-depression>.
- [15] Jean Baptiste Joseph Fourier. *Théorie analytique de la chaleur*. Vol. 1. Gauthier-Villars, 1888.
- [16] Mallat Stephane. *A wavelet tour of signal processing*. 1999.
- [17] D. Benitez et al. «The use of the Hilbert transform in ECG signal analysis». Em: *Computers in Biology and Medicine* 31.5 (2001), pp. 399–406. ISSN: 0010-4825. DOI: [https://doi.org/10.1016/S0010-4825\(01\)00009-9](https://doi.org/10.1016/S0010-4825(01)00009-9). URL: <https://www.sciencedirect.com/science/article/pii/S0010482501000099>.
- [18] Corinna Cortes e Vladimir Vapnik. «Support-vector networks». Em: *Machine learning* 20.3 (1995), pp. 273–297.
- [19] Asmaa Nabil Mohamed, Amgad A. Salama e Samy H. Darwish. «Classification of Voice Pathology Using SVM Classifier». Em: *2023 International Telecommunications Conference (ITC-Egypt)*. 2023, pp. 419–422. DOI: 10.1109/ITC-Egypt58155.2023.10206116.

- [20] Evelyn Fix e Joseph L Hodges Jr. *Discriminatory analysis: nonparametric discrimination: consistency properties*. Rel. téc. University of California, Berkeley, Technical Report No. 4, USAF School of Aviation Medicine, 1951.
- [21] Sanchari Chowdhury et al. «Effective Application of Supervised KNN Algorithm to Ascertain and Assess Abnormal Growth of Blood Cancerous Cells Predictive Modeling». Em: *Proceedings of Fifth Doctoral Symposium on Computational Intelligence*. Ed. por Abhishek Swaroop et al. Singapore: Springer Nature Singapore, 2024, pp. 553–561. ISBN: 978-981-97-6726-7.
- [22] J Ross Quinlan. «Induction of decision trees». Em: *Machine learning* 1.1 (1986), pp. 81–106.
- [23] Sonia L. Mestizo Gutiérrez et al. «Decision trees for the analysis of genes involved in Alzheimers disease pathology». Em: *Journal of Theoretical Biology* 357 (2014), pp. 21–25. ISSN: 0022-5193. DOI: <https://doi.org/10.1016/j.jtbi.2014.05.002>. URL: <https://www.sciencedirect.com/science/article/pii/S0022519314002690>.
- [24] 33rd Square. *Guide for Feature Extraction Techniques*. Acessado em: 02 de dezembro de 2024. 2024. URL: <https://www.33rdsquare.com/guide-for-feature-extraction-techniques/>.
- [25] Shekhar Banerjee. «Exploring the Power and Limitations of Multi-Layer Perceptron (MLP) in Machine Learning». Em: *Medium* (2023). URL: <https://shekhar-banerjee96.medium.com/exploring-the-power-and-limitations-of-multi-layer-perceptron-mlp-in-machine-learning-d97a3f84f9f4>.
- [26] Ulas Baran Baloglu et al. «Classification of myocardial infarction with multi-lead ECG signals and deep CNN». Em: *Pattern recognition letters* 122 (2019), pp. 23–30.
- [27] V. Guedes et al. «Long Short Term Memory on Chronic Laryngitis Classification». Em: *CENTERIS/ProjMAN/HCist 2018 - Procedia Computer Science*. Vol. 138. 2018, pp. 250–257. DOI: 10.1016/j.procs.2018.10.036.

- [28] P. M. Rodrigues e J. P. Teixeira. «Classification of Electroencephalogram Signals Using Artificial Neural Networks». Em: *Proceedings of 3rd International Conference on BioMedical Engineering and Informatics (BMEI'10)*. Yantai, China, out. de 2010. DOI: 10.1109/BMEI.2010.5639941.
- [29] Borui Hou et al. «LSTM-Based Auto-Encoder Model for ECG Arrhythmias Classification». Em: *IEEE Transactions on Instrumentation and Measurement* 69.4 (2020), pp. 1232–1240. DOI: 10.1109/TIM.2019.2910342.
- [30] R. Costa et al. «QRS Peaks, P and T Waves Identification in ECG». Em: *CENTERIS/ProjMAN/HCist 2020 - Procedia Computer Science*. Vol. 181. 2021, pp. 957–964. DOI: 10.1016/j.procs.2021.01.252.
- [31] B Anuradha e VC Veera Reddy. «ANN for classification of cardiac arrhythmias». Em: *ARPJN Journal of Engineering and Applied Sciences* 3.3 (2008), pp. 1–6.
- [32] Khondker Fariha Hossain et al. «ECG-Adv-GAN: Detecting ECG Adversarial Examples with Conditional Generative Adversarial Networks». Em: *2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA)*. 2021, pp. 50–56. DOI: 10.1109/ICMLA52953.2021.00016.
- [33] P. H. Borghi, R. Borges e J. P. Teixeira. «Atrial fibrillation classification based on MLP networks by extracting Jitter and Shimmer parameters». Em: *CENTERIS/ProjMAN/HCist 2020 - Procedia Computer Science*. Vol. 181. 2021, pp. 931–939. DOI: 10.1016/j.procs.2021.01.249.
- [34] S. Kusuma e K.R. Jothi. «ECG signals-based automated diagnosis of congestive heart failure using Deep CNN and LSTM architecture». Em: *Biocybernetics and Biomedical Engineering* 42.1 (2022), pp. 247–257. ISSN: 0208-5216. DOI: <https://doi.org/10.1016/j.bbe.2022.02.003>. URL: <https://www.sciencedirect.com/science/article/pii/S0208521622000067>.
- [35] Annisa Darmawahyuni et al. «Congestive heart failure waveform classification based on short time-step analysis with recurrent network». Em: *Informatics in Medicine*

- Unlocked* 21 (2020), p. 100441. ISSN: 2352-9148. DOI: <https://doi.org/10.1016/j.imu.2020.100441>. URL: <https://www.sciencedirect.com/science/article/pii/S2352914820305918>.
- [36] V. Jahmunah et al. «Automated detection of coronary artery disease, myocardial infarction and congestive heart failure using GaborCNN model with ECG signals». Em: *Computers in Biology and Medicine* 134 (2021), p. 104457. ISSN: 0010-4825. DOI: <https://doi.org/10.1016/j.combiomed.2021.104457>. URL: <https://www.sciencedirect.com/science/article/pii/S0010482521002511>.
- [37] Ahmed S. Eltrass, Mazhar B. Tayel e Abeer I. Ammar. «A new automated CNN deep learning approach for identification of ECG congestive heart failure and arrhythmia using constant-Q non-stationary Gabor transform». Em: *Biomedical Signal Processing and Control* 65 (2021), p. 102326. ISSN: 1746-8094. DOI: <https://doi.org/10.1016/j.bspc.2020.102326>. URL: <https://www.sciencedirect.com/science/article/pii/S1746809420304420>.
- [38] Mihaela Porumb et al. «A convolutional neural network approach to detect congestive heart failure». Em: *Biomedical Signal Processing and Control* 55 (2020), p. 101597. ISSN: 1746-8094. DOI: <https://doi.org/10.1016/j.bspc.2019.101597>. URL: <https://www.sciencedirect.com/science/article/pii/S1746809419301776>.
- [39] Zerina Masetic e Abdulhamit Subasi. «Congestive heart failure detection using random forest classifier». Em: *Computer Methods and Programs in Biomedicine* 130 (2016), pp. 54–64. ISSN: 0169-2607. DOI: <https://doi.org/10.1016/j.cmpb.2016.03.020>. URL: <https://www.sciencedirect.com/science/article/pii/S0169260715303369>.
- [40] A. Goldberger et al. «PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals». Em: *Circulation [Online]* 101.23 (2000), e215–e220.

- [41] Donald S. Baim et al. «Survival of patients with severe congestive heart failure treated with oral milrinone». Em: *Journal of the American College of Cardiology* 7.3 (1986), pp. 661–670. ISSN: 0735-1097. DOI: [https://doi.org/10.1016/S0735-1097\(86\)80478-8](https://doi.org/10.1016/S0735-1097(86)80478-8). URL: <https://www.sciencedirect.com/science/article/pii/S0735109786804788>.
- [42] R. Boussejot, D. Kreiseler e A. Schnabel. «Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet». Em: *Biomedizinische Technik / Biomedical Engineering* 40.s1 (1995), pp. 317–318.
- [43] André Pacheco. *Introdução a Redes Neurais Artificiais*. Acessado em 29/08/2024. 2024. URL: <https://computacaointeligente.com.br/algoritmos/conceitos/redes-neurais-artificiais/>.
- [44] Jingfeng Wu et al. *Direction Matters: On the Implicit Bias of Stochastic Gradient Descent with Moderate Learning Rate*. 2021. arXiv: 2011.02538 [cs.LG]. URL: <https://arxiv.org/abs/2011.02538>.
- [45] Anderson Castro Soares de Oliveira et al. «Aplicação de redes neurais artificiais na previsão da produção de álcool». Em: *Ciencia E Agrotecnologia - CIENC AGRO-TEC* 34 (abr. de 2010). DOI: 10.1590/S1413-70542010000200002.
- [46] Gabriel Couto. *O Poder das Redes Neurais Convolucionais: Um Guia Prático para Construir sua CNN Básica*. Acessado em 30/10/2024. Dez. de 2023. URL: <https://www.linkedin.com/pulse/o-poder-das-redes-neurais-convolucionais-um-guia-pr%C3%A1tico-couto-j7omf/>.
- [47] Huang Jin Jie e Putra Wanda. «RunPool: A Dynamic Pooling Layer for Convolution Neural Network». Em: *International Journal of Computational Intelligence Systems* 13.1 (2020), pp. 66–76. ISSN: 1875-6883. DOI: 10.2991/ijcis.d.200120.002. URL: <https://doi.org/10.2991/ijcis.d.200120.002>.
- [48] Raúl Rojas. «The Backpropagation Algorithm». Em: *Neural Networks: A Systematic Introduction*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1996, pp. 149–182.

ISBN: 978-3-642-61068-4. DOI: 10.1007/978-3-642-61068-4_7. URL: https://doi.org/10.1007/978-3-642-61068-4_7.

- [49] Akshay Tondak. *Recurrent Neural Networks (RNN) Tutorial: RNN Training, Advantages & Disadvantages (Complete Guidance)*. Acessado em 29/08/2024. 2023. URL: <https://k21academy.com/datascience-blog/machine-learning/recurrent-neural-networks/>.
- [50] Sepp Hochreiter e Jürgen Schmidhuber. «Long Short-term Memory». Em: *Neural computation* 9 (dez. de 1997), pp. 1735–80. DOI: 10.1162/neco.1997.9.8.1735.
- [51] Ivan Pisa et al. «Denoising Autoencoders and LSTM-Based Artificial Neural Networks Data Processing for Its Application to Internal Model Control in Industrial Environments—The Wastewater Treatment Plant Control Case». Em: *Sensors* 20 (jul. de 2020), p. 3743. DOI: 10.3390/s20133743.
- [52] Pooria Ahmadi et al. «Age and gender differences of basic electrocardiographic values and abnormalities in the general adult population; Tehran Cohort Study». Em: *BMC Cardiovascular Disorders* 23.1 (2023), p. 303.
- [53] U. Rajendra Acharya et al. «Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network». Em: *Information Sciences* 405 (2017), pp. 81–90. ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2017.04.012>. URL: <https://www.sciencedirect.com/science/article/pii/S0020025517306539>.
- [54] U. Rajendra Acharya et al. «A deep convolutional neural network model to classify heartbeats». Em: *Computers in Biology and Medicine* 89 (2017), pp. 389–396. ISSN: 0010-4825. DOI: <https://doi.org/10.1016/j.combiomed.2017.08.022>. URL: <https://www.sciencedirect.com/science/article/pii/S0010482517302810>.
- [55] Ozal Yildirim et al. «A new approach for arrhythmia classification using deep coded features and LSTM networks». Em: *Computer Methods and Programs in Biomedicine* 176 (2019), pp. 121–133. ISSN: 0169-2607. DOI: <https://doi.org/10.1016/j>.

- cmpb.2019.05.004. URL: <https://www.sciencedirect.com/science/article/pii/S0169260718314329>.
- [56] C.E. Shannon. «Communication in the Presence of Noise». Em: *Proceedings of the IRE* 37.1 (jan. de 1949), pp. 10–21. DOI: 10.1109/jrproc.1949.232969. URL: <https://doi.org/10.1109/jrproc.1949.232969>.
- [57] Era Ajdaraga e Marjan Gusev. «Analysis of sampling frequency and resolution in ECG signals». Em: *2017 25th Telecommunication Forum (TELFOR)*. 2017, pp. 1–4. DOI: 10.1109/TELFOR.2017.8249438.
- [58] Marek Malik. «Heart rate variability: Standards of measurement, physiological interpretation, and clinical use: Task force of the European Society of Cardiology and the North American Society for Pacing and Electrophysiology». Em: *Annals of Noninvasive Electrocardiology* 1.2 (1996), pp. 151–181.
- [59] Dhaval Patel. *Kaggle Titanic Dataset: Cleaning & Split data into train, validation, and test set*. Accessed: 2024-09-05. Mai. de 2021. URL: <https://www.kaggle.com/code/dhavalpatel/kaggle-titanic-dataset-cleaning-split-data>.

Apêndice A

Outro(s) Apêndice(s)

BIDMC Congestive Heart Failure Database													
chf01	chf02	chf03	chf04	chf05	chf07	chf08	chf09	chf10	chf11	chf12	chf13	chf14	chf15
chf01_1	chf02_31	chf03_61	chf04_91	chf05_121	chf07_151	chf08_181	chf09_211	chf10_241	chf11_271	chf12_301	chf13_331	chf14_361	chf15_391
chf01_2	chf02_32	chf03_62	chf04_92	chf05_122	chf07_152	chf08_182	chf09_212	chf10_242	chf11_272	chf12_302	chf13_332	chf14_362	chf15_392
chf01_3	chf02_33	chf03_63	chf04_93	chf05_123	chf07_153	chf08_183	chf09_213	chf10_243	chf11_273	chf12_303	chf13_333	chf14_363	chf15_393
chf01_4	chf02_34	chf03_64	chf04_94	chf05_124	chf07_154	chf08_184	chf09_214	chf10_244	chf11_274	chf12_304	chf13_334	chf14_364	chf15_394
chf01_5	chf02_35	chf03_65	chf04_95	chf05_125	chf07_155	chf08_185	chf09_215	chf10_245	chf11_275	chf12_305	chf13_335	chf14_365	chf15_395
chf01_6	chf02_36	chf03_66	chf04_96	chf05_126	chf07_156	chf08_186	chf09_216	chf10_246	chf11_276	chf12_306	chf13_336	chf14_366	chf15_396
chf01_7	chf02_37	chf03_67	chf04_97	chf05_127	chf07_157	chf08_187	chf09_217	chf10_247	chf11_277	chf12_307	chf13_337	chf14_367	chf15_397
chf01_8	chf02_38	chf03_68	chf04_98	chf05_128	chf07_158	chf08_188	chf09_218	chf10_248	chf11_278	chf12_308	chf13_338	chf14_368	chf15_398
chf01_9	chf02_39	chf03_69	chf04_99	chf05_129	chf07_159	chf08_189	chf09_219	chf10_249	chf11_279	chf12_309	chf13_339	chf14_369	chf15_399
chf01_10	chf02_40	chf03_70	chf04_100	chf05_130	chf07_160	chf08_190	chf09_220	chf10_250	chf11_280	chf12_310	chf13_340	chf14_370	chf15_400
chf01_11	chf02_41	chf03_71	chf04_101	chf05_131	chf07_161	chf08_191	chf09_221	chf10_251	chf11_281	chf12_311	chf13_341	chf14_371	chf15_401
chf01_12	chf02_42	chf03_72	chf04_102	chf05_132	chf07_162	chf08_192	chf09_222	chf10_252	chf11_282	chf12_312	chf13_342	chf14_372	chf15_402
chf01_13	chf02_43	chf03_73	chf04_103	chf05_133	chf07_163	chf08_193	chf09_223	chf10_253	chf11_283	chf12_313	chf13_343	chf14_373	chf15_403
chf01_14	chf02_44	chf03_74	chf04_104	chf05_134	chf07_164	chf08_194	chf09_224	chf10_254	chf11_284	chf12_314	chf13_344	chf14_374	chf15_404
chf01_15	chf02_45	chf03_75	chf04_105	chf05_135	chf07_165	chf08_195	chf09_225	chf10_255	chf11_285	chf12_315	chf13_345	chf14_375	chf15_405
chf01_16	chf02_46	chf03_76	chf04_106	chf05_136	chf07_166	chf08_196	chf09_226	chf10_256	chf11_286	chf12_316	chf13_346	chf14_376	chf15_406
chf01_17	chf02_47	chf03_77	chf04_107	chf05_137	chf07_167	chf08_197	chf09_227	chf10_257	chf11_287	chf12_317	chf13_347	chf14_377	chf15_407
chf01_18	chf02_48	chf03_78	chf04_108	chf05_138	chf07_168	chf08_198	chf09_228	chf10_258	chf11_288	chf12_318	chf13_348	chf14_378	chf15_408
chf01_19	chf02_49	chf03_79	chf04_109	chf05_139	chf07_169	chf08_199	chf09_229	chf10_259	chf11_289	chf12_319	chf13_349	chf14_379	chf15_409
chf01_20	chf02_50	chf03_80	chf04_110	chf05_140	chf07_170	chf08_200	chf09_230	chf10_260	chf11_290	chf12_320	chf13_350	chf14_380	chf15_410
chf01_21	chf02_51	chf03_81	chf04_111	chf05_141	chf07_171	chf08_201	chf09_231	chf10_261	chf11_291	chf12_321	chf13_351	chf14_381	chf15_411
chf01_22	chf02_52	chf03_82	chf04_112	chf05_142	chf07_172	chf08_202	chf09_232	chf10_262	chf11_292	chf12_322	chf13_352	chf14_382	chf15_412
chf01_23	chf02_53	chf03_83	chf04_113	chf05_143	chf07_173	chf08_203	chf09_233	chf10_263	chf11_293	chf12_323	chf13_353	chf14_383	chf15_413
chf01_24	chf02_54	chf03_84	chf04_114	chf05_144	chf07_174	chf08_204	chf09_234	chf10_264	chf11_294	chf12_324	chf13_354	chf14_384	chf15_414
chf01_25	chf02_55	chf03_85	chf04_115	chf05_145	chf07_175	chf08_205	chf09_235	chf10_265	chf11_295	chf12_325	chf13_355	chf14_385	chf15_415
chf01_26	chf02_56	chf03_86	chf04_116	chf05_146	chf07_176	chf08_206	chf09_236	chf10_266	chf11_296	chf12_326	chf13_356	chf14_386	chf15_416
chf01_27	chf02_57	chf03_87	chf04_117	chf05_147	chf07_177	chf08_207	chf09_237	chf10_267	chf11_297	chf12_327	chf13_357	chf14_387	chf15_417
chf01_28	chf02_58	chf03_88	chf04_118	chf05_148	chf07_178	chf08_208	chf09_238	chf10_268	chf11_298	chf12_328	chf13_358	chf14_388	chf15_418
chf01_29	chf02_59	chf03_89	chf04_119	chf05_149	chf07_179	chf08_209	chf09_239	chf10_269	chf11_299	chf12_329	chf13_359	chf14_389	chf15_419
chf01_30	chf02_60	chf03_90	chf04_120	chf05_150	chf07_180	chf08_210	chf09_240	chf10_270	chf11_300	chf12_330	chf13_360	chf14_390	chf15_420

Figura A.1: Lista dos 30 sinais derivados de cada um dos 14 pacientes da BIDMC

PTB Diagnostic ECG Database

117/ s0291lr	121/ s0311lr	122/ s0312lr	131/ s0273lr	172/ s0304lr	173/ s0305lr	229/ s0452_re	239/ s0467_re	243/ s0472_re	246/ s0478_re	248/ s0481_re	252/ s0487_re	266/ s0502_re	267/ s0504_re
s0291lr_421	s0311lr_451	s0312lr_481	s0273lr_511	s0304lr_541	s0305lr_571	s0452_re_601	s0467_re_631	s0472_re_661	s0478_re_691	s0481_re_721	s0487_re_751	s0502_re_781	s0504_re_811
s0291lr_422	s0311lr_452	s0312lr_482	s0273lr_512	s0304lr_542	s0305lr_572	s0452_re_602	s0467_re_632	s0472_re_662	s0478_re_692	s0481_re_722	s0487_re_752	s0502_re_782	s0504_re_812
s0291lr_423	s0311lr_453	s0312lr_483	s0273lr_513	s0304lr_543	s0305lr_573	s0452_re_603	s0467_re_633	s0472_re_663	s0478_re_693	s0481_re_723	s0487_re_753	s0502_re_783	s0504_re_813
s0291lr_424	s0311lr_454	s0312lr_484	s0273lr_514	s0304lr_544	s0305lr_574	s0452_re_604	s0467_re_634	s0472_re_664	s0478_re_694	s0481_re_724	s0487_re_754	s0502_re_784	s0504_re_814
s0291lr_425	s0311lr_455	s0312lr_485	s0273lr_515	s0304lr_545	s0305lr_575	s0452_re_605	s0467_re_635	s0472_re_665	s0478_re_695	s0481_re_725	s0487_re_755	s0502_re_785	s0504_re_815
s0291lr_426	s0311lr_456	s0312lr_486	s0273lr_516	s0304lr_546	s0305lr_576	s0452_re_606	s0467_re_636	s0472_re_666	s0478_re_696	s0481_re_726	s0487_re_756	s0502_re_786	s0504_re_816
s0291lr_427	s0311lr_457	s0312lr_487	s0273lr_517	s0304lr_547	s0305lr_577	s0452_re_607	s0467_re_637	s0472_re_667	s0478_re_697	s0481_re_727	s0487_re_757	s0502_re_787	s0504_re_817
s0291lr_428	s0311lr_458	s0312lr_488	s0273lr_518	s0304lr_548	s0305lr_578	s0452_re_608	s0467_re_638	s0472_re_668	s0478_re_698	s0481_re_728	s0487_re_758	s0502_re_788	s0504_re_818
s0291lr_429	s0311lr_459	s0312lr_489	s0273lr_519	s0304lr_549	s0305lr_579	s0452_re_609	s0467_re_639	s0472_re_669	s0478_re_699	s0481_re_729	s0487_re_759	s0502_re_789	s0504_re_819
s0291lr_430	s0311lr_460	s0312lr_490	s0273lr_520	s0304lr_550	s0305lr_580	s0452_re_610	s0467_re_640	s0472_re_670	s0478_re_700	s0481_re_730	s0487_re_760	s0502_re_790	s0504_re_820
s0291lr_431	s0311lr_461	s0312lr_491	s0273lr_521	s0304lr_551	s0305lr_581	s0452_re_611	s0467_re_641	s0472_re_671	s0478_re_701	s0481_re_731	s0487_re_761	s0502_re_791	s0504_re_821
s0291lr_432	s0311lr_462	s0312lr_492	s0273lr_522	s0304lr_552	s0305lr_582	s0452_re_612	s0467_re_642	s0472_re_672	s0478_re_702	s0481_re_732	s0487_re_762	s0502_re_792	s0504_re_822
s0291lr_433	s0311lr_463	s0312lr_493	s0273lr_523	s0304lr_553	s0305lr_583	s0452_re_613	s0467_re_643	s0472_re_673	s0478_re_703	s0481_re_733	s0487_re_763	s0502_re_793	s0504_re_823
s0291lr_434	s0311lr_464	s0312lr_494	s0273lr_524	s0304lr_554	s0305lr_584	s0452_re_614	s0467_re_644	s0472_re_674	s0478_re_704	s0481_re_734	s0487_re_764	s0502_re_794	s0504_re_824
s0291lr_435	s0311lr_465	s0312lr_495	s0273lr_525	s0304lr_555	s0305lr_585	s0452_re_615	s0467_re_645	s0472_re_675	s0478_re_705	s0481_re_735	s0487_re_765	s0502_re_795	s0504_re_825
s0291lr_436	s0311lr_466	s0312lr_496	s0273lr_526	s0304lr_556	s0305lr_586	s0452_re_616	s0467_re_646	s0472_re_676	s0478_re_706	s0481_re_736	s0487_re_766	s0502_re_796	s0504_re_826
s0291lr_437	s0311lr_467	s0312lr_497	s0273lr_527	s0304lr_557	s0305lr_587	s0452_re_617	s0467_re_647	s0472_re_677	s0478_re_707	s0481_re_737	s0487_re_767	s0502_re_797	s0504_re_827
s0291lr_438	s0311lr_468	s0312lr_498	s0273lr_528	s0304lr_558	s0305lr_588	s0452_re_618	s0467_re_648	s0472_re_678	s0478_re_708	s0481_re_738	s0487_re_768	s0502_re_798	s0504_re_828
s0291lr_439	s0311lr_469	s0312lr_499	s0273lr_529	s0304lr_559	s0305lr_589	s0452_re_619	s0467_re_649	s0472_re_679	s0478_re_709	s0481_re_739	s0487_re_769	s0502_re_799	s0504_re_829
s0291lr_440	s0311lr_470	s0312lr_500	s0273lr_530	s0304lr_560	s0305lr_590	s0452_re_620	s0467_re_650	s0472_re_680	s0478_re_710	s0481_re_740	s0487_re_770	s0502_re_800	s0504_re_830
s0291lr_441	s0311lr_471	s0312lr_501	s0273lr_531	s0304lr_561	s0305lr_591	s0452_re_621	s0467_re_651	s0472_re_681	s0478_re_711	s0481_re_741	s0487_re_771	s0502_re_801	s0504_re_831
s0291lr_442	s0311lr_472	s0312lr_502	s0273lr_532	s0304lr_562	s0305lr_592	s0452_re_622	s0467_re_652	s0472_re_682	s0478_re_712	s0481_re_742	s0487_re_772	s0502_re_802	s0504_re_832
s0291lr_443	s0311lr_473	s0312lr_503	s0273lr_533	s0304lr_563	s0305lr_593	s0452_re_623	s0467_re_653	s0472_re_683	s0478_re_713	s0481_re_743	s0487_re_773	s0502_re_803	s0504_re_833
s0291lr_444	s0311lr_474	s0312lr_504	s0273lr_534	s0304lr_564	s0305lr_594	s0452_re_624	s0467_re_654	s0472_re_684	s0478_re_714	s0481_re_744	s0487_re_774	s0502_re_804	s0504_re_834
s0291lr_445	s0311lr_475	s0312lr_505	s0273lr_535	s0304lr_565	s0305lr_595	s0452_re_625	s0467_re_655	s0472_re_685	s0478_re_715	s0481_re_745	s0487_re_775	s0502_re_805	s0504_re_835
s0291lr_446	s0311lr_476	s0312lr_506	s0273lr_536	s0304lr_566	s0305lr_596	s0452_re_626	s0467_re_656	s0472_re_686	s0478_re_716	s0481_re_746	s0487_re_776	s0502_re_806	s0504_re_836
s0291lr_447	s0311lr_477	s0312lr_507	s0273lr_537	s0304lr_567	s0305lr_597	s0452_re_627	s0467_re_657	s0472_re_687	s0478_re_717	s0481_re_747	s0487_re_777	s0502_re_807	s0504_re_837
s0291lr_448	s0311lr_478	s0312lr_508	s0273lr_538	s0304lr_568	s0305lr_598	s0452_re_628	s0467_re_658	s0472_re_688	s0478_re_718	s0481_re_748	s0487_re_778	s0502_re_808	s0504_re_838
s0291lr_449	s0311lr_479	s0312lr_509	s0273lr_539	s0304lr_569	s0305lr_599	s0452_re_629	s0467_re_659	s0472_re_689	s0478_re_719	s0481_re_749	s0487_re_779	s0502_re_809	s0504_re_839
s0291lr_450	s0311lr_480	s0312lr_510	s0273lr_540	s0304lr_570	s0305lr_600	s0452_re_630	s0467_re_660	s0472_re_690	s0478_re_720	s0481_re_750	s0487_re_780	s0502_re_810	s0504_re_840

Figura A.2: Lista dos 30 sinais derivados de cada um dos 14 indivíduos da PTB