

**UNIVERSIDADE BRASIL  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA  
CAMPUS ITAQUERA**

**JOSÉ VIGNO MOURA SOUSA**

**APLICAÇÕES DE MODELOS COMPUTACIONAIS DE ANÁLISE DE  
DADOS BIOMÉDICOS EM PLATAFORMAS DE DISPOSITIVOS  
MÓVEIS**

**APPLICATIONS OF COMPUTATIONAL MODELS OF BIOMEDICAL  
DATA ANALYSIS ON MOBILE DEVICE PLATFORMS**

São Paulo – SP  
2020

**JOSÉ VIGNO MOURA SOUSA**

**APLICAÇÕES DE MODELOS COMPUTACIONAIS DE ANÁLISE DE  
DADOS BIOMÉDICOS EM PLATAFORMAS DE DISPOSITIVOS  
MÓVEIS**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Brasil, como parte dos requisitos necessários para obtenção do título de Doutor em Engenharia Biomédica.

Prof. Dr. Vilson Rosa de Almeida  
**Orientador**

Prof. Dr. Mardoqueu Martins da Costa  
**Coorientador**

São Paulo – SP  
2020

**Ficha catalográfica elaborada pelo Sistema de Bibliotecas da Universidade Brasil,  
com os dados fornecidos pelo (a) autor (a).**

S697a SOUSA, José Vigno Moura

Aplicações de Modelos Computacionais de Análise de Dados Biomédicos em Plataformas de Dispositivos Móveis / José Vigno Moura Sousa. -- São Paulo: Universidade Brasil, 2020.

116 f.: il. color.

Tese de Doutorado defendida no Programa de Pós-graduação do Curso de Engenharia Biomédica da Universidade Brasil.

Orientação: Prof. Dr. Vilson Rosa de Almeida

Coorientação: Prof. Dr. Mardoqueu Martins da Costa

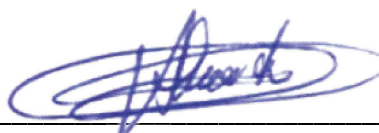
1. Pneumonia. 2. Covid-19. 3. Arritmia. 4. Compressão. 5. Imagens. I. Almeida, Vilson Rosa de. II. Costa, Mardoqueu Martins da. III. Título.

## TERMO DE APROVAÇÃO

JOSÉ VIGNO MOURA SOUSA

### “APLICAÇÕES DE MODELOS COMPUTACIONAIS DE ANÁLISE DE DADOS BIOMÉDICOS EM PLATAFORMAS DE DISPOSITIVOS MÓVEIS”

Tese aprovada como requisito parcial para obtenção do título de **Doutor no Programa de Pós-Graduação em Engenharia Biomédica** da Universidade Brasil, pela seguinte banca examinadora:



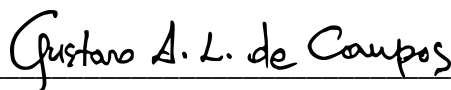
Prof(a). Dr(a) Vilson Rosa de Almeida (presidente-orientador)



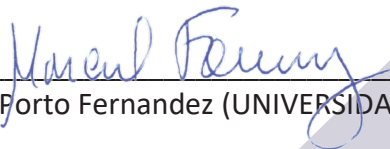
Prof(a). Dr(a) Thiago de Oliveira Mendes (UNIVERSIDADE BRASIL)



Prof(a). Dr(a) Anderson de Oliveira Lobo (UNIVERSIDADE BRASIL)



Prof(a). Dr(a) Gustavo Augusto Lima de Campos (UNIVERSIDADE ESTADUAL DO CEARÁ)



Prof(a). Dr(a) Marcial Porto Fernandez (UNIVERSIDADE ESTADUAL DO CEARÁ)

São Paulo, 18 de dezembro de 2020.

Presidente da Banca Prof.(a) Dr.(a) Vilson Rosa de Almeida

Houve alteração do Título: sim ( ) não ( X ):

---

---

---

## Termo de Autorização

### Para Publicação de Dissertações e Teses no Formato Eletrônico na Página WWW do Respectivo Programa da Universidade Brasil e no Banco de Teses da CAPES

Na qualidade de titular(es) dos direitos de autor da publicação, e de acordo com a Portaria CAPES no. 13, de 15 de fevereiro de 2006, autorizo(amos) a Universidade Brasil a disponibilizar através do site <http://www.universidadebrasil.edu.br>, na página do respectivo Programa de Pós-Graduação *Stricto Sensu*, bem como no Banco de Dissertações e Teses da CAPES, através do site <http://bancodeteses.capes.gov.br>, a versão digital do texto integral da Dissertação/Tese abaixo citada, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira.

A utilização do conteúdo deste texto, exclusivamente para fins acadêmicos e científicos, fica condicionada à citação da fonte.

Título do Trabalho: **“APLICAÇÕES DE MODELOS COMPUTACIONAIS DE ANÁLISE DE DADOS BIOMÉDICOS EM PLATAFORMAS DE DISPOSITIVOS MÓVEIS”**

**Autor(es):**

Discente: **José Vigno Moura Sousa**

Assinatura: *José Vigno Moura Sousa*

Orientador(a): **Prof.(a) Dr.(a) Vilson Rosa de Almeida**

Assinatura: \_\_\_\_\_  
*[Assinatura manuscrita]*

Coorientador(a): **Prof.(a) Dr.(a)**

Assinatura: \_\_\_\_\_

Houve alteração do Título: sim ( ) não ( X ):

\_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

Data: 18/12/2020

## DEDICATÓRIA

*Dedico à Deus por ter me concedido vida, saúde e sabedoria, por ser essencial em minha vida, autor de meu destino, meu guia, socorro presente na hora da angústia. A minha querida esposa, Aglaíse, pelo companheirismo, apoio e incentivo em todos os momentos, por me ajudar a conquistar meus objetivos. Te amo muito e sei que sempre estará ao meu lado caminhando nesta jornada da vida. A minha querida filha, Bianca, minha princesa, com você eu descobri que meu coração é gigante e não para de crescer, pois meu amor por você aumenta todos os dias! Aos meus queridos pais, José Virgílio (in memoriam) e Elizabeth, pelo grande amor e dedicação em todos os momentos, pelo apoio e incentivo para lutar e alcançar meus sonhos e objetivos. Vocês são meus maiores mestres! Ao meu irmão, Vagno, que acompanha e apoia esta minha jornada de vida em todos os momentos.*

## **AGRADECIMENTOS**

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) que apoiou com o benefício do Programa de Suporte à Pós-Graduação de Instituições de Ensino Particulares (PROSUP) a realização do presente trabalho.

Aos meus alunos de graduação Bruno, Luciano, Felipe, Pedro, que com toda sabedoria, paciência e dedicação não mediram esforços a me ajudarem a conquistar esse título, serei eternamente grato a vocês! Muito obrigado!

Aos meus professores Dr. Vilson e Dr. Mardoqueu, que com toda sabedoria, paciência e dedicação não mediram esforços a me ajudarem a conquistar esse título, serei eternamente grato a vocês! Muito obrigado!

A todos aqueles que de alguma forma estiveram e estão próximos de mim, fazendo esta vida valer cada vez mais a pena.

## RESUMO

Este trabalho desenvolve o CNN-Pulmonar e o CNN-Cardio, implementações de modelos computacionais para otimização de análise de dados biomédicos de radiografia de tórax (CXR) e eletrocardiograma (ECG), respectivamente, implementáveis em plataformas de dispositivos móveis, além de uma comparação de vários métodos de compressão de sinais. O CNN-Pulmonar é uma abordagem para a classificação de imagens de radiografias de tórax em três classes: pneumonia bacteriana, pneumonia viral (Covid-19 ou outro tipo) e pulmão normal. Emprega-se Redes Neurais Convolucionais, a partir de redes pré-treinadas em conjunto com um processo de quantização, por meio do método da plataforma TensorFlow Lite, com o que se reduz o custo computacional. Usa-se o método de classificação em cascata, que possibilita a divisão das classificações em diferentes estágios; dessa forma, foi possível obter 99,16% de precisão na classificação de imagens com suspeita de Covid-19. O aplicativo móvel resultante também apresenta uma interface de usuário simples e intuitiva. No CNN-Cardio, é proposto um novo método para classificar sinais de eletrocardiograma em dispositivos móveis, que pode classificar diferentes arritmias de acordo com o padrão EC57 da *Association for the Advancement of Medical Instrumentation*. Uma rede neural convolucional foi construída, treinada e validada com o conjunto de dados de arritmia MIT-BIH, em que essa base de dados possui 5 classes diferentes: batimento normal, batimento supra-ventricular prematuro, contração ventricular prematura, fusão de batimento ventricular, normal e batimento inclassificável. Depois de treinado e validado, o modelo é submetido a um estágio de quantização pós-treinamento usando o método de conversão TensorFlow Lite. Os resultados obtidos foram bem satisfatórios, antes e após a quantização; a rede neural convolucional obteve uma acurácia de 99%. Com a técnica de quantização, foi possível obter uma redução significativa no tamanho do modelo, possibilitando assim o desenvolvimento do aplicativo móvel; essa redução foi de aproximadamente 90% em relação ao tamanho do modelo original. Adicionalmente, comparou-se o comportamento de diferentes sinais, quando aplicados a diferentes técnicas de compressão, de modo a testar e encontrar as melhores técnicas de compressão para diferentes tipos de sinais biomédicos, comprovando também que diferentes tipos de sinais biomédicos se comportam de maneira distinta em diferentes tipos de compressão de sinais biomédicos; os resultados desta comparação de métodos de compressão de sinais foram bastante satisfatórios, demonstrando que diferentes tipos de compressão podem ser usados em sinais biomédicos, para obter melhores resultados de desempenho e qualidade em sua transmissão.

**Palavras-chave:** Pneumonia, Covid-19, Arritmia, Compressão de Dados, Imagens e Sinais biomédicos.

## ABSTRACT

This work develops CNN-Pulmona and CNN-Cardio, implementations of computational models for optimization of analysis of biomedical data from chest radiography (CXR) and electrocardiogram (ECG), respectively, deployable in mobile device platforms, in addition to a comparison of several methods of signal compression. CNN-Pulmona is an approach for classifying chest X-ray images into three classes: bacterial pneumonia, viral pneumonia (Covid-19 or other type) and healthy lung. Convolutional Neural Networks are used, based on pre-trained networks in conjunction with a quantization process, by means of the TensorFlow Lite platform method, thereby reducing the computational cost. The cascade classification method is used, which makes it possible to divide the classifications into different stages; thus, it was possible to obtain 99.16% accuracy in the classification of images with suspicion of Covid-19. The resulting mobile application program also features a simple and intuitive user interface. In CNN-Cardio, a new method to classify electrocardiogram signals on mobile devices is proposed, which can classify different arrhythmias according to the EC57 standard of the Association for the Advancement of Medical Instrumentation. A convolutional neural network was built, trained and validated with the MIT-BIH arrhythmia dataset, in which this database has 5 different classes: normal beat, premature supraventricular beat, premature ventricular contraction, ventricular beat fusion, normal and unclassifiable beat. After being trained and validated, the model is submitted to a post-training quantization stage using the TensorFlow Lite conversion method. The results obtained were very satisfactory, before and after quantization; the convolutional neural network obtained an accuracy of 99%. With the quantization technique, it was possible to obtain a significant reduction in the size of the model, thus enabling the development of the mobile application; this reduction was approximately 90% in relation to the size of the original model. Additionally, the behavior of different signals was compared, when applied to different compression techniques, in order to test and find the best compression techniques for distinct types of biomedical signals, also proving that different types of biomedical signals behave distinctly in different types compression of biomedical signals, the results of this comparison of signal compression methods were very satisfactory, demonstrating that different types of compression can be used on signals for better results.

**Keywords:** Pneumonia, Covid-19, Arrhythmia, Data Compression, Biomedical Images and Signals.

## LISTA DE FIGURAS

Figura 1 – Exemplo de EEG. . . . .	29
Figura 2 – Exemplo de EOG. . . . .	31
Figura 3 – Exemplo de EMG. . . . .	32
Figura 4 – Exemplo de ECG. . . . .	33
Figura 5 – Imagem de Raio-X de pacientes com pneumonia viral. . . . .	36
Figura 6 – Raio-X de pacientes com pneumonia bacteriana. . . . .	38
Figura 7 – Raio X de pacientes com pneumonia causada pela Covid-19. . . . .	39
Figura 8 – Processo de aprendizado de máquina supervisionado. . . . .	42
Figura 9 – Rede neural multicamadas. . . . .	44
Figura 10 – Exemplo da arquitetura de uma CNN (AlexNet). . . . .	45
Figura 11 – Diagrama das três aplicações desenvolvidas. . . . .	56
Figura 12 – Otimização Bayesiana. . . . .	59
Figura 13 – Estrutura do sistema da aplicação móvel CNN-Pulmona. . . . .	61
Figura 14 – Gráfico de distribuição da base dados final utilizado nesse projeto. . . . .	64
Figura 15 – Arquitetura da CNN. . . . .	65
Figura 16 – Imagem original da radiografia de tórax (A), imagem após rotação de 15 graus no sentido horário (B), imagem após rotação de 15 graus no sentido anti-horário (C), imagem após 5% de translação horizontal (D), após 5% de translação vertical (E ), e após 5% de translação horizontal e vertical (F). . . . .	65
Figura 17 – Modelo em cascata. . . . .	66
Figura 18 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-x do <b>Modelo 1</b> . . . . .	67
Figura 19 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-x do <b>Modelo 2</b> . . . . .	68
Figura 20 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-X do <b>Modelo 3</b> . . . . .	69

Figura 21 – Funcionamento do sistema. . . . .	70
Figura 22 – Fluxograma do sistema de classificação de ECG. . . . .	72
Figura 23 – Número de dados para cada classe. . . . .	73
Figura 24 – Exemplo de dez amostras de sinais com o janelamento de 10 segundos para cada classe após a extração dos sinais. . . . .	75
Figura 25 – Arquitetura da CNN usada para a classificação de ECG no app CNN-Cardio. . . . .	76
Figura 26 – Aplicação dos métodos de compressão. . . . .	79
Figura 27 – Matriz de confusão da classificação Normal x Pneumonia (Modelo 1). . . . .	82
Figura 28 – Matriz de confusão da classificação Pneumonia Viral x Pneumonia Bacteriana (Modelo 2). . . . .	83
Figura 29 – Matriz de confusão da classificação Pneumonia por outros Vírus x Pneumonia por Covid-19 (Modelo 3). . . . .	84
Figura 30 – Exemplo de uma classificação para um Raio-X possuindo indícios para o vírus Covid-19. Em cada estágio, é possível observar a classe para a qual o modelo prediz, assim como a taxa probabilidade de ser dessa classe. . . . .	85
Figura 31 – Exemplo de classificação móvel (Classes batimento normal e fusão de batimento ventricular e normal). . . . .	88
Figura 32 – Matriz de confusão da CNN antes da quantização. . . . .	89
Figura 33 – Exemplo de classificação móvel (Classes Batimento prematuro supraventricular e Contração ventricular prematura). . . . .	90
Figura 34 – EEG e ECG originais. . . . .	91
Figura 35 – Sinais reconstruídos por IDCT. . . . .	91
Figura 36 – Processo de compressão e reconstrução por FWHT. . . . .	92
Figura 37 – Sinais reconstruídos por FWHT. . . . .	93
Figura 38 – Sinais reconstruídos por IDWT. . . . .	93
Figura 39 – Sinais reconstruídos por IDWT. . . . .	94
Figura 40 – Processo de compressão e reconstrução por FWHT. . . . .	94
Figura 41 – Sinais reconstruídos por IDCT. . . . .	95

Figura 42 – Sinais reconstruídos por IFWHT. . . . .	95
Figura 43 – Sinais reconstruídos por IDWT. . . . .	96

## LISTA DE TABELAS

Tabela 1 – Opções de quantização pós-treinamento. . . . .	47
Tabela 2 – Sumário da rede neural usada para a classificação de sinal ECG no app CNN-Cardio. . . . .	77
Tabela 3 – Resultados das métricas para os dados de <b>Teste</b> . . . . .	81
Tabela 4 – Resultados das métricas para os dados de <b>Validação</b> . . . . .	81
Tabela 5 – Resultados do uso computacional do aplicativo CNN-Pulmona. . . . .	84
Tabela 6 – Resultados da CNN antes da quantização para cada classe com os dados de <b>Teste</b> . . . . .	87
Tabela 7 – Resultados da CNN antes da quantização para cada classe com os dados de <b>Validação</b> . . . . .	87
Tabela 8 – Dados de processamento e uso de memória do aplicativo CNN-Cardio.	88
Tabela 9 – Resultados das métricas para as técnicas de compressão no sinal <b>EEG</b> . . . . .	97
Tabela 10 – Resultados das métricas para as técnicas de compressão no sinal <b>EOG</b> . . . . .	97
Tabela 11 – Resultados das métricas para as técnicas de compressão no sinal <b>EMG</b> . . . . .	97
Tabela 12 – Resultados das métricas para as técnicas de compressão no sinal <b>ECG</b> . . . . .	98
Tabela 13 – Trabalhos relacionados que realizaram a classificação de imagens de Raio-X. . . . .	102
Tabela 14 – Trabalhos relacionados que realizaram a classificação com o mesmo conjunto de dados (MIT-BIH). . . . .	102

## LISTA DE ABREVIATURAS E SIGLAS

RT-PCR	<i>Reverse-Transcriptase Polymerase Chain Reaction</i>
CXR	Radiografia de Tórax
TC	Tomografia Computadorizada
ECG	Eletrocardiograma
CNN	Redes Neurais Convolucionais
CNN-Pumona	Aplicativo móvel para análise de imagens de CXR
CNN-Cardio	Aplicativo para analisar ECG
LSTM	<i>Long Short-Term Memory</i>
EEG	Eletroencefalograma
GAN	Redes Adversárias Gerativas
LDA	Análise Discriminante Linear
DNN	Redes Neurais Profundas
EMG	Eletromiografia
EOG	Eletrooculografia
AV	Atrioventricular
RSV	Vírus sincicial respiratório
MERS	Síndrome respiratória do Oriente Médio
DPOC	Doença pulmonar obstrutiva crônica
IA	Inteligência artificial
MLP	<i>Multilayer perceptron</i>
QNN	Redes Neurais Quantizadas
TFL	TensorFlow Lite
CCM	Modelo de Classificação em Cascata
DCT	Transformada Discreta de Cosseno

FWHT	<i>Fast Walsh-Hadamard Transform</i>
DWT	Transformada Discreta de Wavelet
FFT	Transformada Rápida de Fourier
MAE	Erro Médio Absoluto
SNR	Relação sinal-ruído
PSNR	Relação sinal-ruído de pico
MSE	Erro Quadrático Médio

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>18</b>
<b>2</b>	<b>OBJETIVOS</b>	<b>22</b>
2.1	OBJETIVO GERAL	22
2.2	OBJETIVOS ESPECÍFICOS	22
<b>3</b>	<b>MOTIVAÇÃO</b>	<b>23</b>
<b>4</b>	<b>REVISÃO DA LITERATURA</b>	<b>24</b>
4.1	TRABALHOS RELACIONADOS	24
4.2	FUNDAMENTAÇÃO TEÓRICA	27
4.2.1	DESENVOLVIMENTO DE APLICATIVOS MÓVEIS NA SAÚDE	27
4.2.2	TIPOS DE SINAIS BIOMÉDICOS	29
4.2.2.1	EEG	29
4.2.2.2	EOG	30
4.2.2.3	EMG	31
4.2.2.4	ECG	32
4.2.3	ARRITMIAS CARDÍACAS	33
4.2.4	DOENÇAS PULMONARES	34
4.2.4.1	PNEUMONIA VIRAL	35
4.2.4.2	PNEUMONIA BACTERIANA	37
4.2.4.3	PNEUMONIA POR COVID-19	39
4.2.5	RADIOGRAFIA DE TÓRAX	40
4.2.6	INTELIGÊNCIA ARTIFICIAL	40
4.2.7	APRENDIZADO DE MÁQUINA	41
4.2.8	REDES NEURAIS ARTIFICIAIS	43
4.2.8.1	REDE NEURAL MULTILAYER PERCEPTRON	44
4.2.8.2	REDE NEURAL CONVOLUCIONAL	45
4.2.9	TRANSFERÊNCIA DE APRENDIZADO	46
4.2.10	REDES NEURAIS QUANTIZADAS	46
4.2.11	MODELOS EM CASCATA	47
4.2.12	AUMENTO DE IMAGEM	48
4.2.13	OTIMIZAÇÃO BAYESIANA DE HIPERPARÂMETROS	48
4.2.14	MÉTRICAS DE AVALIAÇÃO DAS REDES NEURAIS	49
4.2.15	TÉCNICAS DE COMPRESSÃO	50
4.2.15.1	DCT	50
4.2.15.2	FWHT	51
4.2.15.3	DWT	52
4.2.16	MÉTRICAS DE AVALIAÇÃO PARA A COMPRESSÃO DE SINAIS	53

4.2.16.1 MSE . . . . .	54
4.2.16.2 MAE . . . . .	54
4.2.16.3 SNR . . . . .	54
4.2.16.4 PSNR . . . . .	55
<b>5 MATERIAIS E MÉTODOS . . . . .</b>	<b>56</b>
5.1 OTIMIZAÇÃO DOS HIPERPARÂMETROS DAS REDES NEURAIS . . . . .	57
5.2 QUANTIZAÇÃO DAS CNNs . . . . .	59
5.3 CLASSIFICAÇÃO DE IMAGENS DE RAIO-X (CNN-PULMONA) . . . . .	60
5.3.1 DATASET DE RAIO-X . . . . .	61
5.3.2 ARQUITETURA E TREINAMENTO DA CNN PARA CLASSIFI- CAÇÃO DE RAIO-X . . . . .	64
5.3.3 APLICATIVO MÓVEL DE CLASSIFICAÇÃO DE RAIO-X (CNN- PULMONA) . . . . .	69
5.4 CLASSIFICAÇÃO DE SINAIS DE ECG (CNN-CARDIO) . . . . .	71
5.4.1 DATASET DE ECG . . . . .	72
5.4.2 ARQUITETURA E TREINAMENTO DA CNN PARA CLASSIFI- CAÇÃO DE ECG . . . . .	75
5.4.3 APLICATIVO MÓVEL DE CLASSIFICAÇÃO DE ECG (CNN-CARDIO)	77
5.5 COMPARAÇÃO DE TÉCNICAS DE COMPRESSÃO EM SINAIS BIO- MÉDICOS . . . . .	78
5.5.1 APLICAÇÃO DAS TRANSFORMADAS . . . . .	78
<b>6 RESULTADOS . . . . .</b>	<b>81</b>
6.1 RESULTADOS DA CLASSIFICAÇÃO DE IMAGENS DE RAIO-X (CNN- PULMONA) . . . . .	81
6.2 RESULTADOS DA CLASSIFICAÇÃO DE SINAIS DE ECG (CNN-CARDIO)	87
6.3 RESULTADOS DA COMPRESSÃO DE SINAIS . . . . .	90
<b>7 DISCUSSÃO . . . . .</b>	<b>99</b>
<b>8 CONCLUSÃO . . . . .</b>	<b>103</b>
<b>REFERÊNCIAS . . . . .</b>	<b>105</b>
<b>APÊNDICE A Artigo 1 publicado . . . . .</b>	<b>116</b>
<b>APÊNDICE B Artigo 2 publicado . . . . .</b>	<b>117</b>
<b>APÊNDICE C Artigo 3 em <i>preprint</i> . . . . .</b>	<b>118</b>

# 1 INTRODUÇÃO

Automatizar a exploração de dados, principalmente em imagens e sinais médicos, utilizando aplicações de modelos computacionais, é um grande desafio da atualidade. Essas aplicações tem como objetivo automatizar a análise de dados biomédicos para auxiliar os profissionais da área da saúde a chegar, com precisão, a um diagnóstico precoce (LABHANE et al., 2020) (BALOGLU et al., 2019).

Na população mundial, algumas doenças são mais frequentes, como: pulmonares e cardíacas (SRINIVASAN; SCHILLING, 2018), (CHOWDHURY et al., 2020). Em tratando-se de doença pulmonar, estamos vivenciando uma pandemia global com a Covid-19.

A pandemia global de Covid-19 continua ocasionando um efeito devastador sobre a saúde e o bem-estar da população mundial, onde teve seu início com os relatos de causas desconhecidas de pneumonia em Wuhan, província de Hubei, na China, em 31 de dezembro de 2019 (OZTURK et al., 2020). De acordo com a Organização Mundial de Saúde em 17 de Outubro 2020, o número de casos confirmados é de 39.196.259, com o número de mortes de 1.101.298. Até agora, nenhuma vacina ou tratamento específico para Covid-19 foi desenvolvido, no entanto, existem muitos ensaios clínicos em andamento avaliando possíveis tratamentos. Embora o *Reverse-Transcriptase Polymerase Chain Reaction* (RT-PCR) do escarro seja o padrão-ouro para o diagnóstico de coronavírus, é demorado confirmar os pacientes com Covid-19 por causa de altos níveis de falsos negativos nos testes rápidos (HUANG et al., 2020).

Portanto, imagens médicas como Radiografia de Tórax (*chest X-ray* – CXR) e Tomografia Computadorizada (TC), podem desempenhar um papel importante na confirmação de pacientes com Covid-19 (HUANG et al., 2020), (LIU et al., 2020), (NG et al., 2020). No entanto, a principal desvantagem do uso de imagens por tomografia computadorizada é a alta quantidade de pacientes e custo elevado deste tipo de exame (KROFT et al., 2019). Por outro lado, máquinas de CXR estão disponíveis na maioria dos hospitais e clínicas para produzir imagens de projeção bidimensional (2D) do tórax do paciente. Na maioria dos casos positivos de Covid-19, no estudo de Huang et al (HUANG et al., 2020), apresentam anormalidades radiográficas bilaterais nas imagens de radiografia torácica, o que torna a CRX uma ferramenta potencial para o auxílio na triagem de pacientes com suspeita de Covid-19.

Embora imagens típicas de radiografia torácica possam ajudar na triagem precoce de casos suspeitos, as imagens de várias pneumonias, tanto virais como também bacterianas, são semelhantes a Pneumonia causada pela Covid-19 (CHOWDHURY

et al., 2020). Portanto, é difícil para os radiologistas distinguir a Pneumonia causada pela Covid-19 de outros tipos de pneumonias; os sintomas de Covid-19 sendo semelhantes aos de outros tipos pneumonias podem, as vezes, levar a um diagnóstico errado. Com isso percebe-se que, ferramentas tecnológicas eficientes que permitam a triagem rápida da infecção por Covid-19 com alta precisão pode ser crucialmente útil para os profissionais de saúde.

Por outro lado, as doenças cardiovasculares são uma das principais causas de morte em todo o mundo. Este tipo de patologia afeta o sistema cardiovascular, especificamente os vasos sanguíneos e o coração. Há uma taxa crescente da população que sofre de doenças cardiovasculares, incluindo arritmia (XIONG; STILES; ZHAO, 2017). A morte súbita por arritmia cardíaca é um grande problema de saúde pública em todo o mundo, sendo responsável por 15% a 20% de todas as mortes. Estima-se que 180.000 a 300.000 mortes cardíacas súbitas ocorram anualmente nos EUA (SRINIVASAN; SCHILLING, 2018).

No diagnóstico clínico de doença cardíaca, a arritmia indica uma alteração grave na função dos batimentos cardíacos e pode causar um acidente vascular cerebral ou morte súbita cardíaca se não tratada (YANG et al., 2018a). Para detecção de anomalias cardíacas, o uso do Eletrocardiograma (ECG) é um diagnóstico fundamental. Essa análise clínica pode realizar o monitoramento de doenças cardiovasculares, onde esse procedimento é feito manualmente. No entanto, existem vários problemas com a análise manual de sinais de ECG, tais como: similaridade com outros dados de séries temporais, dificuldade em detectar e categorizar diferentes formas de onda e morfologia do sinal. Para um ser humano, esta tarefa é demorada e sujeita a erros (DEY et al., 2017), (SARAIVA et al., 2018).

Para resolver problemas com análise manual de imagens de CXR e sinal de ECG, muitos estudos na literatura usam técnicas de aprendizado de máquina para detectar anomalias nas imagens e nos sinais, (HEIDARI et al., 2020), (ISLAM; ISLAM; ASRAF, 2020), (MARTIS et al., 2013), (APOSTOLOPOULOS; MPESIANA, 2020), (LI; ZHOU, 2016), (ACHARYA et al., 2017a). Porém, nessas abordagens não é proposta uma aplicação final aos modelos de aprendizagem, uma aplicação final é importante porque a taxa de mortalidade causada por essas anomalias é elevada, como já mencionado.

Os avanços tecnológicos e o aumento do poder computacional possibilitam o uso de técnicas que podem auxiliar no diagnóstico clínico, como as Redes Neurais bioinspiradas artificiais em neurônios humanos. Como exemplo, Redes Neurais Convolucionais (Convolutional Neural Networks - CNNs) (SOUSA et al., 2020a), (SARAIVA et al., 2019). Mas as CNNs exigem um alto custo computacional nas aplicações finais, o que torna o desenvolvimento desses aplicações em dispositivos móveis uma tarefa

desafiadora.

Com o desenvolvimento de novos modelos computacionais otimizados é possível realizar análise de dados biomédicos (imagens, sinais) com maior precisão, agilidade e utilizando menos recursos computacionais, possibilitando a execução destes modelos em dispositivos móveis. A compressão de sinais é uma estratégia para ser utilizada no armazenamento e/ou transmissão de dados. Na transmissão dos dados é essencial para minimizar o consumo de dados ao transmitir sinais como o ECG para outro profissional de saúde, podendo ser uma ferramenta de apoio para diagnóstico médico.

O trabalho de (SARAIVA et al., 2019) mostra que o ECG tem melhor taxa de compressão e reconstrução com técnicas específicas ou seja, a escolha da técnica utilizada para compressão do sinal pode ser de vital importância no diagnóstico dado pelo profissional, além disso dependendo do sinal a técnica escolhida muda pois cada sinal se comporta de maneira diferente dependendo da técnica de compressão a qual foi submetido, o que pode alterar nos dados recuperados após a reconstrução como diz o trabalho de (SOUSA et al., 2020b).

Neste trabalho apresentaremos o desenvolvimento de três aplicações distintas para otimizar a análise de dados biomédicos. A primeira aplicação trata-se de um aplicativo móvel (CNN-Pumona) para análise de imagens de CXR, a segunda aplicação consiste em outro aplicativo para analisar ECG (CNN-Cardio), tais aplicações têm com o propósito de auxiliar os profissionais de saúde nos diagnósticos de doenças pulmonares e cardíacas executando os aplicativos em seus próprios dispositivos móveis. Além disso, a terceira aplicação consiste na definição da estratégia de compressão de sinais, para possibilitar o melhor armazenamento das informações em base de dados e transmissão do ECG para solicitar o apoio do diagnóstico com outro profissional de saúde especializado, também é realizada uma análise de como diferentes sinais biomédicos se comportam ao aplicar diferentes técnicas de compressão, os sinais usados foram ECG, Eletroencefalograma (EEG), Eletromiografia (EMG), e Eletrooculografia (EOG). As três aplicações são descritas melhor abaixo:

- O sistema para análise de imagens de CXR consiste em um aplicativo móvel (CNN-Pulmonar), capaz de identificar se o paciente tem ou não Pneumonia, caso tenha o mesmo identifica o agente causador, podendo ser Pneumonia Bacteriana, Pneumonia Viral causada por Covid-19 ou Pneumonia Viral causada por outros vírus.
- O sistema para análise de ECG consiste em um sistema de classificação móvel (CNN-Cardio), capaz de classificar diferentes arritmias de acordo com o padrão EC57 do Advancement of Medical Instrumentation (AAMI) (INSTRUMENTATION

et al., 1998), (KACHUEE; FAZELI; SARRAFZADEH, 2018): Batimento normal, Batimento prematuro supraventricular, Contração ventricular prematura , Fusão de batimento ventricular e normal, Batimento inclassificável.

- Posteriormente, a comparação e a definição do método de compressão de sinais, no caso de enviar ao profissional registros de ECG, também é aferido o método de compressão de sinais para outros sinais biológico, o EMG, por exemplo (SARAIVA et al., 2020b).

Esta tese é composta de múltiplas contribuições, todas conectadas pelo elo comum de dados (imagens e/ou sinais) biomédicos passíveis de serem analisados por meio de metodologias computacionais implementáveis em dispositivos móveis, das quais podemos elencar as principais: a meta-heurística desenvolvida para a construção dos aplicativos móveis, onde são analisadas e combinadas técnicas existentes na literatura. Com isso foi possível o desenvolvimento de ferramentas portáteis, promissoras e funcionais para análise de dados biomédicos. Outra contribuição notável presente, é a inovação tecnológica contida nesta tese, onde são desenvolvidos dois aplicativos móveis capazes de classificar arritmias e doenças pulmonares de forma offline, vale ressaltar que até o presente momento são aplicações inéditas na literatura.

## 2 OBJETIVOS

### 2.1 OBJETIVO GERAL

Desenvolver modelos computacionais para compressão de sinais biomédicos e classificação de pneumonias e arritmias considerando respectivamente os dados biométricos de imagens de Raio-X do tórax e sinais ECG.

### 2.2 OBJETIVOS ESPECÍFICOS

- Desenvolver o sistema CNN-Pulmona para aplicativo móvel Android, capaz de identificar se o paciente tem ou não Pneumonia, caso tenha o mesmo identifica o agente causador, podendo ser Pneumonia Bacteriana, Pneumonia Viral causada por Covid-19 ou Pneumonia Viral causada por outros vírus.
- Desenvolver o sistema CNN-Cardio para aplicativo móvel Android, capaz de identificar se o paciente tem ou não doença cardíaca, podendo ser diferentes arritmias.
- Escolher e comparar e escolher as técnicas de compressão de dados mais adequadas para serem aplicadas em cada tipo de sinal biomédico analisado, e que necessitará ser enviado com o mínimo de distorção e/ou perda de informações.
- Analisar o consumo de memória e processamento de modelos embutidos em dispositivos móveis, e analisar em quais cenários a implantação em dispositivos móveis para uso offline pode ser viável.
- Analisar os impactos na precisão e custo computacional, ao aplicar potenciais técnicas de redução de modelos de CNNs propostas na literatura, a fim de embarcá-los em dispositivos móveis.

## 3 MOTIVAÇÃO

O aumento das doenças pulmonares e cardiovasculares são a motivação deste trabalho de doutorado, para desenvolver aplicativos móveis capazes de auxiliar profissionais da saúde no combate de Covid-19, através da aplicação de modelos computacionais para automatizar a classificação de imagens do Raio-X do Tórax de pacientes com suspeita de Pneumonia e análise de sinais de eletrocardiograma de pacientes com alterações no batimento cardíacos.

Os aspectos motivacionais relevantes deste estudo resultaram nas soluções desenvolvidas para análise automática e otimizada de dados biomédicos; nesse caso, os aplicativos móveis (CNN-Pulmona) e (CNN-Cardio). Com isso, é possível minimizar os aspectos negativos dos cenários descritos anteriormente. Para isso um estudo e uma análise aprofundada dos métodos para classificação de imagens e sinais foi realizado. Cabe ressaltar que tais métodos até o presente momento ainda não tinham sido usados para o propósito deste trabalho e, portanto, tornaram-se fatores adicionais de motivação. Nesse contexto, pode-se citar: um método de classificação em cascata automático em um dispositivo móvel usando uma CNN pré-treinada para classificar imagens de Raio-X do tórax e um método de classificação automático de sinais ECG em dispositivo móvel utilizando uma CNN com o objetivo de identificar diferentes arritmias.

Para que esses modelos de aprendizagem pudessem obter um bom desempenho com relação aos já existentes na literatura, foi analisado e utilizado algumas técnicas de otimização para esses modelos de CNNs, essa otimização consiste em ganho de desempenho e também em redução de custo computacional, o que é vital para o desenvolvimento das aplicações em dispositivos móveis.

Adicionalmente, em virtude de uma motivação por fidedignidade e rapidez na transmissão de sinais biomédicos, foram analisadas as técnicas de compressão de sinais e realizado a definição da técnica mais otimizada e com menor perda de sinais, para que se torne viável poupar espaço de armazenamento e banda na transmissão destes dados, como um módulo à ser adicionado posteriormente no CNN-Cardio.

## 4 REVISÃO DA LITERATURA

A Revisão da Literatura é dividida em duas seções: Trabalhos Relacionados e Fundamentação Teórica. Na primeira seção é expressado os principais trabalhos identificados na literatura sobre os temas tratados neste trabalho. Posteriormente, na seção de Fundamentação Teórica, são enunciados os conceitos da literatura relevantes para modelagem deste trabalho.

### 4.1 TRABALHOS RELACIONADOS

Um estudo propõe uma abordagem de triagem de Raio-X torácico, que em vez de usar diretamente as imagens originais de raios-X de tórax para treinar modelos de aprendizado profundo, aplicam algoritmos de processamento de imagem para remover áreas indesejáveis, normalizar o contraste e reduzir o ruído da imagem, gerando um pseudo imagem colorida para alimentar 3 canais de entrada dos modelos atuais de aprendizado profundo que foram pré-treinados usando imagens coloridas (RGB) no processo de aprendizado de transferência. Para testar a hipótese o autor utiliza um dataset com 3 classes: Pneumonia Viral, Pneumonia Adquirida por Covid-19 e Normal. Em seguida utilizam um modelo baseado na CNN pre-treinada VGG16 usando a técnica de aprendizado por transferência obtendo uma precisão geral de 94.5% na classificação de 3 classes e 98,1% na classificação de casos com e sem infecção por Covid-19 (HEIDARI et al., 2020).

Outro trabalho utiliza uma rede CNN *Long Short-Term Memory* (CNNLSTM) profunda para a detecção do novo Covid-19 a partir de imagens de raios-X. O método proposto faz uso da CNN como um extrator de recursos e a rede LSTM funciona como um classificador para a detecção de coronavírus. O desempenho do sistema proposto é melhorado pela combinação de recursos extraídos com LSTM que diferenciam os casos Covid-19 de outros. O sistema desenvolvido obteve uma precisão de 99,4% (ISLAM; ISLAM; ASRAF, 2020).

O trabalho de (KARTHIK; MENAKA; HARIHARAN, 2020) propõe uma arquitetura de CNN dual-ramificada de canal aleatório para detectar Covid-19 através de radiografias de tórax. O algoritmo proposto aprende exclusivamente filtros convolucionais distintos para cada rótulo. Isso é feito restringindo certos filtros para responder ao máximo apenas a uma classe particular de pneumonia/Covid-19. Também fornece visualizações dos filtros top-k que são aprendidos para identificar classes de destino específicas. Além disso, as regiões salientes no Raio-X que influenciam a previsão da classe CNN são apresentadas para auxiliar a localização da infecção. A proposta

CSDB CNN atingiu uma precisão média de 93,42% na classificação das quatro classes alvo.

O trabalho de (GAO; WANG, 2020) utiliza o método de aprendizagem supervisionada como o processo de aprendizagem a partir do conjunto de dados de treinamento, obtendo uma precisão média acima de 95%. A CNN profunda é baseada no VGG-19 e tem como objetivo distinguir a pneumonia Covid-19 da pneumonia não Covid-19, logo em seguida, este CNN profundo é usado para distinguir pneumonia viral de bacteriana.

O artigo proposto por (PANTELOPOULOS; BOURBAKIS, 2010) apresenta a estrutura de design do sistema vestível *Prognosis*, que visa realizar o monitoramento contínuo e da saúde de pessoas em risco, além de fornecer suporte de decisão integrado para melhorar o gerenciamento ou prevenção de doenças. O esquema funcional do sistema é construído em cima de uma linguagem formal para descrever e fundir sintomas de saúde que são extraídos das medições adquiridas de uma variedade de sensores vestíveis, que podem ser distribuídos ao longo do corpo de um paciente. Além disso, ao incorporar um sistema de diálogo automatizado inteligente e interativo, um *feedback* do estado de saúde adicional pode ser obtido do usuário em termos de sintomas descritos, capturados usando um módulo de reconhecimento de voz, que pode aumentar ainda mais as capacidades de decisão autônoma do sistema. Uma estrutura de simulação construída em Java também é apresentada, que foi usada para modelar a operação baseada em eventos do *Prognosis* e para capturar os problemas de simultaneidade que surgem em tal projeto de sistema.

O autor (PANDEY et al., 2019) propôs um novo sistema biomédico para detecção de arritmia e convulsão automatizada e eficiente em sinais biomédicos como ECG e eletroencefalografia (EEG). Foi usada uma rede residual profunda em várias camadas, automatizada e em vários estágios para a detecção de anomalias nos sinais biomédicos. O algoritmo proposto é validado nas bases de dados de referência publicamente disponíveis MIT-BIH Arrhythmia e CHB-MIT Scalp. Os resultados mostram uma melhora significativa em termos de sensibilidade de 90% e 97,1% para batimentos supraventriculares e ventriculares, respectivamente. Um bom ponto é que o método proposto fornece resultados confiáveis com amostras de EEG de pequena duração. O algoritmo proposto fornece sensibilidade de 81% para detecção de crises em sinais de EEG.

A realidade virtual e aumentada vem tendo um crescimento constante na medicina nos últimos anos. Ao mesmo tempo, as imagens radiológicas têm papel central no diagnóstico e planejamento das abordagens cirúrgicas. Dessa maneira, (IZARD et al., 2019) apresenta uma tentativa de visualização aprimorada de imagens radiológicas por meio de realidade virtual e aumentada para melhor planejamento e moni-

toramento das cirurgias. Esta aplicação permite ir além das imagens bidimensionais tradicionais para modelos tridimensionais que podem ser visualizados e manipulados tanto com Realidade Aumentada como com Realidade Virtual. Assim, o (IZARD et al., 2019) propôs possíveis abordagens para automatizar a segmentação de imagens radiológicas, utilizando técnicas de visão computacional e Inteligência Artificial.

No trabalho proposto por (SERRA; GALDI; TAGLIAFERRI, 2019), foram revisadas as metodologias existentes para discutir modos e princípios de operação, com o objetivo de aumentar o desenvolvimento no campo biomédico. Assim, organizou os métodos descritos em três categorias, de acordo com o tipo de dados, o problema estatístico e o tipo de integração. Neste trabalho destaca as vantagens e desvantagens de diferentes tipos de pensamento, pretendendo ser uma referência para quem deseja começar a trabalhar com integração de dados biomédicos. Série de exemplos representativos em bioinformática e neuroinformática são demonstrados, para mostrar o potencial das aplicações de aprendizagem multivistas para determinados problemas. Após demonstrar as técnicas na literatura, é proposto uma discussão de como as técnicas de aprendizagem profunda estão obtendo cada vez mais reconhecimento em vários campos pode ser aplicado a dados multimodais para aprender representações complexas, além alguns exemplos dessa aplicação.

O enorme crescimento de dados com relação a área da engenharia biomédica representa um grande desafio para a análise e processamento de dados. Esse grande volume de aproveitamento de dados biomédicos leva a um grande desafio. Uma maneira de resolver os problemas dessas naturezas é proposto por (DAS; NAIK; BEHERA, 2020), onde compara as medidas de desempenho de vários algoritmos de classificação de aprendizado de máquina em dados biomédicos. Os vários algoritmos de classificação, como árvore de decisão, K-vizinhos mais próximos, Naive Bayes, máquina de vetor de suporte linear, máquina de vetor de suporte de função de base radial, máquina de vetor de suporte polinomial, *Random Forest* e *Adaboost* são usados para o processo de classificação para medir a precisão da classificação com 14 conjuntos de dados biomédicos. Observa-se que a natureza do conjunto de dados tem impacto muito forte no desempenho dos classificadores. O desempenho de todos os algoritmos de classificação mencionados é analisado em 14 conjuntos de dados biomédicos e observado que o classificador *Adaboost* supera em desempenho dos demais classificadores abordados.

O trabalho de (SHAKER et al., 2020), propõe uma nova técnica de aumento de dados usando Redes Adversárias Gerativas (GANs), para balancear as classes do Dataset MIT-BIH Arrhythmia. Eles usam duas abordagens de aprendizagem profunda: a) Uma abordagem ponta a ponta e uma abordagem hierárquica de dois estágios, b) Com base em CNNs. Os resultados mostram que, com o aumento dos dados gerados pela técnica proposta, é possível observar uma melhora efetiva no desempenho da

classificação do ECG em relação à classificação do conjunto de dados original.

No trabalho de (LIU et al., 2019), propôs um algoritmo baseado no CNN capaz de classificar a arritmia cardíaca pelo ECG. Comparar diferentes modelos da CNN e depois usá-los para aumentar a taxa de acerto na classificação, combinando a Análise Discriminante Linear (LDA) e a Máquina de Vetor de suporte (SVM). O banco de dados de arritmia do MIT-BIH também foi utilizado neste trabalho, onde os autores obtiveram um resultado de 91,29% correto.

Em (KUMAR; PAWAR; O'REILLY, 2019), apresenta um método de classificação de ECG, que utiliza uma técnica de pré-processamento generalizado de sinal e utiliza uma rede Perceptron Multicamadas para a tarefa de classificação de arritmias, de acordo com a norma AAMI EC57. O método é treinado e avaliado por meio do conjunto de dados PhysioNet MIT-BIH, obtendo uma precisão média de 98,72%.

Em (ZIHLMANN; PEREKRESTENKO; TSCHANNEN, 2017) explica o uso de duas arquiteturas de Redes Neurais Profundas (DNNs) para classificação de ECG avaliando o conjunto de dados de classificação de fibrilação atrial fornecido pelo *PhysioNet/CinC Challenge 2017*. A primeira arquitetura é uma CNN com agregação de recursos de média a comprimento. ao longo do tempo e segundo é uma rede neural recorrente convolucional que combina uma CNN de 24 camadas com uma rede de 3 camadas de memória de longo-curto prazo para agregação temporal de recursos.

## 4.2 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta alguns conceitos importantes para a realização do trabalho proposto, são os seguintes conceitos: Desenvolvimento de Aplicativos Móveis, Radiografia de Tórax e Sinal ECG, Doenças pulmonares, Arritmias Cardíacas, Inteligência Artificial e Métricas de Avaliação.

### 4.2.1 DESENVOLVIMENTO DE APLICATIVOS MÓVEIS NA SAÚDE

Os aplicativos para dispositivos móveis são uma parte cada vez mais importante da vida diária das pessoas e já representam a maioria dos sistemas computadorizados atualmente, mais de um milhão de aplicativos estão agora disponíveis para Android e iOS nas suas respectivas lojas (BÖHM; SCHREIBER, 2014). Criar aplicativos para dispositivos móveis requer diversos desafios, como: lidar com limitações tais como CPU, memória, tela, dispositivos de entrada, bateria, entre outros. À medida que os dispositivos crescem no mundo recentemente, o acesso à internet e a possibilidade de poder procurar aplicativos que podem facilitar a vidas das pessoas, ganham grande importância. As lojas de aplicativos permitem que os usuários pesquisem, comprem e

instalem aplicativos móveis e, em seguida, forneça *feedback* na forma de análises e classificações.

Um aplicativo pode extrair conteúdo e informações da internet de forma semelhante a um site, mas também pode baixar o conteúdo para que possa ser utilizado posteriormente na ausência de conexão com a Internet, o que é uma grande vantagem. Assim, os aplicativos que não precisam de conexão com a Internet podem ser usados "em qualquer lugar e em todo lugar", ou seja, o aplicativo pode ser usado offline.

Os aplicativos móveis atualmente se enquadram amplamente em três categorias: nativos, baseados na web e híbridos (JOORABCHI; MESBAH; KRUCHTEN, 2013). Os aplicativos nativos são executados no sistema operacional de um dispositivo e precisam ser adaptados para diferentes dispositivos. Os aplicativos baseados na web requerem um navegador da web em um dispositivo móvel. Aplicativos híbridos são aplicativos da web "nativos". Uma pesquisa recente revelou que os desenvolvedores estão principalmente interessados em construir aplicativos nativos, porque eles podem utilizar os recursos nativos do dispositivo (por exemplo, câmera, sensores, acelerômetro, geolocalização) (JOORABCHI; MESBAH; KRUCHTEN, 2013).

A introdução de dispositivos de computação móvel, causou um grande impacto em muitos campos, incluindo a medicina. Profissionais de saúde agora usam *smartphones* ou *tablets* para funções que antes precisavam de aparelhos específicos (VENTOLA, 2014). *Smartphones* e *tablets* combinam recursos de computação e comunicação em um único dispositivo que pode ser segurado com a mão ou armazenado em uma mochila, permitindo fácil acesso e uso no ponto de atendimento. Além de voz e texto, novos modelos de dispositivos móveis oferecem recursos mais avançados, como pesquisa na *web*, sistemas de posicionamento global, câmeras de alta qualidade e gravadores de som. Com esses recursos, bem como processadores e sistemas operacionais poderosos, memórias grandes e telas de alta resolução, os dispositivos móveis tornaram-se essencialmente computadores portáteis.

O uso de dispositivos móveis por profissionais de saúde transformou muitos aspectos da prática clínica. Os dispositivos móveis tornaram-se comuns em ambientes de saúde, levando a um rápido crescimento no desenvolvimento de aplicativos que usam *software* médico para essas plataformas (VENTOLA, 2014). Vários aplicativos estão agora disponíveis para auxiliar os profissionais de saúde em muitas tarefas importantes, como: gerenciamento de informações e tempo; manutenção e acesso aos registros de saúde; comunicações e consultoria; referência e coleta de informações; gerenciamento e monitoramento de pacientes; tomada de decisão clínica; educação e treinamento médico (VENTOLA, 2014).

## 4.2.2 TIPOS DE SINAIS BIOMÉDICOS

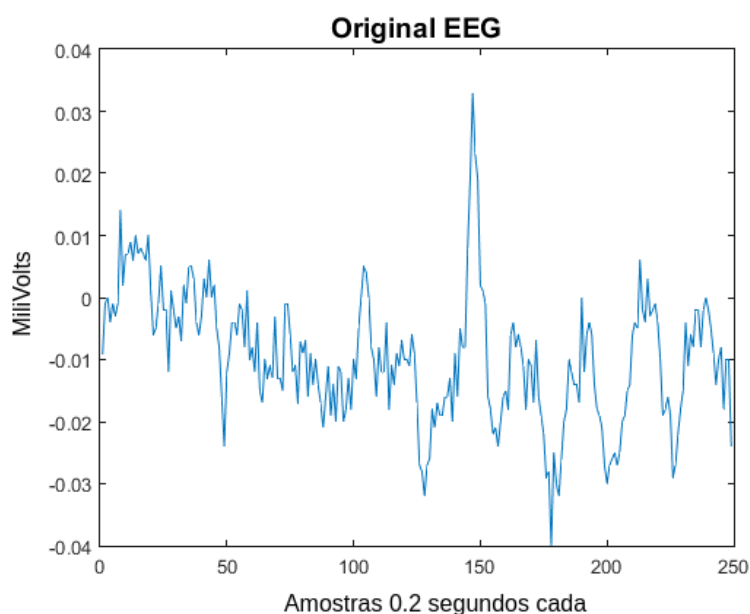
Existem diferentes tipos de sinais que podem ser captados do corpo humano todos eles influem de certa maneira em nossa saúde. Os sinais tratados a seguir são: ECG, EEG, Eletromiografia (EMG), e Eletrooculografia (EOG) .

### 4.2.2.1 EEG

O EEG é um método de monitoramento eletrofisiológico para registrar a atividade elétrica do cérebro. É tipicamente não invasivo, com os eletrodos colocados ao longo do couro cabeludo, embora eletrodos invasivos às vezes sejam usados, como na eletrocorticografia. O EEG mede as flutuações de voltagem resultantes da corrente iônica dentro dos neurônios do cérebro (SARAIVA et al., 2018). Em contextos clínicos, o EEG se refere ao registro da atividade elétrica espontânea do cérebro durante um período de tempo, conforme registrado a partir de vários eletrodos colocados no couro cabeludo.

As aplicações de diagnóstico geralmente se concentram em potenciais relacionados a eventos ou no conteúdo espectral do EEG. O primeiro investiga as flutuações potenciais do tempo bloqueado para um evento como o início do estímulo ou pressionamento de botão. Este último analisa o tipo de oscilações neurais, popularmente chamadas de "ondas cerebrais", que podem ser observadas em sinais de EEG no domínio da frequência (SARAIVA et al., 2019), um exemplo gráfico de um EEG pode ser visto na Figura 1.

Figura 1 – Exemplo de EEG.



Fonte: Autoria própria.

#### 4.2.2.2 EOG

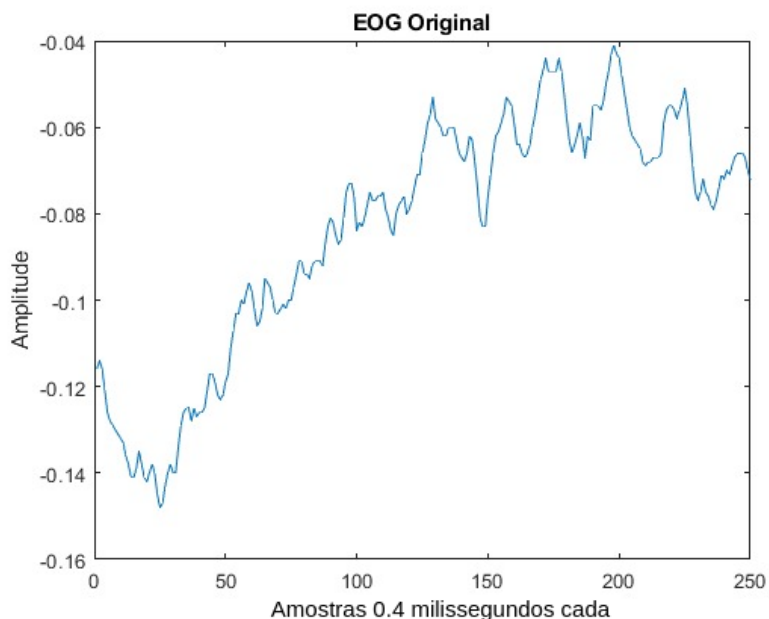
A EOG é uma técnica para medir o potencial ereto córneo-retiniano que existe entre a frente e o fundo do olho humano. O sinal resultante é chamado de EOG. As principais aplicações são no diagnóstico oftalmológico e no registro dos movimentos oculares. Ao contrário do eletrorretinograma, o EOG não mede a resposta a estímulos visuais individuais (BROWN et al., 2006).

Para medir o movimento dos olhos, pares de eletrodos são normalmente colocados acima e abaixo do olho ou à esquerda e à direita do olho. Se o olho se move da posição central em direção a um dos dois eletrodos, este eletrodo "vê" o lado positivo da retina e o eletrodo oposto "vê" o lado negativo da retina. Conseqüentemente, ocorre uma diferença de potencial entre os eletrodos. Assumindo que o potencial de repouso é constante, o potencial registrado é uma medida da posição do olho (SARAIVA et al., 2018).

A EOG é usada para registrar os movimentos dos olhos durante o teste eletro nistagmográfico. É baseado no potencial córneo-retiniano (diferença na carga elétrica entre a córnea e a retina), com o longo eixo do olho atuando como um dipolo. Os movimentos do olho em relação aos eletrodos de superfície colocados ao redor do olho produzem um sinal elétrico que corresponde à posição do olho. As gravações do movimento dos olhos são precisas em cerca de 0,5 grau, mas ainda são menos sensíveis do que a inspeção visual, que pode perceber movimentos de cerca de 0,1 grau. Portanto, a inspeção visual com lentes de Frenzel às vezes ainda é necessária para documentar nistagmo de baixa amplitude. Outra limitação da EOG é que os movimentos oculares de torção não podem ser monitorados. Novamente, a inspeção visual com lentes de Frenzel às vezes é necessária para documentar o nistagmo torsional (SARAIVA. et al., 2019), um exemplo gráfico de um EOG pode ser visto na Figura 2.

Felizmente, novas técnicas foram desenvolvidas para fornecer maior precisão e amplitude para testes oculomotores. A técnica mais útil clinicamente que foi desenvolvida é o sistema eletro nistagmográfico de vídeo infravermelho. Aqui, o paciente usa óculos de proteção que iluminam os olhos com luz infravermelha (invisível para o paciente), permitindo que uma pequena câmera de vídeo capte e projete uma imagem dos olhos em um monitor.

Figura 2 – Exemplo de EOG.



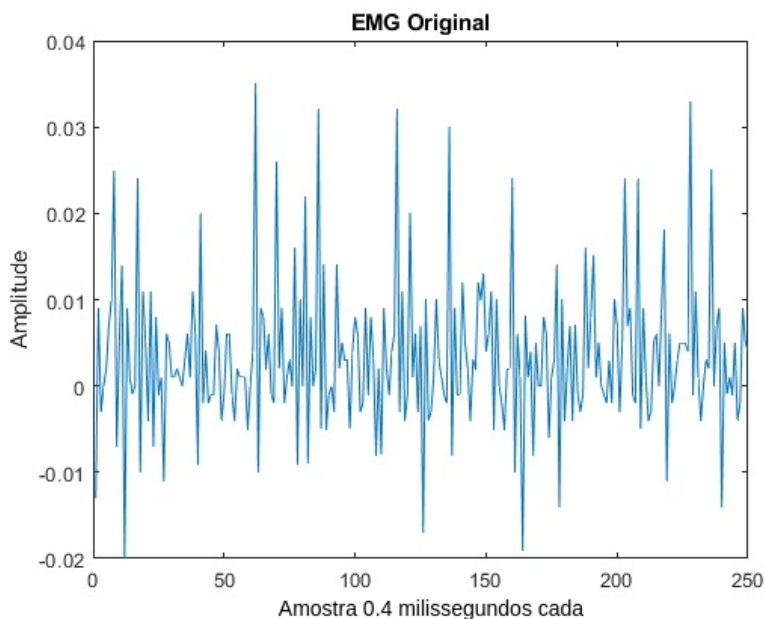
Fonte: Autoria própria.

#### 4.2.2.3 EMG

O EMG é o processo pelo qual um examinador coloca uma agulha em um determinado músculo e estuda a atividade elétrica desse músculo, essas atividades elétricas vêm do próprio músculo, não são usados choques para estimular o músculo, por isso é possível encontrar um músculo que apresentam um problema ou doença particular (SARAIVA et al., 2018).

A excitabilidade de uma fibra muscular através do controle neural representa um fator preponderante na fisiologia muscular, pois a EMG é uma técnica voltada para o desenvolvimento do registro e análise de sinais mio elétricos, os sinais captados por este processo são formados por variações fisiológicas no estado de membranas de fibras musculares, por isso algumas doenças e problemas podem ser detectados se a variação não seguir os padrões normais sob pequenas exceções, há outra forma de medir a EMG, é a EMG neurológica, desta forma choques elétricos são utilizados para estimular o músculo, mas neste trabalho será abordada a EMG cinesiológica, neste tipo apenas as respostas naturais do músculo são tomadas como objeto de estudo então para que sejam utilizadas para captar o sinal (SARAIVA et al., 2019), um exemplo gráfico de um EMG pode ser visto na Figura 3.

Figura 3 – Exemplo de EMG.



Fonte: Autoria própria.


#### 4.2.2.4 ECG

Para entender os princípios de um ECG, vamos primeiro entender como o coração produz sinais elétricos. Para um coração normal e saudável, em repouso, um ECG exibe uma série de ondas que refletem as diferentes fases de um batimento cardíaco. O ECG começa no nodo sinoatrial, também conhecido como nodo SA, que está localizado no átrio direito e atua como marca-passo no coração (APPATHURAI et al., 2019). Os sinais elétricos causam a contração atrial, forçando o sangue para os ventrículos. Essa sequência é registrada como a onda P no ECG. Esse sinal então passa dos átrios para os ventrículos, fazendo com que eles se contraiam e bombeiem o sangue para o resto do corpo. Isso é registrado como o complexo QRS.

Um sinal de eletrocardiograma é a expressão da atividade elétrica do miocárdio na superfície corporal, que aparece como um sinal quase periódico. É bem conhecido que o ECG contém muitas informações sobre doenças cardíacas. Um único ciclo normal do ECG representa a despolarização / repolarização arterial e despolarização/repolarização ventricular sucessivas, que ocorrem a cada batimento cardíaco, desse modo, tradicionalmente, o ciclo de ECG é rotulado com as letras P, Q, R, S e T para os picos individuais de toda a forma de onda do ciclo (YEH; WANG, 2008). O diagnóstico é realizado com base em características extraídas da época e morfologia desses pontos fiduciais. Portanto, a detecção do ECG é muito importante para que os médicos façam um diagnóstico clínico correto, um exemplo gráfico de um ECG pode ser visto na Figura 4.

A partir do momento que os sinais de ECG são utilizados com bastante frequência para reconhecer muitas variabilidades da atividade cardíaca, é muito importante obter os parâmetros do sinal de ECG claros sem ruído (ALFAOURI; DAQROUQ, 2008). Esta etapa fornece um quadro completo e informações detalhadas sobre a eletrofisiologia das doenças cardíacas e as alterações isquêmicas que podem ocorrer, como infarto do miocárdio, defeitos de condução e arritmia. Portanto, uma coleta de um sinal ruidoso levaria a interpretações equivocada acerca do quadro clínico do paciente examinado.

Figura 4 – Exemplo de ECG.



Fonte: Autoria própria.

### 4.2.3 ARRITMIAS CARDÍACAS

Arritmias são anormalidades na frequência, ritmo ou em ambos, ou seja, são distúrbios das propriedades elétricas do coração. Podem ocorrer dois tipos principais de distúrbios, uma anormalidade na geração de um impulso elétrico (anormalidade na automaticidade) ou uma anormalidade na condução do impulso após a geração do impulso (anormalidade na propagação) (DANIELE et al., 2002). De outra perspectiva, as arritmias podem ser divididas em bradiarritmias (arritmias lentas) e taquiarritmias (arritmias rápidas). Ainda de outra perspectiva, as arritmias podem ser classificadas com base no sítio anatômico de origem, ou seja, atrial, atrioventricular (AV) juncional ou ventricular (ocorrendo abaixo da bifurcação do feixe de His) (DOWD, 2007).

O desenvolvimento de taxas ou ritmos anormais tem muitas causas (SHIH et al., 1988; SEFEROVIĆ et al., 2006). Algumas dessas causas são primárias e outras são secundárias (WIT; ROSEN, 1983). As causas primárias são aquelas que ocorrem

no coração. As causas secundárias são aquelas que resultam de forças externas que agem indiretamente sobre o coração para causar uma mudança em sua taxa ou ritmo. Se a arritmia for secundária (FURLANELLO et al., 2007; WAMBOLDT et al., 2019), é melhor tratar a causa subjacente do que simplesmente tentar normalizar o ritmo cardíaco com medicamentos e ignorar o que causou a mudança em primeiro lugar.

Existem vários tipos de arritmias cardíacas (SOUSA et al., 2018a), nas quais podem ser vistos abaixo os tipos usados para a detecção proposto neste trabalho:

- Batimento supraventricular prematuro:

Os batimentos supraventriculares prematuros são gerados no átrio e podem ser de duas formas: batimentos prematuros atriais ou batimentos prematuros da junção AV (BRAMBILA, 2008).

Os batimentos prematuros atriais apresentam ondas P e complexos QRS normais, mas o intervalo P-R entre o batimento precedente e o batimento prematuro é mais curto enquanto o intervalo entre o batimento prematuro e o batimento seguinte é mais longo (VIKMAN et al., 2005). Os batimentos prematuros de junção AV, por sua vez, são gerados por impulsos elétricos na região inferior do átrio direito ou em células próximas ao feixe de His (SHERF; JAMES, 1972).

- Contração prematura ventricular:

Uma contração ventricular prematura é o batimento cardíaco muito rápido originários dos ventrículos e perturba o ritmo cardíaco normal, ou seja, são batimentos cardíacos extras que começam em uma das duas câmaras de bombeamento inferiores (ventrículos) (CHA et al., 2012). Essas batidas extras interrompem seu ritmo cardíaco regular, às vezes fazendo com que seja uma vibração ou uma batida saltada no peito (WANG et al., 2014).

- Fusão de batimento ventricular:

Um batimento de fusão ocorre quando impulsos elétricos de fontes diferentes acontecem na mesma região do coração simultaneamente (BORIANI et al., 2005). Se atuar sobre as câmaras ventriculares, é denominado batimento de fusão ventricular, ao passo que as correntes de colisão nas câmaras atriais produzem batimentos de fusão atrial (GIANFRANCHI et al., 2008).

#### 4.2.4 DOENÇAS PULMONARES

Os pulmões são parte de um sistema complexo, que se expande e relaxa milhares de vezes ao dia para trazer oxigênio e enviar dióxido de carbono. A doença

pulmonar pode ocorrer quando há problemas em qualquer parte deste sistema fundamental para o ser humano. A doença pulmonar pode afetar a função respiratória, ou a capacidade de respirar, e a função pulmonar, que é a maneira como os pulmões funcionam (BANASCHEWSKI; HOFMANN, 2019).

As doenças pulmonares são algumas das condições médicas mais comuns do mundo, onde refere-se a vários tipos de doenças ou distúrbios que impedem o funcionamento adequado dos pulmões (WORLD HEALTH, 2016). Dezenas de milhões de pessoas têm doenças pulmonares apenas nos EUA. Sendo causado por diversos fatores, como fumar, infecções, poluições e genes causam a maioria das doenças pulmonares.

Existem muitas doenças pulmonares diferentes, algumas das quais são causadas por infecções bacterianas, virais ou fúngicas. Outras doenças pulmonares estão associadas a fatores ambientais, incluindo asma, mesotelioma e câncer de pulmão (BANASCHEWSKI; HOFMANN, 2019). A partir das doenças respiratórias, a pneumonia consiste em uma doença comum e grave. A cada ano nos Estados Unidos, aproximadamente 15% das 600.000 pessoas afetadas que são admitidas no hospital morrem da doença (MARRIE et al., 2000). As análises de dados administrativos mostram que existem grandes variações nas taxas de admissão, tempo de internação hospitalar e uso de recursos institucionais (MARRIE et al., 2000).

#### 4.2.4.1 PNEUMONIA VIRAL


Sabe-se hoje da existência de 1.200 vírus que infectam o trato respiratório, embora muitos deles, provavelmente, não causem doença (FIGUEIREDO, 2009a). Como consequência de infecções do trato respiratório por vírus, destacam-se duas doenças muito comuns, mas de difícil distinção: o resfriado e a gripe. Entretanto, os vírus também podem acometer o trato respiratório baixo, causando bronquiolite, bronquite e pneumonia (FIGUEIREDO, 2009a). As infecções virais mais comuns são: vírus sincicial respiratório (RSV), parainfluenza, adenovírus e vírus influenza (GARG et al., 2019).

A pneumonia viral é definida como uma doença na qual há anormalidades nas trocas gasosas no nível alveolar acompanhadas de inflamação do parênquima pulmonar (FIGUEIREDO, 2009b). O fenômeno inflamatório pulmonar comumente se traduz em anormalidades de imagem que são detectáveis por Raios-X ou TC. Na pneumonia viral, os perfis clínicos são bastante variados, dependendo do agente infeccioso, bem como da idade e do estado imunológico do hospedeiro. No entanto, além de causar pneumonia primária, os vírus prejudicam os mecanismos de defesa do trato respiratório local por danificar a mucosa do trato respiratório, favorecendo o aparecimento de pneumonia bacteriana secundária. Além disso, algumas doenças crônicas,

como DPOC e insuficiência cardíaca, e até mesmo a gravidez, foram descritas como associadas a um maior risco de pneumonia viral (FIGUEIREDO, 2009b).

Para o diagnóstico da pneumonia viral, o médico começa fazendo alguns testes físicos no paciente. Como parte do exame, o médico irá ouvir os pulmões para verificar se possuem sons pulmonares que indicam a presença de pneumonia. Esses sons podem incluir estalidos nos pulmões ou respiração ofegante. O médico também verificará se há aumento da frequência cardíaca e diminuição do fluxo de ar. Se o médico suspeitar da presença de pneumonia, é provável que ele solicite alguns dos seguintes exames: Raio-X do tórax, podendo ser visto de acordo com a Figura 5, cotonete nasal para verificar a existência de vírus, cultura de escarro do muco dos pulmões exames de sangue, incluindo um hemograma completo para procurar marcadores inflamatórios e teste de gasometria arterial.

Figura 5 – Imagem de Raio-X de pacientes com pneumonia viral.



Fonte: Imagens da base de dados do *Chest Xray Coronahack*

(COHEN et al., 2020)

Para fazer a detecção da Pneumonia viral, o médico responsável pode observar algumas características na imagem. O Influenzavírus pode mostrar na radiografia de uma pessoa com esse tipo de pneumonia que: consolidação segmentar com predominância basal; opacidades de vidro fosco bilateral difuso; nódulos centrolobulares e espessamento da parede brônquica (RIQUELME et al., 2011). Nenhuma diferença é observada nos achados radiológicos de pneumonias causadas por influenza tipo A ou B ou vários subtipos de A (SCHEIBLAUER et al., 1992). O vírus Sincicial Respiratório é a causa mais comum de infecção viral do trato respiratório inferior em crianças, causando bronquiolite e broncopneumonia, em que pode ser comum: infiltrados peribrônquicos com hiperinsuflação associada; às vezes, colapso ou consolidação lobar ou linfonodos hilares aumentados; nódulos centrolobulares e aparência de árvore em brotamento (JAFRI et al., 2004). O adenovírus também é conhecido como vírus do resfriado comum, que às vezes pode causar pneumonia e pode predominar: opacidades irregulares ou confluentes dispersas e linfadenopatia hilar; consolidação bilateral; áreas de opacidades de vidro fosco; nódulos e derrame pleural (HAKIM; TLEYJEH,

2008). Alguns casos pode se assemelhar uma pneumonia causada pelo adenovírus com pneumonia bacteriana (GARG et al., 2019). A infecção por citomegalovírus é comum: consolidação; opacidades de vidro fosco, opacidades reticulares irregulares ou nódulos centrolobulares (CUNHA, 2010). A pneumonia por varicela é mais comum em adultos, os padrões podem ser: pequenos nódulos acinares discretos espalhados por ambos os pulmões ou/e vários pequenos nódulos aleatórios (MOHSEN; MCKENDRICK, 2003).


#### 4.2.4.2 PNEUMONIA BACTERIANA

A pneumonia bacteriana é uma infecção dos pulmões causada por certas bactérias. O mais comum é o *Streptococcus* (pneumococo), mas outras bactérias também podem causá-lo, como *Haemophilus influenzae*, *Mycoplasma pneumoniae*, *Chlamydia pneumoniae* e *Legionella pneumophila*. Em uma pessoa jovem e basicamente saudável, essas bactérias podem viver na garganta sem causar problemas. Mas se as defesas do seu corpo (sistema imunológico) ficarem fracas por algum motivo, a bactéria pode descer para os pulmões e depois se multiplica. Quando isso acontece, os sacos de ar nos pulmões infeccionam e inflamam. Eles se enchem de líquido e isso causa pneumonia (PEYRANI et al., 2019).

A pneumonia por *Streptococcus* é a principal causa de pneumonia bacteriana. Pode entrar nos pulmões por inalação ou pela corrente sanguínea. *Haemophilus influenzae* é a segunda causa mais comum de pneumonia bacteriana. Esta bactéria pode viver em seu trato respiratório superior. Normalmente não causa danos ou doenças, a menos que você tenha um sistema imunológico enfraquecido (MIYASHITA; YAMAUCHI, 2018).

Existe alguns meios para poder diagnosticar pneumonia bacteriana, em geral, o médico poderá: ouvir os sons torácicos anormais que indiquem uma forte secreção de muco; Retirar uma amostra de sangue para determinar se sua contagem de leucócitos está alta, o que geralmente indica infecção; Faça uma hemocultura, que pode ajudar a determinar se a bactéria se espalhou para a corrente sanguínea e também ajuda a identificar a bactéria que está causando a infecção; Retire uma amostra de muco ou cultura de escarro para identificar a bactéria que causa a infecção; (SATTAR; SHARMA, 2020) Solicite radiografias de tórax para confirmar a presença e extensão da infecção, mostrado na Figura 6.

Figura 6 – Raio-X de pacientes com pneumonia bacteriana.



Fonte: Imagens da base de dados do *Chest Xray Coronahack*  
(COHEN et al., 2020)


Para poder diferenciar a Pneumonia bacteriana a partir do Raio-X torácico, o radiologista e o médico responsável pelo diagnóstico deverá observar alguns aspectos contido no Raio-X, lembrando que podem ocorrer padrões que não possa ser comum (GARG et al., 2019). A Pneumonia causado pela bactéria *Streptococcus* pode ser comum que: pneumonia lobar é a aparência de imagem predominante nos casos; envolve predominantemente os lobos inferiores (podendo ser vista na figura 6); o volume pulmonar não é alterado; cavitação é rara; uma pequena quantidade de derrame pleural reativo é geralmente observada; áreas irregulares de consolidação que podem ser multilobares ou bilaterais foram observadas em pacientes (ANDRADE et al., 2018). *Mycoplasma pneumoniae*, geralmente afeta jovens, pode predominar: opacidades reticulonodulares ou áreas irregulares de consolidações; nódulos centrolobulares, opacidades de vidro fosco e áreas lobulares de consolidação com espessamento da parede brônquica (DAXBOECK; KRAUSE; WENISCH, 2003). A *Legionella pneumophila*, podendo ser causada pela inalação de gotículas de água contaminada, predomina: mostra uma consolidação de rápida progressão, que geralmente é segmentar e periférica inicialmente e torna-se bilateral na maioria dos casos; o Raio-X mostra multilobar ou multissegmentar do espaço aéreo intercalada com opacidades de vidro fosco (CARRATALA et al., 1994). Entre os *anaeróbios*, *Bacteroides*, *Fusobacterium* e *Actinomyces*, são comuns que: afeta os segmento posterior dos lobos superiores e os segmentos superiores dos lobos inferiores do paciente; pulmão direito geralmente está mais envolvido do que o esquerdo; um padrão de broncopneumonia é visto variando de áreas segmentares de opacidades bilaterais irregulares a doença confluyente extensa; podem apresentar cavitação ou formação de abscesso (GARG et al., 2019).

#### 4.2.4.3 PNEUMONIA POR COVID-19

Covid-19 é uma doença causada pelo SARS-CoV-2 que pode desencadear o que os médicos chamam de infecção do trato respiratório. Pode afetar o trato respiratório superior (seios da face, nariz e garganta) ou o trato respiratório inferior (traqueia e pulmões) (MO et al., 2020). O SARS-CoV-2 é um dos sete tipos de coronavírus, incluindo os que causam doenças graves como a síndrome respiratória do Oriente Médio (MERS) e a síndrome respiratória aguda súbita (SARS) (LANA et al., 2020). Os outros coronavírus causam a maioria dos resfriados que nos afetam durante o ano, mas não são uma ameaça séria para pessoas saudáveis.

Os testes de diagnóstico para Covid-19 se enquadram em duas categorias principais: testes moleculares que detectam RNA viral e testes sorológicos que detectam imunoglobulinas anti-SARS-CoV-2 (ZHAI et al., 2020). O método mais comum de teste é feito através do cotonete, em que procura sinais do vírus no trato respiratório superior. A pessoa que está aplicando o teste coloca um cotonete em seu nariz para obter uma amostra da parte de trás do nariz e da garganta. O teste de anticorpos é outro teste que pode ser feito, ele mostrar se a pessoa já foi exposta ao vírus, mesmo que não tenha sintomas. Na Figura 7 pode ser visto um Raio-X de um paciente infectado pela Covid-19, onde as setas apontam para os danos causado pelo agente viral.

Figura 7 – Raio X de pacientes com pneumonia causada pela Covid-19.



Fonte: Imagens da base de dados do *Chest Xray Coronahack*

(COHEN et al., 2020).

Numa imagem de radiografia em que o paciente possui o Covid-19, os fatores que são considerados típicos do Covid-19, até o momento, são: opacidades em vidro fosco; consolidações focais e opacidades mistas (incluindo opacidades com halo invertido) (FARIAS et al., 2020); padrão pavimentação em mosaico com distribuição bilateral e multifocal, com predominância periférica e posterior (ARAUJO-FILHO et al., 2020).

#### 4.2.5 RADIOGRAFIA DE TÓRAX

Assim com o avanço tecnológico obtido nas últimas décadas com outros métodos de imagem, como Tomografia Computadorizada, Ressonância Nuclear Magnética e Ultrassonografia, não foi capaz de diminuir a importância da radiografia do tórax no atendimento emergencial (BRENTANO et al., 2014). Sua ampla disponibilidade, baixo custo e rapidez fazem da radiografia um dos primeiros exames complementares a serem solicitados na maioria dos casos atendidos no Serviço de Emergência. Além disso, o paciente tem uma exposição a radiação menor, sem contar seu baixo custo (BRENTANO et al., 2014).

Os raios-X são ondas de radiação de alta energia que podem penetrar a maioria das substâncias (em graus variados). Em doses muito baixas, os raios-X são usados para produzir imagens que ajudam o médico a diagnosticar doenças. Em altas doses, os raios-X (terapia de radiação) são usados para tratar câncer (CASALI, 2006). As radiografias podem ser usadas isoladamente como radiografias simples ou combinadas com outras técnicas, como TC.

Uma parte corporal onde a radiografia é bastante usada é no tórax, onde é um exame que serve para auxiliar no diagnóstico ou avaliação da resposta aos tratamentos em várias patologias, como por exemplo a pneumonia, tuberculose, doença pulmonar obstrutiva crônica (DPOC), fraturas, entre outros. O tórax é a região anatômica situada entre a região do pescoço (cervical) e o abdômen, sendo separada desta última pelo diafragma (músculo interno).

Para diagnosticar uma radiografia, um médico ou técnico em radiologia realiza o procedimento e então logo após faz uma avaliação prévia das imagens, para ter certeza se estão suficientes nítidas. Saber se estão nítidas, garante que não aconteçam interpretações erradas (YAFFE; ROWLANDS, 1997). Logo em seguida, as imagens são enviadas a um especialista em radiologia e alguma outra especialidade, isso porque o Conselho Federal de Medicina exige que apenas especialistas na área do exame podem emitir o laudo médico. Depois que as imagens são analisadas, são então classificados como normal ou anormal.

#### 4.2.6 INTELIGÊNCIA ARTIFICIAL

Inteligência artificial (IA), é termo usado para definir a capacidade das máquinas de assimilar o modo do ser humano de pensar, resolver problemas, ou seja, de ser inteligente. As principais pesquisas definem o campo como "o estudo e projeto de agentes inteligentes", onde um agente inteligente é um sistema que percebe seu ambiente e toma atitudes que maximizam suas chances de sucesso (RUSSELL; NORVIG, 2016), (SOUSA et al., 2018b), (BRUNO et al., 2018).

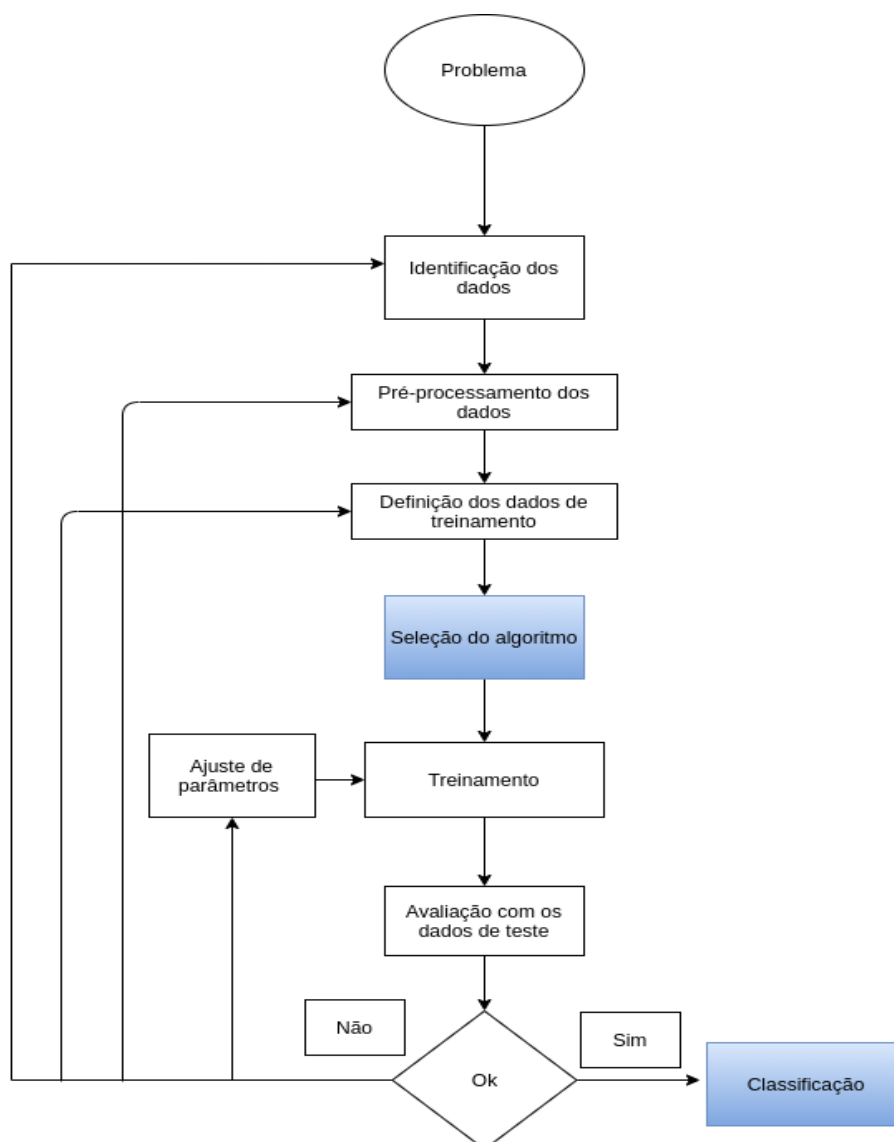
A promessa de IA tem sido um tópico de interesse há décadas. Desde a década de 1950, havia esperanças de que técnicas de inteligência artificial baseadas em lógica, representação do conhecimento, raciocínio e planejamento resultassem em *softwares* revolucionários que poderiam, entender linguagens, controlar robôs, fornecer consultoria especializada e entre outras funcionalidades (BOTTOU; CURTIS; NOCEDAL, 2018), (SARAIVA et al., 2018).

#### 4.2.7 APRENDIZADO DE MÁQUINA

A IA pode ser definida, como a ciência capaz de assimilar as habilidades humanas, porém o Aprendizado de Máquina do inglês "*Machine Learning*", é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da IA baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana (HARRINGTON, 2012).

Existem 3 tipos de aprendizado que caracterizam o aprendizado de máquina: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço. No aprendizado supervisionado durante o treinamento do algoritmo é informado o que é cada entrada "*Label*", a partir disso é possível aprender as características de cada entrada Figura 8. De acordo com o tipo de resultado do algoritmo, pode-se classificá-lo entre algoritmo de classificação ou de regressão (AYO-DELE, 2010).

Figura 8 – Processo de aprendizado de máquina supervisionado.



Fonte: Ayodele, T. O (AYODELE, 2010).

No aprendizado não supervisionado, a aprendizagem ocorre com dados não rotulados, ou seja, não é preciso especificar ao computador o que é aquela entrada. Por exemplo, um modelo que aprendeu a classificar imagens entre dois grupos distintos. Ao receber uma nova imagem, com base em seus atributos, ele identifica a qual grupo ela pertence, sem necessariamente saber a classe (ZHOU et al., 2017).

A aprendizagem por reforço, é uma especificar de ensinar ao computador qual ação priorizar dada uma determinada situação. É possível vincular recompensas e punições aos possíveis resultados e, ponderando-as da forma certa, ensinar o nível de prioridade de cada meta (LI et al., 2016).

#### 4.2.8 REDES NEURAIS ARTIFICIAIS

Redes Neurais são modelos alimentados por neurônios artificiais onde são unidades minúsculas organizadas em uma série de camadas conectadas umas às outras. Entre estas camadas, uma é exclusivamente para a entrada de informação para então reconhecer, interpretar e classificar esses dados (EBERHART; DOBBINS, 1990). Na outra extremidade possui uma camada onde é produzida o resultado do processo de aprendizado da rede. Entre as duas extremidades é constituída de camadas ocultas que realiza maior parte do trabalho, determinando como processar a informação que chega às entradas (EBERHART; DOBBINS, 1990).

As conexões entre um neurônio e outro são chamados de pesos e podem ser positivas ou negativas. Cada neurônio recebe entradas de dados e os mesmos são multiplicadas pelos pesos das conexões pelas quais viajam. Cada neurônio soma todas as entradas que recebe e se a soma for superior a um certo limite, definida pela função de ativação, ele “dispara” com base se a entrada é relevante para a previsão do modelo.


Uma rede neural aprende recebendo *feedback* e dizendo se está certo ou errado. Dependendo desse *feedback*, a rede fará ajustes para corrigir o erro. Esses ajustes consistem em atualizações dos pesos dos neurônios. De acordo com (SHAHIN; MAIER; JAKSA, 2004), para treinar um modelo de aprendizado de máquina, é necessário dividir os dados em dois conjuntos (treinamento e teste). O conjunto de dados de treinamento é a amostra de dados usada para ajustar o modelo, onde o modelo vê e aprende com esses dados (KRAWCZYK, 2016). O conjunto de dados de teste, no entanto, é a amostra de dados usada para fornecer uma avaliação imparcial do modelo no conjunto de dados de treinamento, após os ajustes dos hiperparâmetros do modelo (KRAWCZYK, 2016).

No campo das redes neurais, a rede neural convolucional CNN é uma das principais para a tarefa de reconhecimentos e classificações de imagens. Detecções de objetos e reconhecimento de rosto são algumas das áreas onde as CNNs são amplamente utilizadas. Uma CNN pega uma imagem de entrada, processam-na e classificam-na em certas categorias (por exemplo, cachorro, gato, tigre, leão). A partir que uma imagem entra na CNN, essa imagem passa por uma série de convoluções, composto por um conjunto filtros que servem para poder extrair o máximo de característica dessa imagem. Após passar por esses blocos de convolução e as características da imagem forem extraídas, o resultado desse processo é então passado para uma rede neural do tipo *feed-forward*, para assim poder aprender a rotular essa imagem.

#### 4.2.8.1 REDE NEURAL MULTILAYER PERCEPTRON

As redes neurais *Multilayer perceptron* (MLP), são compostos de uma ou mais camadas de neurônios. Os dados são alimentados na camada de entrada, pode haver uma ou mais camadas ocultas, as previsões são feitas na camada de saída, também chamada de camada visível (SARAIVA et al., 2019), (SARAIVA. et al., 2019).

Figura 9 – Rede neural multicamadas.



Fonte: Autoria própria.

O funcionamento geral de uma MLP está representada na Figura 9 . Cada neurônio recebe todos os valores das entradas, representadas pelo símbolo  $y$ , que são multiplicadas pelos pesos sinápticos simbolizados pelo  $W$  e somadas entre junta-se com uma constante chamada de polarização ou bias, representada pelo símbolo  $b$ , na camada de saída geralmente é usado funções de ativação probabilísticas como *Softmax*, *Sigmoid* entre outras (KOURETAS; PALIOURAS, 2019). A MLP utiliza uma técnica de aprendizado supervisionado chamada *backpropagation* para treinamento e suas camadas múltiplas e ativação não linear distinguem o MLP de um perceptron linear (ZHANG et al., 2016).

Nas CNNs usadas nos aplicativos CNN-Cardio e CNN-Pulmona é aplicado às funções de ativações *Softmax* e *Sigmoid* respectivamente, então o cálculo da probabilidade da classificação de uma amostra é realizado através destas funções. A fórmula matemática das mesma podem ser analisado nas Equações 4.1, 4.2, a Equação 4.1 trata-se da função de ativação *Sigmoid* onde  $x$  é resultado do somatório dos pesos pelas entradas, a Equação 4.2 por sua vez consiste na função *Softmax*, onde  $i$  representa o índice do neurônio de saída sendo calculado e  $j$  representa os índices

de todos os neurônios de um nível, a variável  $z$  designa o vetor de neurônios de saída (KOURETAS; PALIOURAS, 2019).


$$y = \frac{1}{1 + e^{-x}} \quad (4.1)$$

$$\sigma(Z) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (4.2)$$

#### 4.2.8.2 REDE NEURAL CONVOLUCIONAL

As *Convolutional Neural Network* (CNNs), são similares a redes neurais tradicionais (SARAIVA et al., 2019), (SARAIVA. et al., 2019), ambas são compostas por neurônios que possuem pesos e bias que necessitam ser treinados. Cada neurônio recebe algumas entradas, aplica o produto escalar das entradas e pesos além de uma função não-linear (CHEN et al., 2017). Uma CNN assume que todas as entradas são imagens, o que permite codificar algumas propriedades na arquitetura. Redes neurais tradicionais não são escaláveis para imagens, uma vez que a mesma produz um número muito alto de pesos a serem treinados (ESTEVA et al., 2017).

Figura 10 – Exemplo da arquitetura de uma CNN (AlexNet).



Fonte: (KRIZHEVSKY; SUTSKEVER; HINTON, 2017).

Uma CNN é composta por uma sequência de camadas, Figura 10, além de camada de entrada, que normalmente é composta por uma imagem com largura e altura, existem três camadas principais: camada convolucional, camada de *Pooling* e camada totalmente conectada. Além disso, após uma camada de convolução é comum uma camada de ativação normalmente uma função de unidade de retificação linear (ReLU). Essas camadas, quando colocadas em sequência (ou empilhadas), forma uma arquitetura de uma CNN (SALAMON; BELLO, 2017).

## 4.2.9 TRANSFERÊNCIA DE APRENDIZADO

No contexto de aprendizagem de máquina, a reutilização de conhecimento adquirido anteriormente em tarefas semelhantes é conhecida como transferência de aprendizado, que pode ser utilizado em qualquer algoritmo da natureza de aprendizado de máquina (SOUSA et al., 2020a).

A técnica consiste na utilização de um modelo pré-treinado com classes distintas do problema objetivo. Isso se torna vantajoso no uso de conjunto de dados pequenos, pois existe uma dificuldade em obter bases de dados grandes o suficiente para esses tipos de problemas específicos (WU et al., 2018).

Normalmente essa técnica preserva as camadas iniciais e intermediárias, por outro lado a camada final é substituída e treinada novamente. Desse modo todos os outros pesos são definidos como não treináveis. Assim as últimas camada das redes são removidas e adicionam-se novas camadas de neurônios totalmente conectadas (RAMALINGAM; GARZIA, 2018).

## 4.2.10 REDES NEURAIIS QUANTIZADAS

Redes Neurais Quantizadas (QNNs) usam pesos e ativações de baixa precisão, por exemplo, realizando operações com 18 ou 32 bits. Essas redes são treinadas do zero em uma precisão arbitrária de ponto fixo. Onde na precisão, os QNNs que usam menos bits requerem arquiteturas de rede mais profundas e mais amplas do que as redes que usam operadores mais precisos, ao mesmo tempo em que exigem menos aritmética complexa e menos bits por peso (MOONS et al., 2017).

Um método foi introduzido para treinar QNNs com pesos e ativações de precisão extremamente baixa (por exemplo, 1 bit) em tempo de execução. No *traintime*, pesos quantizados e ativações são usados para calcular os gradientes dos parâmetros. Durante as próximas etapas, os QNNs reduzem drasticamente o tamanho e o acesso à memória, substituindo a maioria das operações aritméticas por operações bit a bit (HUBARA et al., 2017). Isto é para dizer que o esquema de quantização é um mapeamento inteiro  $q$  para números reais  $r$ , isto é, da forma:

$$r = S(q - Z) \quad (4.3)$$

Este esquema consiste na multiplicação de duas matrizes quadradas  $N \times N$  de números reais (HUBARA et al., 2017),  $r_1$ , e  $r_2$ , com seu produto representado por  $r_3 = r_1 r_2$ . É demonstrado as entradas de cada uma dessas matrizes  $r_\alpha$  ( $\alpha = 1, 2, ou 3$ ) como  $r_\alpha^{(i,j)}$  para  $i, j \in N$ , e os parâmetros de quantização com os quais eles são quantificados como  $(S_\alpha, Z_\alpha)$ . É representado as entradas quantificadas por  $q_\alpha^{(i,j)}$  a **Equação**

4.3 então se torna:

$$r_{\alpha}^{(i,j)} = S_{\alpha}(q_{\alpha}^{(i,j)} - Z_{\alpha}) \quad (4.4)$$

A partir da definição da multiplicação de matrizes, temos:

$$S_3(q_3^{(i,k)} - Z_3) = \sum_{j=1}^N S_1(q_1^{(i,j)} - Z_1)S_2(q_2^{(j,k)} - Z_2) \quad (4.5)$$

que pode ser reescrito como:

$$q_3^{(i,k)} = Z_3 + M \sum_{j=1}^N (q_1^{(i,j)} - Z_1)(q_2^{(j,k)} - Z_2) \quad (4.6)$$

Para essa aplicação foi realizado a Quantização pós-treinamento (ABADI et al., 2016), dessa forma reduzindo o tamanho do modelo e ao mesmo tempo, melhorar a latência da CPU, com pouca degradação na precisão do modelo (ABADI et al., 2016). Essas técnicas podem ser executadas em um modelo TensorFlow treinado e aplicadas durante a conversão do TensorFlow Lite (TFL).

Existem várias opções de quantização pós-treinamento (ABADI et al., 2016), como pode ser analisado na Tabela 1, os métodos escolhidos e implementados são a Quantização de Pesos e Quantização inteira completa de pesos e ativações. A Quantização de Pesos é o método mais simples de Quantização pós-treinamento, é quantizado apenas os pesos de ponto flutuante para 8 bits de precisão (também chamada quantização "híbrida") (ABADI et al., 2016). Essa técnica é realizada com a conversor do modelo para TFL. Já a Quantização inteira completa de pesos e ativações resulta em um modelo totalmente quantizado, porem o modelo ainda usa entrada e saída de ponto flutuante (ABADI et al., 2016).

Tabela 1 – Opções de quantização pós-treinamento.

Técnica	Benefícios	Hardware
Pós-treinamento "híbrido"	4x menor, 2-3x mais rápido, Precisão	CPU
Pós-treinamento "inteiro"	4x menor, Mais rápido	CPU, Edge TPU, etc.
Pós treino fp16	2x menor, Potencial aceleração da GPU	CPU/GPU

Fonte: Autoria própria.

#### 4.2.11 MODELOS EM CASCATA

Modelo de Classificação em Cascata (CCM) consiste em um método de aprendizado por conjunto baseado na concatenação de vários classificadores, usando

todas as informações coletadas da saída de um determinado classificador como informações adicionais para o próximo classificado na cascata (LIANG et al., 2018).

Uma estrutura em cascata é normalmente formada ao conectar classificadores como uma arquitetura de vários estágios. Em cada estágio, com base na confiança de sua previsão, um classificador pode decidir sobre a classificação da amostra de entrada atual e encerrar a execução ou passá-la para o próximo estágio (KOURIS; VENIERIS; BOUGANIS, 2018).

#### 4.2.12 AUMENTO DE IMAGEM

Os métodos mais comuns de aumento de dados incluem modificações simples no conjunto de dados, como translação, rotação, inversão e escala. Usar o aumento clássico de dados é um procedimento amplamente utilizado em tarefas de visão computacional. Esse aumento de dados é usado com frequência em aplicações de aprendizado profundo, especificamente em imagens essa técnicas é usada para o treinamento de modelos. Com um número maior de dados no treinamento o modelo consegue obter melhores resultados quando submetido a uma avaliação com os dados de teste. (FRID-ADAR et al., 2018)

Foram utilizadas duas formas distintas de aumento de dados, ambas as quais permitem que imagens transformadas sejam produzidas a partir das imagens originais com cálculo muito pequeno, de forma que as imagens transformadas não precisem ser armazenadas em disco. As imagens transformadas são geradas em código Python na CPU enquanto a GPU está treinando o lote anterior de imagens. Gerando um esquema de aumento de dados computacionalmente livre (KRIZHEVSKY; SUTSKEVER; HINTON, 2017).

#### 4.2.13 OTIMIZAÇÃO BAYESIANA DE HIPERPARÂMETROS

O ajuste de hiperparâmetros visa encontrar as escolhas corretas de hiperparâmetros para um determinado algoritmo de aprendizado de máquina, de forma que ele retorne o melhor desempenho quando avaliado em um conjunto de testes (SNOEK et al., 2015). Existem várias técnicas para encontrar bons hiperparâmetros, sendo o *Grid Search* e o *Random Search* os mais comuns, o *Grid Search* consiste em tentar todas as combinações possíveis de hiperparâmetros de forma sequencial. A Pesquisa Aleatória, por outro lado, tenta várias combinações de parâmetros de forma completamente aleatória (ZHANG et al., 2019). Esses métodos são adequados para o ajuste de hiperparâmetros, mas não aprendem nada com os conjuntos de hiperparâmetros avaliados durante o processo de ajuste, que pode ser um processo muito longo, para resolver este problema este trabalho usa o método de otimização Bayesiana.

A otimização bayesiana constrói um modelo de probabilidade que mapeia valores de hiperparâmetros para a probabilidade de obtenção de um determinado valor da função objetivo, geralmente referido como pontuação. Usando essas probabilidades, os valores de hiperparâmetros mais promissores são selecionados para avaliar a verdadeira função objetivo (DOKE et al., 2020).

#### 4.2.14 MÉTRICAS DE AVALIAÇÃO DAS REDES NEURAIIS

A acurácia do modelo pode ser estimada pela **Equação 4.7**, em que  $TP$  são os verdadeiros positivos,  $FP$  são os falsos positivos,  $TN$  são os verdadeiros negativos e  $FN$  são os falsos negativos. Isso nos permite inferir a capacidade de generalização da rede.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.7)$$

Uma matriz de confusão apresenta uma tabela frequentemente usada para demonstrar o desempenho de um modelo de classificação nos conjuntos de dados de teste e validação comparados com os verdadeiros valores. Os valores apresentados na tabela são: verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.

Os valores verdadeiramente positivos e os valores falsos positivos são os valores nos quais a rede conseguiu classificar de maneira correta. Já os valores verdadeiros negativos e falsos negativos representam os valores que a rede neural classificou erroneamente.

Como ferramenta estatística, temos a matriz de confusão que fornece a base para descrever a precisão da classificação bem como caracterizar os erros, ajudando a refinar a precisão (SARAIVA et al., 2018). A matriz de confusão é formada por uma matriz de quadrados de números dispostos em linhas e colunas que expressam o número de unidades de amostra de uma categoria particular, inferida por uma regra de decisão, em comparação com a categoria atual. Uma matriz de confusão apresenta informações sobre a frequência com que um determinado comportamento é detectado corretamente e com que frequência é classificado como outro comportamento.

As medidas derivadas da matriz de confusão são: acurácia total (utilizada neste trabalho), precisão de classe individual, precisão do produtor, precisão do usuário e índice *Kappa*, entre outras.

A precisão total é calculada dividindo a soma da diagonal principal da matriz

de erro  $x_{ii}$ , pelo número total de amostras coletadas  $n$ , de acordo com a **Equação 4.8**:

$$T = \frac{\sum_{i=1}^a x_{ii}}{n}. \quad (4.8)$$

Para avaliar completamente a eficácia dos modelos, a precisão e *recall* são examinadas. Infelizmente, precisão e *recall* estão frequentemente em tensão. Ou seja, melhorar a precisão geralmente reduz o *recall* e vice-versa.

$$Precision = \frac{TP}{TP + FP} \quad (4.9)$$

$$Recall = \frac{TP}{TP + FN} \quad (4.10)$$

F1 Score é uma métrica simples, que leva em conta a precisão e a recuperação, então você pode tentar maximizar esse número para melhorar seu modelo. Esta é simplesmente a média harmônica de precisão e *recall*.

$$F1Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4.11)$$

AUC - Curva ROC é uma medida de desempenho para classificar problemas em várias configurações de limite. ROC é uma curva de probabilidade e AUC representa o grau ou medida de separabilidade (BOWERS; ZHOU, 2019).

#### 4.2.15 TÉCNICAS DE COMPRESSÃO

A compressão de dados é o processo de detecção e eliminação de redundâncias de um conjunto de dados. Em termos de técnicas de compressão de sinal, métodos diretos ou transformados são encontrados na maior parte da literatura. São caracterizados por não atingirem o maior nível de compressão, não terem controle sobre a qualidade do sinal recuperado, tendo como objetivo testar a eficácia desses métodos em cada sinal foram utilizadas as técnicas de compressão Transformada Discreta de Cosseno, Transformada Rápida de Walsh-Hadamard (*Fast Walsh-Hadamard Transform* - FWHT), e Transformada Discreta de Wavelet (DWT) as quais serão discutidas mais abaixo.

##### 4.2.15.1 DCT

O DCT é uma técnica com perdas, muito relacionada com a Transformada Discreta de Fourier, muitas vezes pode reconstruir uma sequência precisa de apenas alguns coeficientes DCT, esta propriedade é muito útil para aplicações que requerem

redução de dados, justamente o objetivo deste trabalho, para explorar a redução do uso de dados em eletrocardiograma (SARAIVA et al., 2020a).

O DCT tem quatro variantes padrão, para um sinal  $x$  de tamanho  $N$  e com o delta dekronecker , as transformações são definidas pelas equações 1, 2, 3 e 4 respectivamente.

$$y(k) = \sqrt{\frac{2}{N}} \sum_{n=1}^N x(n) \frac{1}{\sqrt{1+\delta_{n1}+\delta_{nN}}} \frac{1}{\sqrt{1+\delta_{k1}+\delta_{kN}}} \cos\left(\frac{\pi}{N-1}(n-1)(k-1)\right) \quad (4.12)$$

$$y(k) = \sqrt{\frac{2}{N}} \sum_{n=1}^N x(n) \frac{1}{\sqrt{1-\delta_{k1}}} \cos\left(\frac{\pi}{2N}(2n-1)(k-1)\right) \quad (4.13)$$

$$y(k) = \sqrt{\frac{2}{N}} \sum_{n=1}^N x(n) \frac{1}{\sqrt{1+\delta_{n1}}} \cos\left(\frac{\pi}{2N}(n-1)(2k-1)\right) \quad (4.14)$$

$$y(k) = \sqrt{\frac{2}{N}} \sum_{n=1}^N x(n) \cos\left(\frac{\pi}{4N}(2n-1)(2k-1)\right) \quad (4.15)$$

As séries são indexadas com  $n = 1$  e  $k = 1$  em vez do usual  $n = 0$  e  $k = 0$ .

Nas equações,  $x$  significa a matriz de entrada,  $y$  é o próprio DCT e  $n$  é igual ao comprimento da transformação, um escalar inteiro positivo, com  $x$  e  $y$  sendo vetores (podem ser matrizes) (SARAIVA. et al., 2019).

#### 4.2.15.2 FWHT

O WHT é uma técnica de transformação ortogonal não senoidal com perdas que decompõe o sinal em uma série de funções de base, essas funções de base são chamadas de funções de Walsh, que são ondas retangulares e quadradas com valores de -1 e 1. Elas também são conhecidas como Transformadas de Hadamard, Walsh ou Walsh Fourier (SOUSA et al., 2020b). Eles são muito úteis na redução dos requisitos de armazenamento, largura de banda e análise de espectro. Como a Transformada Rápida de Fourier (FFT), a WHT tem uma versão mais rápida da Transformada Walsh Hadamard (WHT) mais rápida, que em comparação com a FFT requer menos espaço de armazenamento e é mais rápida de calcular, uma vez que usa apenas adições e subtrações reais, enquanto a FFT usa valores complexos. Ambos FWHT e a Transformada Hadamard Rápida Inversa (IFWHT) são simétricos entre si e usam processos de cálculo idênticos. Para um sinal  $x(t)$  de tamanho  $N$ , o FWHT e o IFWHT são definidos da seguinte forma:

$$y = \frac{1}{N} \sum_{i=0}^{n-1} x WAL(n, i) \quad (4.16)$$

$$x = \sum_{i=0}^{n-1} yWAL(n, i) \quad (4.17)$$

tal que  $i = 0, 1, \dots, N - 1$  e  $WAL(n, i)$  são as funções de Walsh. Semelhante ao algoritmo Cooley-Tukey para o FFT, os  $N$  elementos são decompostos em dois conjuntos de  $N / 2$  elementos, que são então combinados usando uma estrutura de borboleta para formar o FWHT (SARAIVA et al., 2018).

#### 4.2.15.3 DWT

Na análise numérica e na análise funcional, uma transformada wavelet discreta (DWT) é qualquer transformada wavelet para a qual as wavelets são amostradas discretamente. Tal como acontece com outras transformações wavelet, uma vantagem chave que ela tem sobre as transformadas de Fourier é a resolução temporal: ela captura informações de frequência e localização (no tempo) (SARAIVA. et al., 2019).

O primeiro DWT foi inventado pelo matemático húngaro Alfréd Haar. Para uma entrada representada por uma lista de  $2^n$  números, a transformada wavelet de Haar pode ser considerada para emparelhar valores de entrada, armazenando a diferença e passando a soma. Este processo é repetido recursivamente, pareando as somas para provar a próxima escala, o que leva a  $2^n - 1$  diferenças e uma soma final.

Técnicas de multi-resolução para processamento de sinal e imagem são usadas há décadas. A necessidade de transformações que levem a uma representação na qual informações espaciais e de escala estejam presentes é amplamente reconhecida. Para fornecer isso, várias técnicas relacionadas foram desenvolvidas, incluindo Gabor, Haar, Walsh-Hadamard e outras expansões, decomposições espaciais de escala de filtragem de sub-banda, etc.

Por volta de 1990, surgiu uma estrutura matemática que fornece uma abordagem mais formal, sólida e unificada para representações de multi-resolução. O paradigma wavelet engloba decomposições multi-resolução de sinais em bases ortogonais de funções wavelet que possuem suporte compacto. Em alguns anos, o paradigma wavelet encontrou muitas aplicações no processamento de sinais e imagens (SOUSA et al., 2020b).

O princípio é, primeiro, calcular uma transformação wavelet trivial (a wavelet preguiçosa) e, em seguida, melhorar suas propriedades alternando as etapas de previsão e atualização, conforme ilustrado na figura. A wavelet preguiçosa apenas divide o sinal 1D  $s_1$  em suas amostras indexadas pares e ímpares, conforme mostrado nas

próximas fórmulas.

$$s1_{1,l}^{(0)} = s1, 2l \quad (4.18)$$

$$d1_{1,l}^{(0)} = s1, 2l + 1 \quad (4.19)$$

A etapa de predição consiste em aplicar um filtro às amostras pares e subtrair o resultado das ímpares, conforme exemplificado na próxima equação.

$$d1_{1,l}^{(1)} = d1_{1,l}^{(0)} - \sum_k P_k S_{1,l-k}^{(0)} \quad (4.20)$$

A etapa de atualização faz o contrário, aplicando um filtro nas amostras ímpares e subtraindo o resultado das amostras pares, a partir disso é possível preparar o sinal a ser reconstruído.

$$d1_{1,l}^{(1)} = d1_{1,l}^{(0)} - \sum_k U_k D_{1,l-k}^{(0)} \quad (4.21)$$

Então, para os pares WHT Após M de etapas de previsão e atualização, as amostras pares representarão os coeficientes de aproximação, enquanto as amostras ímpares representam os coeficientes de alta frequência (SARAIVA. et al., 2019).

O esquema de levantamento é perfeitamente reversível, uma vez que a transformação inversa é derivada invertendo as operações e invertendo os sinais. Na verdade, alternamos as etapas de previsão e atualização. Em seguida, aplicamos a transformação preguiçosa inversa. A transformação inversa pode ser derivada imediatamente da frente, executando o esquema para trás e invertendo os sinais (SOUSA et al., 2020b).

$$s1_{1,l}^{(0)} = s1_{1,l}^{(1)} + \sum_k U_k^{(1)} D_{1,l-k}^{(1)} \quad (4.22)$$

$$d1_{1,l}^{(0)} = d1_{1,l}^{(1)} - \sum_k p_k^{(1)} S_{1,l-k}^{(1)} \quad (4.23)$$

#### 4.2.16 MÉTRICAS DE AVALIAÇÃO PARA A COMPRESSÃO DE SINAIS

Para a obtenção da classificação de fidelidade do sinal comprimido e reconstruído além da qualidade, em comparação com o sinal original foi utilizado o Erro

Quadrático Médio (MSE) , Erro Médio Absoluto (MAE), Relação sinal-ruído (SNR), Relação sinal-ruído de pico (PSNR) os quais serão detalhados mais abaixo.

#### 4.2.16.1 MSE

O MSE é um medidor de fidelidade de sinal. O objetivo de um medidor de fidelidade é comparar dois sinais e fornecer uma pontuação quantitativa que descreve o grau de similaridade ou fidelidade e o nível de erro ou distorção entre eles, assumindo que um dos sinais é primitivo e livre de erros, enquanto o outro é distorcida e contaminada por erros (SARAIVA et al., 2018). O MSE pode ser calculado como mostra a equação:

$$MSE = \frac{1}{mn} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} (I - K^2) \quad (4.24)$$

Tomando  $I$ , como um vetor de predições  $n$  e  $K$ , como um vetor de valores observados da variável sendo predita.

#### 4.2.16.2 MAE

O MAE é uma medida "escalonada", neste sentido, expressa um modelo preciso de predição de erros em unidades da variável de interesse, assim como o MSE, quanto menor o valor, maior a fidelidade do sinal Reconstruído para com o sinal original, o MAE pode ser calculado assumindo que existem  $n$  erros de modelo de amostra e calculado como ( $e_i$ ,  $i = 1, 2, \dots, n$ ):

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4.25)$$

#### 4.2.16.3 SNR

SNR é a taxa entre sinal e ruído, na engenharia e ciências, SNR é a medida que compara o nível do sinal desejado com o nível de ruído de fundo.

Matematicamente, o SNR é o quociente de intensidade de um sinal medido em uma região de interesse (ROI) e o desvio padrão da intensidade do sinal em uma área.

$$SNR = \text{Log} \frac{\sum_{n=0}^N V_R^2(n)}{\sum_{n=0}^N S_R^2(n)} \quad (4.26)$$

O SNR pode ser calculado assumindo  $V_R(n)$  como o sinal reconstruído,  $V(n)$  como o sinal original e o  $S_R(n)$  como a deformação do Sinal reconstruído (SARAIVA et al., 2019)

#### 4.2.16.4 PSNR

O PSNR é um parâmetro usado para quantificar a qualidade do sinal, também é usado como *benchmark*, do nível de similaridade entre o sinal reconstruído e o sinal original.

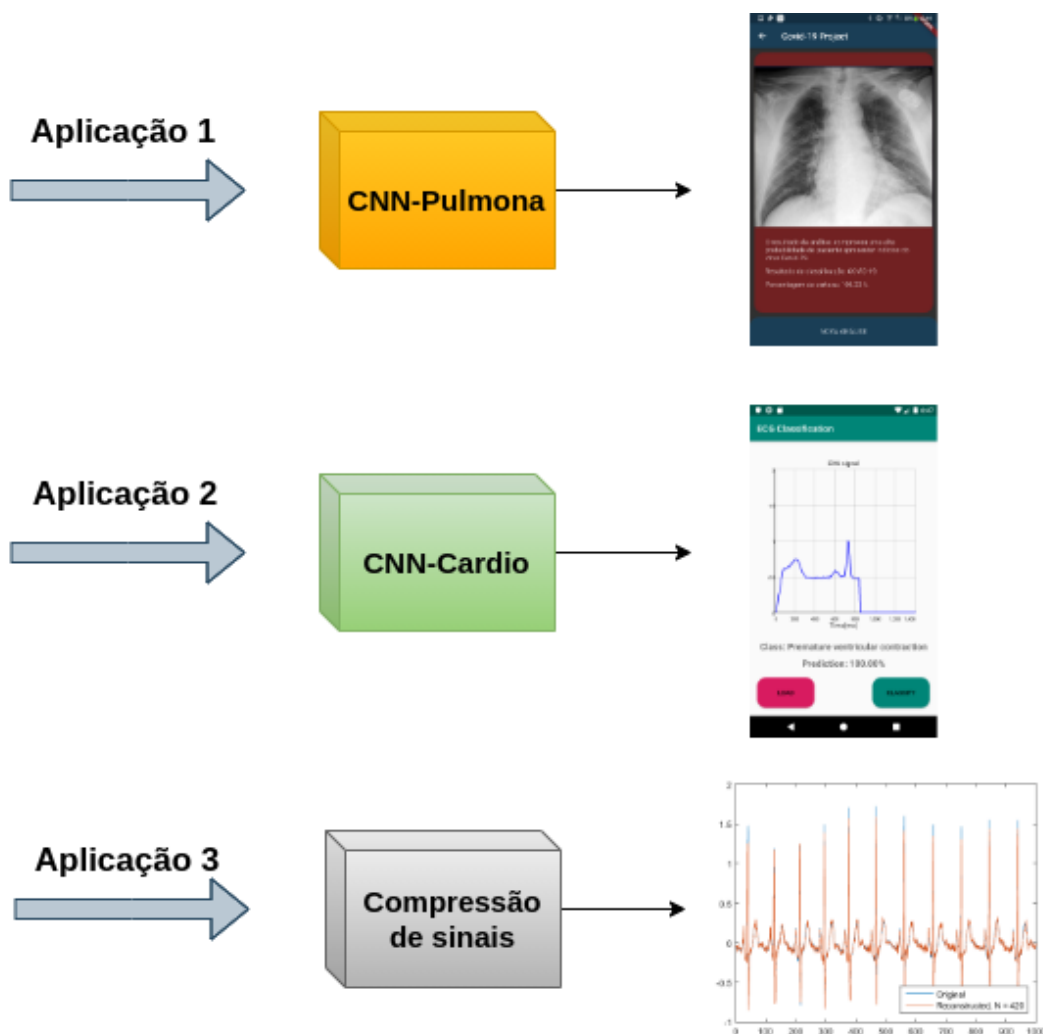
Quanto mais alto o valor PSNR, melhor é a qualidade do sinal. E pode ser calculado como a Equação, mostra (SOUSA et al., 2020b).

$$PSNR = 10 \log \left( \frac{MAX^2}{MSE} \right) = 20 \log \frac{MAX}{MSE^{\frac{1}{2}}} \quad (4.27)$$

## 5 MATERIAIS E MÉTODOS

Neste capítulo são descritos todos os métodos usado para o desenvolvimento das três aplicações proposta, como mencionado anteriormente foram desenvolvidas três aplicações distintas para análise de dados biomédicos: 1) CNN-Pulmona que consiste em uma aplicativo móvel capaz de identificar se o paciente possui algum tipo de Pneumonia e qual o agente causador da mesma, 2) CNN-Cardio por sua vez consiste em outro aplicativo móvel distinto capaz de classificar diferentes tipos de arritmias, 3) trata-se de outra aplicações onde é implementado e comparado diferentes tipos de compressão de sinais biomédicos, no diagrama da Figura 11 é ilustrado as três aplicações mencionadas.

Figura 11 – Diagrama das três aplicações desenvolvidas.



Fonte: Autoria própria.

No processo de criação das aplicações móveis, foi utilizado o kit de desenvolvimento *Flutter*, criado pelo *Google* (PAYNE, 2019). A construção do aplicativo veio para que tornasse mais acessível e prático o uso da rede neural treinada. Para fazer a aplicação mobile conseguir ler e interpretar o modelo treinado, foi usado o *plugin* do TFlite do *Flutter*, assim como também, a rede neural foi convertida para esse tipo de modelo, recomendado para ser utilizado na aplicação móvel.

O percentual de certeza na saída da classificação dos aplicativos CNN-Pulmonar e CNN-Cardio consiste no valor de probabilidade calculado na função de ativação da última camada da CNN, ou seja, como a saída da última camada das CNNs usadas consistem em uma saída probabilística a rede retorna a probabilidade de uma entrada ser de uma determinada classe. Por exemplo, dado uma entrada  $X$  a rede retorna a classe dessa entrada e o valor de probabilidade dessa entrada realmente ser da classe no qual foi classificada, em outras palavras isso significa o grau de certeza da rede em classificar um registro (FENG et al., 2019).

Para a implementação das CNNs usadas nos aplicativos, é usada a biblioteca de aprendizado de máquina TensorFlow (ABADI et al., 2016). O processamento foi realizado usando uma placa de vídeo *Nvidia Titan XP* com 3840 núcleos CUDA (processadores), 12 GB de memória dedicada, 12 GB de RAM e um processador Core i5 de quarta geração.

## 5.1 OTIMIZAÇÃO DOS HIPERPARÂMETROS DAS REDES NEURAS

Neste trabalho para o desenvolvimento das aplicações móveis CNN-Pulmonar e CNN-Cardio, os hiperparâmetros das CNNs usadas são otimizados usando o algoritmo de otimização Bayesiano (SNOEK; LAROCHELLE; ADAMS, 2012), implementado em Python com a biblioteca Scikit-Optimize (OPTIMIZE, 2020). *Gp\_minimize* do módulo *skopt* é usado com o seguinte trecho de código abaixo:

```
1 search_result = gp_minimize(func = fitness,
2                             dimensions = obj_hyper.dimesionHiper(),
3                             acq_func='EI', n_calls = 40,
4                             x0 = default_parameters)
```

Onde *fitness* é a função a ser minimizada, que neste caso é o desempenho da CNN em cada treinamento e teste, *obj\_hyper.dimesionHiper()* é sobre as dimensões que são fornecidas como uma lista contendo as dimensões da pesquisa por cada hiperparâmetro, *acq\_func* é a função a minimizar em relação ao gaussiano anterior e é definido para a melhoria negativa esperada *EI*, e *n\_calls* é o número de chamadas de função a minimizar e é definido como 40. E *default\_parameters* é uma combinação

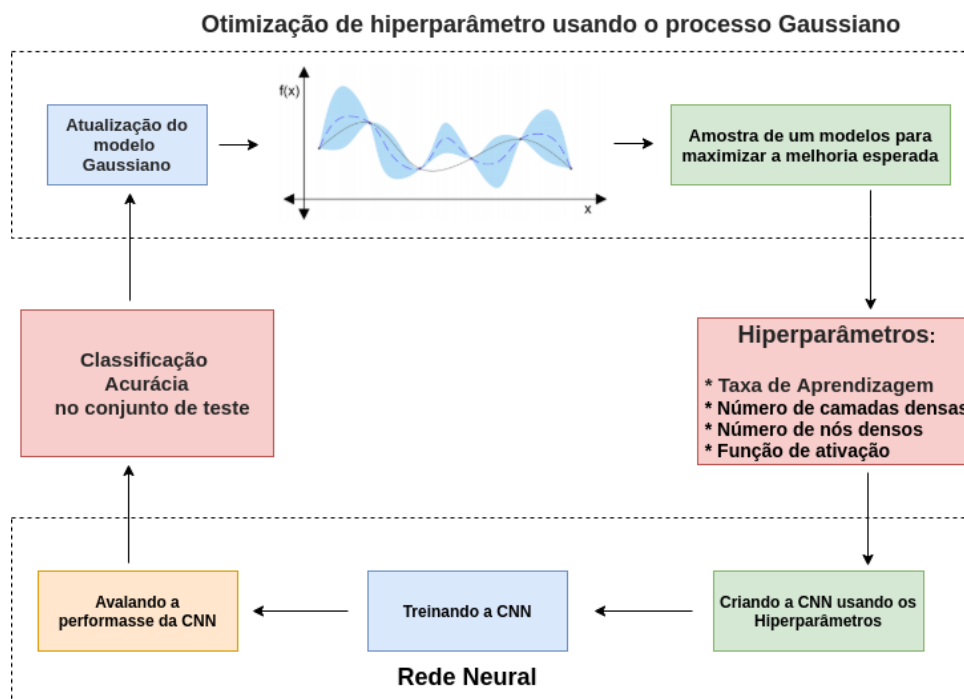
aleatória de hiperparâmetros dentro dos espaços de pesquisa usados para inicializar a otimização. Todos os outros parâmetros *gp\_minimize* são configurados para seus valores padrão. Este método usa um processo gaussiano, para modelar a função substituta e otimiza a probabilidade esperada de que novos testes irão melhorar a solução atual, Figura 12.

Os seguintes hiperparâmetros CNN são otimizados:

- Taxa de Aprendizado:  
O espaço de busca é  $10^{-6}$  a  $10^{-2}$
- Número de camadas densas:  
O espaço de busca é 1 a 8
- Número de nós densos:  
O espaço de busca é 5 a 1024
- Função de Ativação:  
O espaço de busca é *relu* ou *sigmoid*

Em comparação com a *Grid Search*, que é uma técnica padrão para ajustar hiperparâmetros (PONTES et al., 2016), a otimização Bayesiana pode pesquisar em um espaço hiperparâmetro maior. O método aceita um intervalo (ou seja, valores mínimo e máximo) para cada parâmetro e pode considerar qualquer valor nesse intervalo.

Figura 12 – Otimização Bayesiana.



Fonte: Autoria própria.

## 5.2 QUANTIZAÇÃO DAS CNNs

O treinamento de uma Rede Neural em hardware convencional é ineficiente devido aos enormes requisitos de memória para armazenar dados de entrada, parâmetros de peso e ativações da rede, além da grande quantidade de cálculos necessários para o cálculo das somas ponderadas das entradas dos neurônios. No entanto atualmente as Redes Neurais em sua maioria, são treinadas em GPUs (unidades de processamento gráfico) com grande poder de processamento. Devido a esses altos requisitos de recursos, muitas vezes é um desafio executar Redes Neurais em dispositivos Móveis e Embarcados com pouca energia e memória limitada (SOUSA et al., 2020a).

Para resolver isso foi utilizado dois métodos de quantização descrito na seção 4.2.10 nas duas aplicações desenvolvidas, os métodos usados consiste na quantização pós-tratamento (ABADI et al., 2016), essa método reduz o tamanho do modelo e melhora a latência da CPU, com pouca degradação na precisão do modelo (ABADI et al., 2016). Essas técnicas podem ser executadas em um modelo treinador do TensorFlow e aplicadas durante a conversão TFL.

Existem várias opções de quantização pós-treinamento (ABADI et al., 2016), como pode ser visto na Tabela 1 da seção 4.2.10, os métodos escolhidos e implementados são quantização de faixa dinâmica e quantização *Full Integer* de pesos e

ativações. A quantização de faixa dinâmica é o método mais simples de quantização pós-treinamento, apenas os pesos de ponto flutuante são quantizados com precisão de 8 bits (também chamada de quantização "híbrida") (ABADI et al., 2016). Esta técnica é realizada com o modelo para conversor TFL. A quantização inteira de pesos e ativações resulta em um modelo totalmente quantizado, mas o modelo ainda usam entradas e saídas de ponto flutuante (ABADI et al., 2016).

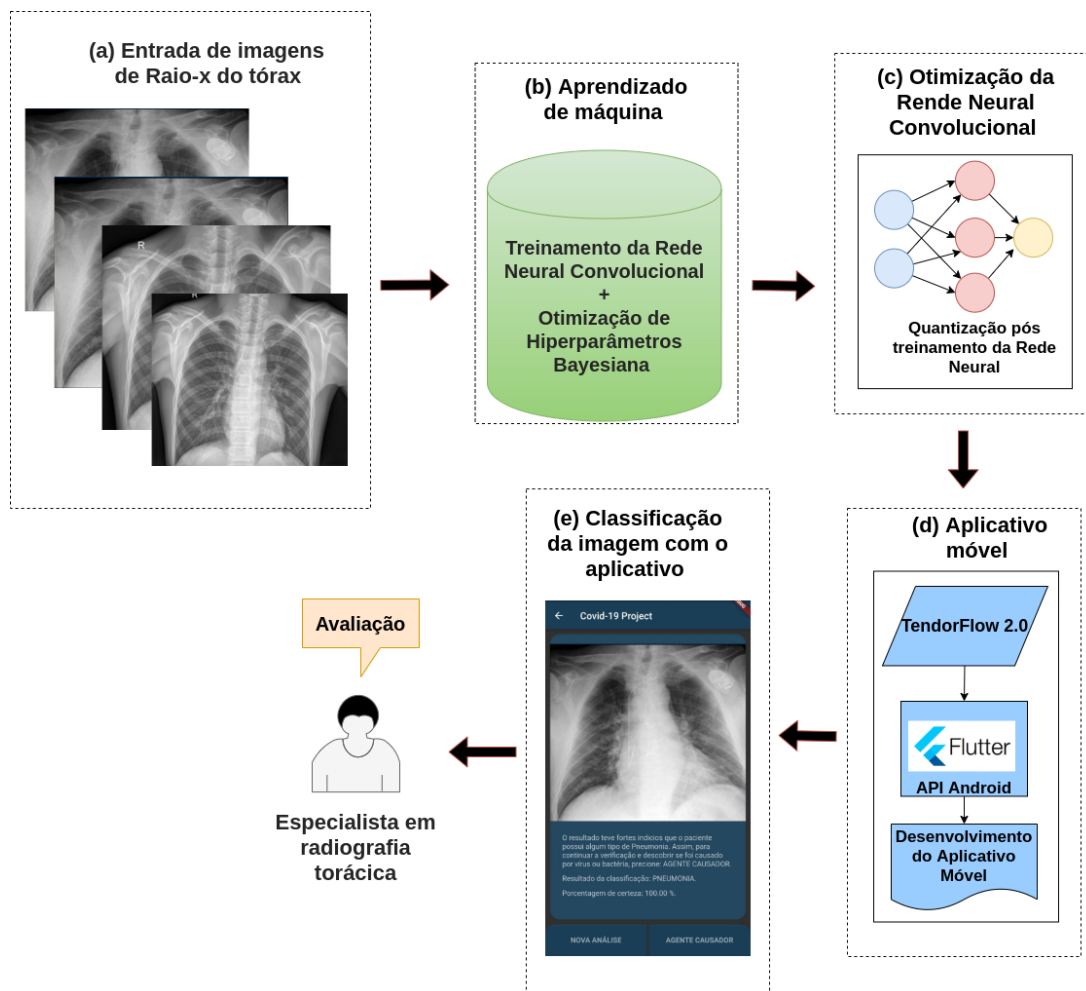
### 5.3 CLASSIFICAÇÃO DE IMAGENS DE RAIOS-X (CNN-PULMONA)

A classificação das imagens de Raios-X no app CNN-Pulmona é realizada através de modelos de CNNs, para isso é usando uma técnica conhecida como Modelos de Classificação em Cascata (CCM), descrito na seção 4.2.11. Esse método consiste em um aprendizado por conjunto, onde a saída de um modelo é usada como informações para o próximo modelo em cascata. Para isso foi usado uma CNN pré-treinada conhecida como MobileNetV2 (SANDLER et al., 2018), esse rede foi treinadas inicialmente com o conjunto de dados ImageNet (RUSSAKOVSKY et al., 2015), com mais de 1 milhão de imagens e mil classes, esse treinamento é aproveitado usando a técnica de Transferência de Aprendizado, descrita na seção 4.2.9, aproveitando as camadas iniciais e treinando apenas as camadas finais, onde as mesmas e os hiper-parâmetros das CNNs são definidas usando uma otimização Bayesiana descrita nas seções 4.2.13, 5.1.

Como foi descrito na seção 5.2, para a otimização das CNNs, duas técnicas de quantização pós-treinamento são usadas e avaliadas, usando o método de conversão TensorFlow Lite (TFL) (JACOB et al., 2018). Esta técnica visa reduzir drasticamente o tamanho do modelo, consumo e processamento de energia, possibilitando o desenvolvimento de um aplicativo mobile utilizando CNN.

Todo as etapas da construção da aplicação CNN-Pulmona podem ser analisadas no diagrama de imagem 13, onde a etapa a) consiste na entrada de dados de imagens de Raios-x, na etapa b) é realizado o método de aprendizagem de máquina juntamente com a técnica de transferência de aprendizado e a otimização Bayesiana, já na etapa c) é realizado a quantização dos modelos após serem treinados, a etapa d) consiste na criação do app com o kit de ferramentas *Flutter* e por a etapa e) consiste na classificação das imagens no app CNN-Pulmona.

Figura 13 – Estrutura do sistema da aplicação móvel CNN-Pulmona.



Fonte: Autoria própria.

### 5.3.1 DATASET DE RAIIO-X

Para esse projeto, foram utilizadas 5 bases de dados, que juntas, pudessem se complementar. Os dados constituintes nesses datasets foram mesclados, a fim de chegar a uma maior coleção de amostras de Raio-X pulmonar, com o objetivo de melhorar todo o processo de treinamento das redes neurais convolucionais.

Os conjuntos de dados usados foram: Chest xray coronahack (COHEN; MORRISON; DAO, 2020), Covid Chestxray dataset (COHEN et al., 2020), covid-19 radiograph database (CHOWDHURY et al., 2020), BIMCV Dataset (VAYÁ et al., 2020), Figure1 ChestXray dataset (WANG ALEXANDER WONG; GUNRAJ, 2020b), Actual-med COVID dataset (WANG ALEXANDER WONG; GUNRAJ, 2020a). Em todos esses datasets, contém imagens de raio-x da parte torácica do pulmão, em que neles, são classificados tanto como normal, possuindo nenhum tipo de doença, quanto de algumas variantes de pneumonia. As doenças pulmonares presentes, são compostas de agentes patogênicos bacteriano e agentes viral.

Todos os conjuntos de dados utilizados nesse trabalho são públicos e estão dispostas da seguinte maneira:

- **Chest xray coronahack dataset:**

Nessa base de dados, as imagens estão dispostas em dois grupos principais, sendo: Normal (1576 imagens) e Pneumonia (4334 imagens). No grupo de imagens de Raio-X rotuladas como pneumônicas, foram divididas em sub classes da seguinte maneira: stress smoking, ARDS (2 images); vírus COVID-19 (58 images); vírus SARS (4 images); Bacteria *Streptococcus* (5 images); vírus desconhecido (1493 images), bactéria desconhecida (2772 imagens).

- **Covid Chestxray Dataset:**

Nesse dataset é constituído de imagens, além de Raio-X, também de CT de pacientes em que podem ter suspeitas positivas ou negativas de COVID-19, além também de ter outros tipos de pneumonia. Na base de dados, possuem mais de 20 tipos de classificação para as imagens de Raio-x e CT scans. A constituição de amostras, é formada principalmente de imagens relacionada a COVID-19 (545 imagens), enquanto os outros tipos mais presente no dataset são: SARS (16 imagens), *Pneumocystis* (23 imagens), *Streptococcus* (17 imagens), Indefinida (18 imagens), Pneumonia (12 imagens), *Mycoplasma Bacterial Pneumonia* (10 imagens).

- **COVID-19 Radiography Database:**

Essa base de dados foi criada por por uma equipe de pesquisadores do Qatar, Doha, Qatar e da Universidade de Dhaka, Bangladesh, assim com colaboradores da Malásia. Nesse dataset, é composto por casos positivos de COVID-19, junto com casos Normal e casos de Pneumonia Viral. Os dados constituintes nessa base de dados são: COVID-19 (219 imagens), normal (1341 imagens), pneumonia viral (1345 imagens).

- **BIMCV Dataset+:**

O conjunto de dados BIMCV-COVID19 + é um grande conjunto de dados com imagens de radiografia de tórax CXR (CR, DX) e tomografia computadorizada (TC) de pacientes com COVID-19, juntamente com seus achados radiográficos, patologias e relatórios radiográficos do Medical Imaging Data-bank no Banco de Imagens Médicas da Região Valenciana (BIMCV). Além de todos relatórios presentes, são fornecidas informações abrangentes, incluindo informações demográficas do paciente, tipo de projeção e parâmetros de aquisição para o estudo de imagem, entre outros.

- **COVID-19 Chest X-ray Dataset Initiative e Actualmed COVID-19 Chest X-ray Dataset Initiative:**


Nessas duas bases de dados, foram desenvolvidas pelo mesmo time de criadores, o Core COVID-Net Team[ref]. No Figure 1 Covid-19, constitui de amostras pneumônicas de COVID-19 (35 imagens) e Pneumonia (2 imagens), além de imagens desconhecidas (15 imagens) e No findings (3 imagens). Em Actualmed COVID-19 Chest X-ray, os dados que o compõem são: COVID-19 (58 imagens), desconhecidas (53), No findings (127).

A construção do dataset usado nesse trabalho, reuniu partes de todos os datasets mencionados anteriormente. Todas as imagens selecionadas para o treinamento de toda a estrutura neural, foram do tipo de raio-x torácico, além de que, foi priorizado somente imagens de Raio-X da parte frontal dos pacientes.

Para a identificação com eficácia do vírus COVID-19, seria necessário amostras de outros tipos de pneumonia, para que o sistema inteligente fosse capaz de diferenciar entre essas doenças pulmonares. O processo de montagem da base de dados se deu em três grupos principais: Normal, Pneumonia Viral, Pneumonia Bacteriana.

A partir dos grupos formados para a constituição do dataset, foram adicionadas imagens das bases de dados apresentadas, a fim de que possuíssem maiores amostras para cada tipo de classificação. A distribuição do dataset final, ficou de acordo com a Figura 14.

Figura 14 – Gráfico de distribuição da base dados final utilizado nesse projeto.



Fonte: Autoria própria.


### 5.3.2 ARQUITETURA E TREINAMENTO DA CNN PARA CLASSIFICAÇÃO DE RAIOS-X

Como foi descrito na seção 5.3.1 foram utilizadas 9.653 imagens de Raios-x, essas imagens foram disponibilizadas por repositórios públicos. De acordo com o (SHAHIN; MAIER; JAKSA, 2004), para treinar um modelo de aprendizado de máquina, é necessário dividir os dados em dois subconjuntos (treinamento teste e validação). O conjunto de dados de treinamento é a amostra de dados usada para ajustar o modelo, onde o modelo vê e aprende com esses dados (KRAWCZYK, 2016). O conjunto de dados de teste, no entanto, é a amostra de dados usada para fornecer uma avaliação imparcial do modelo no conjunto de dados de treinamento após ajustar os hiperparâmetros do modelo (KRAWCZYK, 2016). Para realizar o treinamento das CNNs, o conjunto de dados foi dividido em treinamento teste e validação, com 70% ,20% 10% de cada classe respectivamente.

Como descrito na Seção 5.1 foi utilizado uma otimização Bayesiana para definir os hiperparâmetros e como isso também a arquitetura das redes são definidas a partir desta otimização, vale ressaltar que a otimização Bayesiana é usada para definir apenas as camadas totalmente conectadas. Baseado nisso foram treinados três modelos de CNNs utilizados na aplicação móvel CNN-Pulmona, arquitetura definida pela otimização Bayesiana das CNNs pode ser analisada na Figura 15, essa arquitetura é


usada para os três modelos em cascata. Como camadas de extração de características foi usado a rede pré-treinada MobileNet com 4 camadas densas de neurônios de 128, 60, 32 e 2 respectivamente, também é usado o *Dropout* de 20%, para controle de *Overfitting* (SRIVASTAVA et al., 2014), com isso 20% dos neurônios da camada anterior a cada de *Dropout* são anulados, mais detalhes sobre as implementações dos modelos podem ser analisado abaixo.

Figura 15 – Arquitetura da CNN.



Fonte: Autoria própria.

Figura 16 – Imagem original da radiografia de tórax (A), imagem após rotação de 15 graus no sentido horário (B), imagem após rotação de 15 graus no sentido anti-horário (C), imagem após 5% de translação horizontal (D), após 5% de translação vertical (E), e após 5% de translação horizontal e vertical (F).



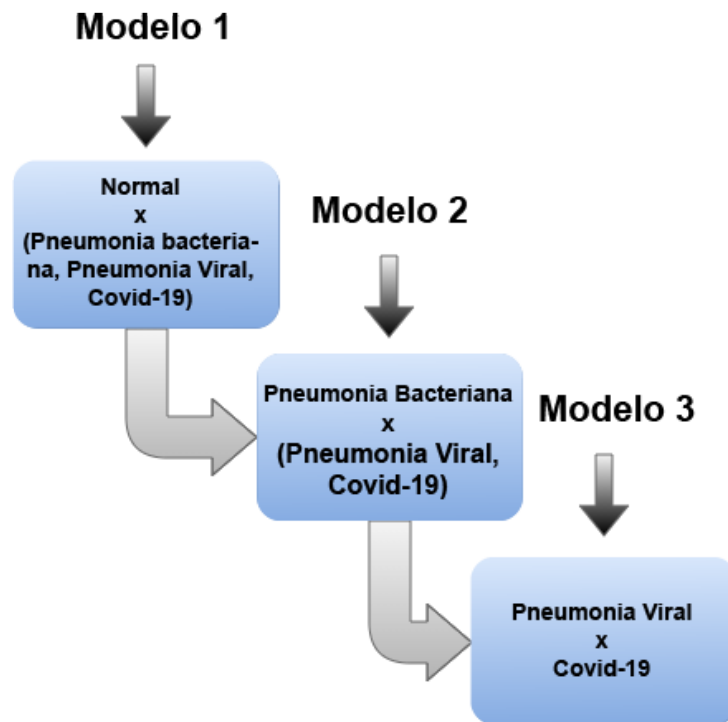
Fonte: Autoria própria.

Como mencionado anteriormente foram treinados 3 modelos de CNNs para a classificação de imagens de Raio-X, cada modelo foi treinado para resolver uma classificação específica descrita abaixo, as entradas dos três modelos corresponde a uma imagem de 3 canais com  $128 \times 128$  pixels correspondente a altura e largura da imagem. Como pré-processamento das imagens foi usado a técnica de Aumento de imagem descrito na Seção 4.2.12, as técnicas usada nos três modelos foi a rotação e translação como descrito na Figura 16, com isso cada classe de imagens é aumenta 5

vezes a mais na etapa de treinamento, consequentemente obtendo uma melhoria de desempenho do modelo.

Na Figura 17 é possível analisar os três modelos em cascata usados, abaixo é descrito os detalhes do desenvolvimento destes modelos:

Figura 17 – Modelo em cascata.

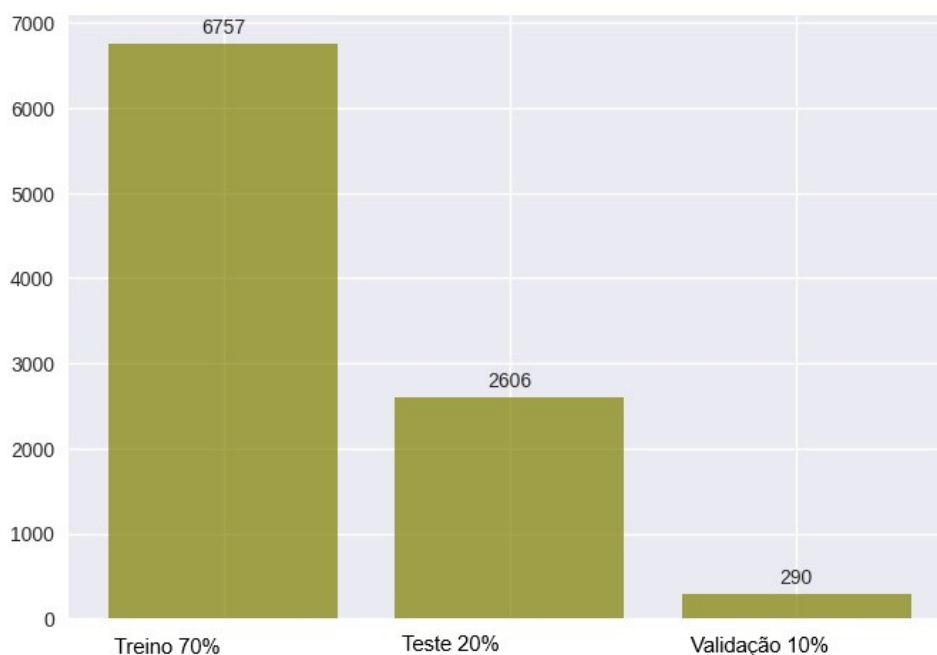


Fonte: Autoria própria.

#### • Modelo 1

- O modelo 1 é responsável pela a classificação de (Pneumonia x Normal), ou seja, esse modelo identifica se o Raio-X possui ou não Pneumonia.
- No treinamento deste modelo foi usado todas as imagens de Raio-x, as classes de pneumonia foram mescladas de forma aleatória, as divisões dos dados podem ser vista na Figura 18.
- Foi usado 100 épocas de treinamento com o *batchsize* de 20 imagens, otimizador usado foi *RMSprop* com uma taxa de aprendizagem de 0.0001 e função de perda é a *binarycrossentropy*, o tempo usado para o treinamento deste modelo foi cerca de 51 minutos.

Figura 18 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-x do **Modelo 1**.

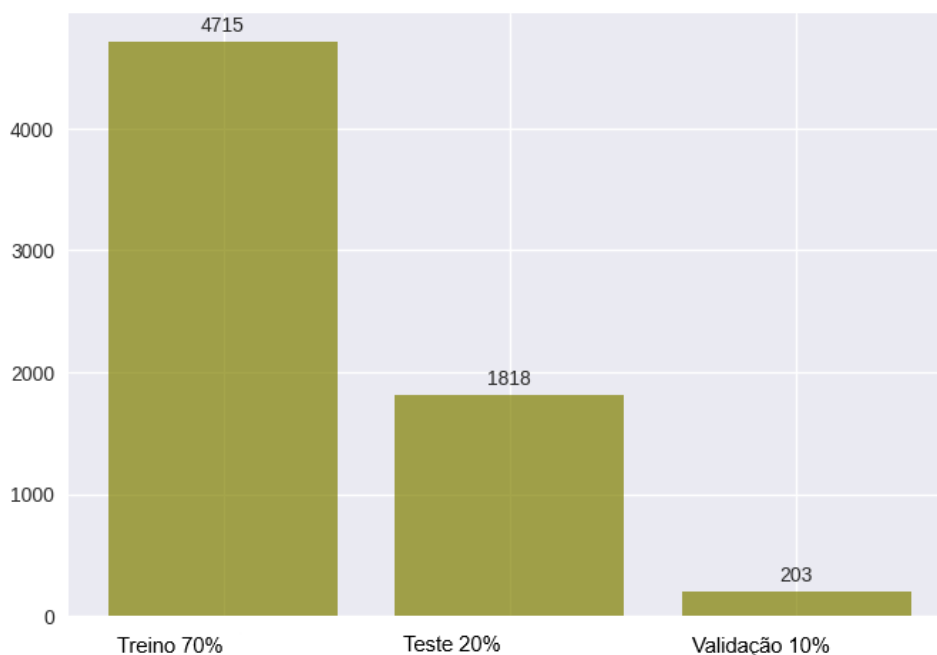


Fonte: Autoria própria.

#### • Modelo 2

- O modelo 2 é responsável pela a classificação de (Pneumonia Bacteriana x Pneumonia viral), ou seja, esse modelo identifica qual o tipo do agente causador da Pneumonia.
- No treinamento deste modelo foi usado apenas as imagens de Raio-X das classes de Pneumonia viral, bacteriana e Covid-19, as imagens de pneumonia foram mescladas de forma aleatória, as divisões dos dados podem ser vista na Figura 19.
- Foi usado 100 épocas de treinamento com o *batchsize* de 20 imagens, otimizador usado foi *RMSprop* com uma taxa de aprendizagem de 0.0001 e função de perda é a *binarycrossentropy*, o tempo usado para o treinamento deste modelo foi cerca de 25 minutos.

Figura 19 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-x do **Modelo 2**.




Fonte: Autoria própria.

### • Modelo 3

- O modelo 3 é responsável pela a classificação de (Pneumonia por Covid-19 x Pneumonia por outros vírus), ou seja, esse modelo identifica qual o tipo de vírus está causando a Pneumonia.
- No treinamento deste modelo foi usado apenas as imagens de Raio-X das classes de Pneumonia viral e Pneumonia causada por Covid-19, as imagens de pneumonia foram mescladas de forma aleatória, as divisões dos dados podem ser vista na Figura 20.
- Foi usado 100 épocas de treinamento com o *batchsize* de 20 imagens, otimizador usado foi *RMSprop* com uma taxa de aprendizagem de 0.0001 e função de perda é a *binarycrossentropy*, o tempo usado para o treinamento deste modelo foi cerca de 15 minutos.

Figura 20 – Divisão dos dados em treinamento, teste e validação das imagens de Raio-X do **Modelo 3**.



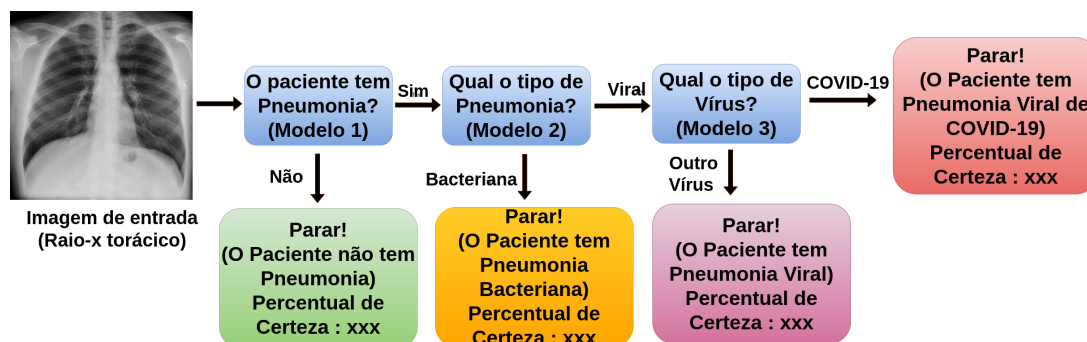
Fonte: Autoria própria.

### 5.3.3 APLICATIVO MÓVEL DE CLASSIFICAÇÃO DE RAIOS-X (CNN-PULMONA)

A interface do aplicativo, foi optada por uma mais simples de utilizar, justamente para ter o máximo de eficácia e rapidez no diagnóstico. Na parte inicial, o usuário terá que fazer o carregamento da imagem de Raio-X desejada, para poder iniciar o diagnóstico, como mostrado na imagem da Figura 30.

O diagnóstico do aplicativo, tem possíveis saídas: Normal, Pneumonia Bacteriana, Pneumonia Viral e Pneumonia causada pelo vírus COVID-19. O processo de análise do Raio-X pela rede neural, se dá em partes, ou seja, o fluxo de diagnóstico possui 3 possíveis etapas de classificação. Essas etapas são constituídas cada uma por uma rede neural, em que, dependendo do resultado de cada uma, a imagem vai ou não ser passada para o passo adiante. Essas condições podem ser vistas de acordo com a Figura 21.

Figura 21 – Funcionamento do sistema.



Fonte: Autoria própria.

Como pode-se analisar no Algoritmo 1, tem-se de modo resumido, toda o controle da aplicação e etapas possíveis para se fazer uma análise de uma determinada imagem de Raio-X. Logo de início de todas as etapas, o aplicativo terá que ter previamente uma imagem carregada para que possa iniciar as análises. Após carregada a imagem, a mesma irá ser pré-processada para que fique de acordo com as entradas das redes neurais. Assim que a imagem estiver com as dimensões corretas,

a mesma irá passar pelos processos como é descrito no Algoritmo 1.

**Algoritmo 1:** Algoritmo de controle da aplicação móvel ( CNN-Pulmona.)

```

1 Funcao preverImagem(nomeModelo, img) :
2   modelo = carregarModelo(nomeModelo);
3   resultado = modelo.prever(img);
4   retorna resultado;
5 img = carregarImagem(localImagem);
6 imgProcessada = preprocessamento(img);
7 eventoBotao = capturarEvento();
8 se eventoBotao == 'classificar' então
9   resultado = preverImagem(modelo1, imgProcessada);
10  exibirResultado(resultado);
11  eventoBotao = capturarEvento();
12  se resultado == 'Pneumonia' e eventoBotao == 'Agente causador' então
13    resultado = preverImagem(modelo2, imgProcessada);
14    exibirResultado(resultado);
15    eventoBotao = capturarEvento();
16    se resultado == 'Viral' e eventoBotao == 'Covid-19 análise' então
17      resultado = preverImagem(modelo3, imgProcessada);
18      exibirResultado(resultado);
19      eventoBotao = capturarEvento();
20    senão
21      Busca uma nova imagem para refazer a análise.
22    fim
23  senão
24    Busca uma nova imagem para refazer a análise.
25  fim
26 senão
27   Busca uma nova imagem para refazer a análise.
28 fim

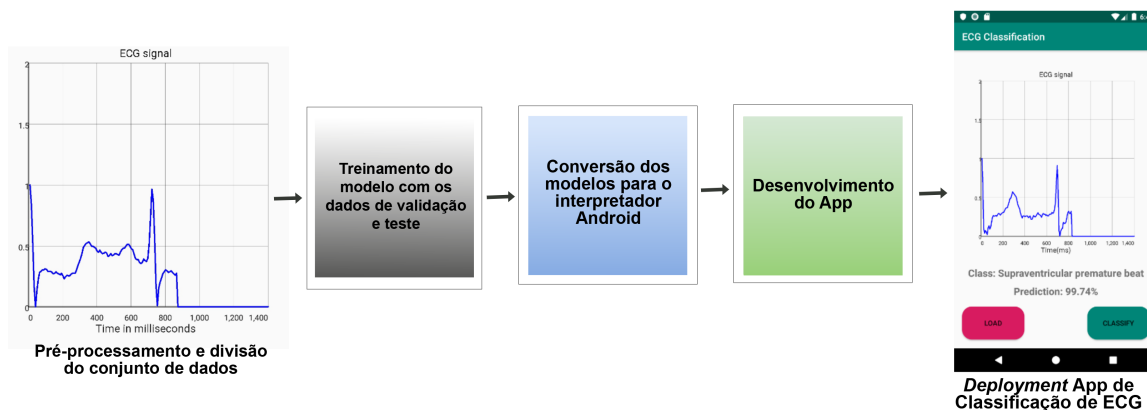
```

## 5.4 CLASSIFICAÇÃO DE SINAIS DE ECG (CNN-CARDIO)

Esta seção apresenta os métodos usados para desenvolver o aplicativo móvel CNN-Cardio. O diagrama ilustrado na Figura 22 mostra as principais partes constituintes do método. É composto por cinco etapas principais: a) Pré-processamento e divisão do conjunto de dados; b) Treinamento, validação e teste do modelo; c) Converter modelos para interpretador Android; d) Desenvolvimento do aplicativo e, por fim, e) *Deployment* do aplicativo de classificação de ECG, onde é analisado o desempenho e

o custo computacional de cada modelo.

Figura 22 – Fluxograma do sistema de classificação de ECG.



Fonte: Autoria própria.

#### 5.4.1 DATASET DE ECG

O banco de dado usado é o *Arrhythmia Dataset* do MIT-BIH (GOLDBERGER et al., 2000), contendo 48 trechos de meia hora de registros de ECG ambulatorial de dois canais, obtidos de 47 indivíduos estudados pelo Laboratório de arritmia BIH entre 1975 e 1979. Vinte e três registros foram escolhidos aleatoriamente de um conjunto de 4000 registros de ECG ambulatorial de 24 horas coletados de uma população mista de pacientes internados (cerca de 60%) e ambulatoriais (cerca de 40%) no Hospital Beth Israel de Boston, mas informações sobre a origem dessa base pode ser encontras em (GOLDBERGER et al., 2000).

Em todos os experimentos, é usado a derivação de ECG II para a frequência de amostragem de 125 Hz como entrada da CNN. Também houve um pré-processamento no conjunto de dados MIT-BIH, criando uma nova tabela de frequência cardíaca dividida em 5 novas categorias de acordo com o padrão AAMI EC57 (INSTRUMENTATION et al., 1998), (KACHUEE; FAZELI; SARRAFZADEH, 2018), que são: Normal, Batimento Supraventricular Prematuro, Escape Ventricular, Fusão de Ventricular e Normal, Batimento inclassificável, abaixo os métodos usado para extração dos sinais ECG, baseado no trabalho de (KACHUEE; FAZELI; SARRAFZADEH, 2018).

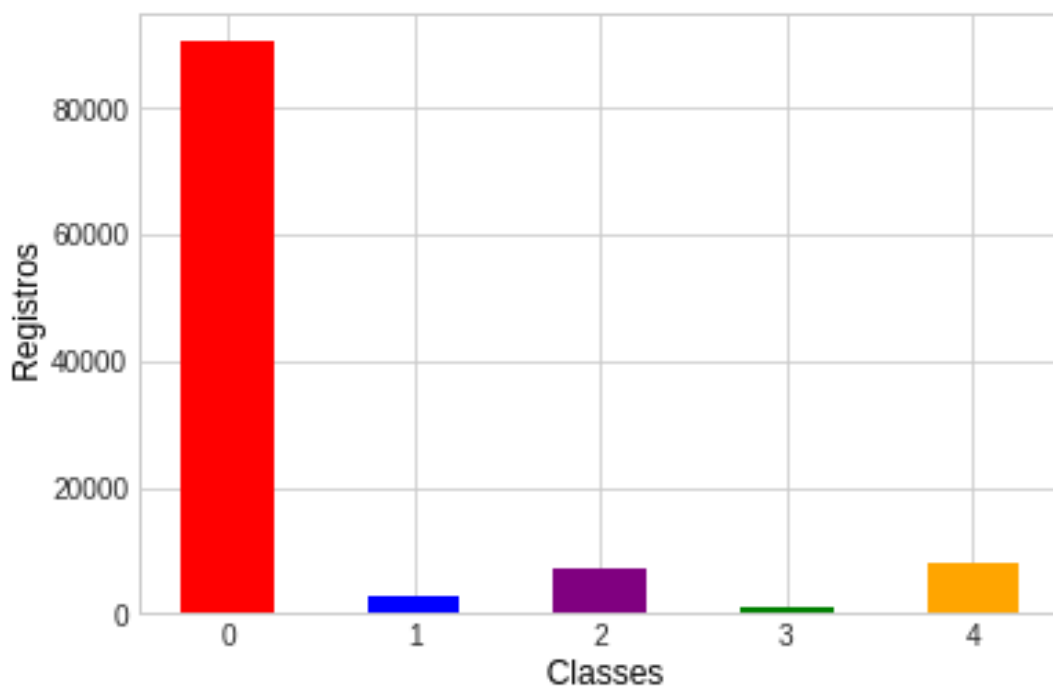
- Um janelamento de 10 segundos para amostra e preenchidas com zeros se necessário para uma dimensão fixa de 187 valores.
- Normalizando os valores de amplitude para o intervalo entre zero e um.

- Encontrar o conjunto de todos os máximos locais com base nos cruzamentos de zero da primeira derivada.
- Encontrar a mediana dos intervalos de tempo R-R como o nominal período de batimento cardíaco dessa janela (T).
- Para cada pico R, selecionando uma parte do sinal com o comprimento igual a  $1.2T$ .

Também houve um pré-processamento no conjunto de dados MIT-BIH, criando uma nova tabela de frequência cardíaca dividida em 5 novas categorias/casses de acordo com o padrão AAMI EC57 (INSTRUMENTATION et al., 1998), (KACHUEE; FAZELI; SARRAFZADEH, 2018), que são: Normal, Batimento Supraventricular Prematuro, Escape Ventricular, Fusão de Ventricular e Normal, Batimento inclassificável.

As casses estão distribuídas da seguinte forma: classe 0 com 90,589, classe 1 com 2,779, classe 2 com 7,236, classe 3 com 803 e classe 4 com 8,039 amostras que podem ser observada na Figura 23.

Figura 23 – Número de dados para cada classe.



Fonte: Autoria própria.


Diante da representação numérica da quantidade de cada registros das classes acima, temos:

- **Classe 0:**

- Batimento normal:  
Que seria um sinal de ECG de uma pessoa com sua saúde cardíaca em condições normais e saudável.
- **Classe 1:**
  - Batimento supraventricular prematuro:  
Representam uma ativação prematura dos átrios de um local diferente do nodo sinusal e podem se originar dos átrios ou do nodo atrioventricular (chamados batimentos prematuros funcionais) (KOCHHÄUSER et al., 2014).
- **Classe 2:**
  - Contração ventricular prematura:  
É um evento em que o batimento cardíaco é iniciado pelas fibras de Purkinje nos ventrículos, e não pelo nó sinoatrial, o iniciador de batimentos cardíacos normal (SALAVATIAN et al., 2019).
- **Classe 3:**
  - Fusão de batimento ventricular e normal:  
Uma batida de fusão ocorre quando impulsos elétricos de diferentes fontes atuam na mesma região do coração ao mesmo tempo (CONOVER, 2002).
- **Classe 4:**
  - Batida sem classificação:  
Batidas em que não tiveram associadas a nenhuma classificação.

Cada classe apresentada, consiste em sinais de diferentes tipos de espectros, ou seja, representações gráficas da distribuição da intensidade de um comprimento de onda, a partir de um determinado sinal. Na Figura 24, está representado cada classe de sinal de ECG, contendo dez amostras para cada rótulo.

Figura 24 – Exemplo de dez amostras de sinais com o janelamento de 10 segundos para cada classe após a extração dos sinais.




Fonte: Autoria própria.

#### 5.4.2 ARQUITETURA E TREINAMENTO DA CNN PARA CLASSIFICAÇÃO DE ECG

Para a tarefa de classificação de sinais de ECG é realizada a reimplementação de uma CNN proposta na literatura (KACHUEE; FAZELI; SARRAFZADEH, 2018), porém utilizando uma otimização Bayesiana de Hiperparâmetros, conseguindo assim uma melhoria no desempenho da rede e conseqüentemente mudando sua arquitetura, na Tabela 2 e na Figura 25 é possível analisar a arquitetura CNN após a otimização Bayesiana.

O conjunto de dados foi dividido em treinamento teste e validação, com 50% de cada classe de dados usada para treinamento, 25% usada para validação e 25% teste. Como mencionado na seção 5.4.1, nem todos os sinais têm o mesmo comprimento, para tratar este problema é usado o mesmo pré-processamento realizado por (KACHUEE; FAZELI; SARRAFZADEH, 2018), as amostras são cortadas, reduzidas ou preenchidas com zeros, se necessário, para uma dimensão fixa de 187 valores.

Figura 25 – Arquitetura da CNN usada para a classificação de ECG no app CNN-Cardio.



Fonte: Autoria própria.

Conforme mencionado na seção 5.1, os hiperparâmetros otimizados foram: Taxa de aprendizagem, Número de camadas densas, Número de nós densos, Função de ativação. A otimização Bayesiana teve 40 iterações com 100 épocas de treinamento e validação, ou seja, a cada interação o modelo é treinado e validado, após um treinamento da rede os hiperparâmetros são atualizados.

Com isso, a rede proposta tem cinco blocos de convolução residual, em todas as camadas de convolução, a convolução  $1D$  é aplicada e cada um tem um tamanho de *kernel* de tamanho 5, o pool máximo com tamanho 5 e o passo 2. Os melhores resultados de otimização para o número de camadas conectadas foi de 2 camadas com o número de 274 neurônios em cada camada, com a função de ativação *ReLU* e uma última camada de 5 neurônios de acordo com o número de classes, com uma taxa de aprendizagem de 0,00027 e o tamanho do lote de 128 amostras, a entrada da rede consiste em um vetor unidimensional com 128 valores correspondentes a uma amostra de sinal de ECG.

Cada interação de otimização Bayesiana demorou cerca de 9 minutos para treinar e validar a rede neural, ou seja, com 40 interações de otimização hiperparâmetro, todo o processo demorou cerca de 360 minutos, usado o *Hardware* mencionado no início do Capítulo 5, para a implementação da rede neural, é usada a biblioteca de aprendizado de máquina TensorFlow (ABADI et al., 2016).

Tabela 2 – Sumário da rede neural usada para a classificação de sinal ECG no app CNN-Cardio.

Camadas	Tipo	Função de Ativação	Tamanho do Kernel	Nº de Filtros	Formato de Saída	Stride	Padding	Dropout	Nº de parâmetros treináveis
1	Conv. 1D	<i>ReLU</i>	5x1	32	183x32	1	<i>same</i>	-	192
2	Conv. 1D	<i>ReLU</i>	5x1	32	183x32	1	<i>same</i>	-	5152
3	Conv. 1D	<i>ReLU</i>	5x1	32	183x32	1	<i>same</i>	-	5152
4	MaxP. 1D	-	5x1	-	90x32	2	-	-	0
5	Conv. 1D	<i>ReLU</i>	5x1	32	90x32	1	<i>same</i>	-	5152
6	Conv. 1D	<i>ReLU</i>	5x1	32	90x32	1	<i>same</i>	-	5152
7	MaxP. 1D	-	5x1	-	43x32	2	-	-	0
8	Conv. 1D	<i>ReLU</i>	5x1	32	43x32	1	<i>same</i>	-	5152
9	Conv. 1D	<i>ReLU</i>	5x1	32	43x32	1	<i>same</i>	-	5152
10	MaxP. 1D	-	5x1	-	20x32	2	-	-	0
11	Conv. 1D	<i>ReLU</i>	5x1	32	20x32	1	<i>same</i>	-	5152
12	Conv. 1D	<i>ReLU</i>	5x1	32	20x32	1	<i>same</i>	-	5152
13	MaxP. 1D	-	5x1	-	8x32	2	-	-	0
14	Conv. 1D	<i>ReLU</i>	5x1	32	8x32	1	<i>same</i>	-	5152
15	Conv. 1D	<i>ReLU</i>	5x1	32	8x32	1	<i>same</i>	-	5152
16	MaxP. 1D	-	5x1	-	2x32	2	-	-	0
17	Fully-connected	<i>ReLU</i>	-	-	274	-	-	25%	17810
18	Fully-connected	<i>ReLU</i>	-	-	274	-	-	25%	75350
19	Fully-connected	<i>Softmax</i>	-	-	5	-	-	-	1375

### 5.4.3 APLICATIVO MÓVEL DE CLASSIFICAÇÃO DE ECG (CNN-CARDIO)

Foi utilizado o kit de desenvolvimento *Flutter*, criado pelo *Google* (PAYNE, 2019), onde é possível desenvolver aplicativos para Android e IOS. O aplicativo foi desenvolvido para a plataforma Android, tendo como objetivo, a classificação de sinais de ECG. A entrada dos dados consiste em carregar um arquivo de texto contendo o sinal a ser analisado e, após o sinal ser carregado, o mesmo passará pela rede neural onde será classificado. A saída será dada, disponibilizando sua classe na qual foi classificada pela rede juntamente com o percentual de certeza da rede ao classificar a mesma. A interface do aplicativo pode ser observada de acordo com as Figuras: 31, 33.

No Algoritmo 2 pode-se analisar todo fluxo de controle do aplicativo para analisar sinais de ECG. Como pode-se observar, o aplicativo espera um arquivo CSV contendo o sinal e assim no que o mesmo é carregado, é pré-processado para deixar

de acordo com a entrada da rede neural para então obter o resultado.

**Algoritmo 2:** Algoritmo de controle da aplicação móvel (CNN-Cardio)

```

1 sinal = lerCsv(arquivo.csv);
2 sinalProcessado = preprocessamento(sinal);
3 modelo = carregarModelo(modelo_ecg);
4 eventoBotao = capturarEvento();
5 se eventoBotao == 'classificar' então
6     resultado = modelo.prever(sinalProcessado);
7     exibirResultado(resultado);
8     eventoBotao = capturarEvento();
9 senão
10     Espera a entrada do sinal para análise.
11 fim

```

## 5.5 COMPARAÇÃO DE TÉCNICAS DE COMPRESSÃO EM SINAIS BIOMÉDICOS

A compressão de dados é utilizada para poupar espaço de armazenamento e banda na transmissão destes dados, sendo fatores essenciais em dispositivos móveis, onde tem limitação recursos de armazenamento e limitação de Internet pela franquia de dados do usuário. Nesse caso, a escolha de uma técnica que tenha uma boa taxa de compressão e uma reconstrução fiel ao sinal original é de vital importância, para isso é necessário comparar as técnicas de compressão e escolher a que mais seja favorável neste contexto de dispositivos móveis.

### 5.5.1 APLICAÇÃO DAS TRANSFORMADAS

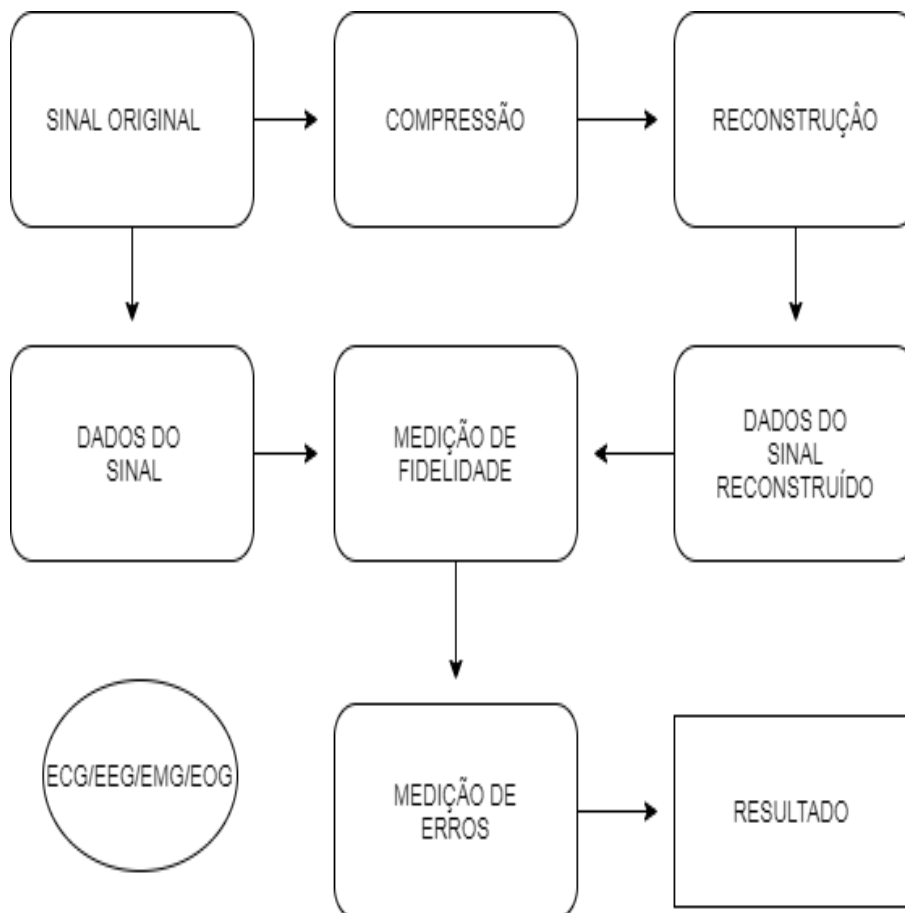
Na Figura 26, foi ilustrado o método de compressão proposto em um diagrama de blocos simples, o exemplo mostra o processo de comparação entre as técnicas de compressão, FWHT, DCT e DWHT.

Primeiramente, o sinal é retirado de uma fonte, neste caso o MIT-Database foi escolhido como base de dados de sinais, as vezes o sinal captado possui ruído, então para resolver isso realizou-se uma filtragem com *Finite Impulse Response* (FIR) Passa Banda, mais detalhes sobre esse filtro pode ser visto no trabalho de (LIAN; HO, 2004). Então, o sinal que foi recebido é carregado no software, logo depois os dados são retirados e serão usados para uma comparação posterior, antes disso, a técnica de compressão é aplicada no sinal, se o FWHT for aplicado, o sinal é repetido 8 vezes e então, um ruído aleatório é adicionado antes do compressão, no caso do DCT e DWT

não serão necessário (SARAIVA et al., 2019).

Após compactado o sinal, obtemos os dados do sinal de entrada e para isso é adicionada a transformada inversa da respectiva técnica de compressão, obtendo com isso um sinal reconstruído. Os sinais reconstruídos podem variar dependendo da técnica de compressão, neste caso, o FWHT tem como sinal reconstruído 8x maior do que o sinal reconstruído DCT e DWT devido à repetição usada precocemente.

Figura 26 – Aplicação dos métodos de compressão.



Fonte: Autoria própria.

As dados do sinal reconstruído foram comparados com o tamanho do sinal original da respectiva técnica, então após a comparação entre o sinal original e o sinal reconstruído, lembrando-se que o sinal reconstruído FWHT deve ser comparado com o sinal original repetido 8x por causa do seu tamanho. O sinal reconstruído após usar a DCT deve ser comparado com o sinal original também por causa do seu tamanho, tendo em vista que o sinal se comporta de maneiras diferentes de acordo com a técnica de compressão e reconstrução, no DWT o sinal não passa por uma repetição (SOUSA et al., 2020b).

Para tanto, as estatísticas utilizadas são: o Erro Quadrático Médio (MSE), Erro Absoluto Médio (MAE), Razão Sinal Ruído (SNR) e Razão Pico Sinal Ruído (PSNR),

com essas métricas, a qualidade e semelhança dos sinais podem ser testadas, de acordo com os resultados obtidos. Na análise de fidelidade do sinal reconstruído em comparação com o sinal original com as transformadas FWHT, DWT ou DCT, tendo em vista que cada técnica tem seu próprio tamanho de sinal original e reconstruído. Na FWHT o sinal foi repetido 8 vezes para obter os coeficientes WHT, o tempo computacional em cada algoritmo foi menor que um segundo.

## 6 RESULTADOS

Neste capítulo são apresentados os resultados deste trabalho que tem múltiplas contribuições para o auxiliar os profissionais de saúde, primeiramente, destaca-se a classificação de imagens de Raio-X no app CNN-Pulmona, logo em seguida o desenvolvimento do outro app, CNN-Cardio, já direcionado para classificação de sinais de ECG e no final a definição da técnica de compreensão de dados de sinais.

### 6.1 RESULTADOS DA CLASSIFICAÇÃO DE IMAGENS DE RAIOS-X (CNN-PULMONA)

Os resultados dos modelos usados para o desenvolvimento do aplicativo CNN-Pulmona podem ser vistos de acordo com as Tabelas 3 e 4. Assim como visto na seção de 5.3.3, cada modelo é chamado de acordo como a imagem de Raio-X vai sendo classificada, ou seja, dependendo da previsão de um modelo, pode ser passada para outra ou não, de acordo com a Figura 21. Assim, pode-se observar que a partir das métricas de validação desses modelos, mostra-se bastante eficiente no processo de classificação de Pneumonia através do Raio-X torácico. Apenas o modelo Pneumonia viral vs Pneumonia bacteriana ficou um pouco abaixo dos outros em relação às métricas de avaliação, mas ainda sim contendo taxas bastante positivas para a tarefa de classificação acerca da Pneumonia viral e bacteriana, se comparado a trabalhos recentes da literatura.

Tabela 3 – Resultados das métricas para os dados de **Teste**.

Classificação	Modelo	Acurácia	Precisão	Recall	F1-Score	Kappa	ROC AUC
Normal x Pneumonia	Modelo 1	98.58%	98.57%	99.39%	98.97%	96.64%	98.07%
Pneumonia Bacteriana x Pneumonia Viral	Modelo 2	85.47%	86.19%	77.82%	81.79%	69.76%	84.41%
Outros Vírus x Covid-19	Modelo 3	99.16%	99.87%	98.97%	99.42%	97.91%	99.31%

Fonte: Autoria própria.

Tabela 4 – Resultados das métricas para os dados de **Validação**.

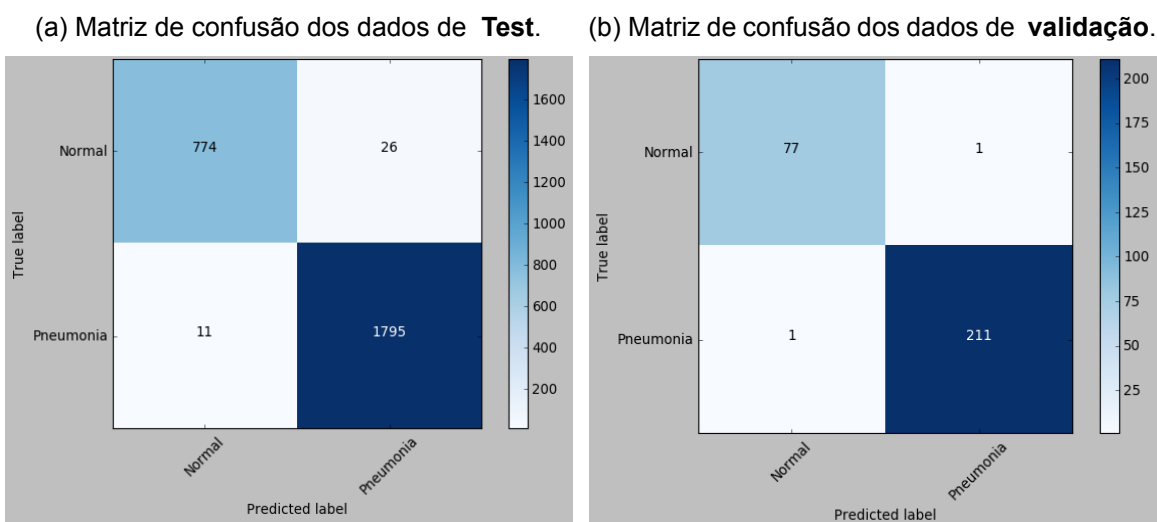
Classificação	Modelo	Acurácia	Precisão	Recall	f1-Score	Kappa	ROC AUC
Normal x Pneumonia	Modelo 1	99.31%	99.52%	99.52%	99.52%	98.24%	99.12%
Pneumonia Bacteriana x Pneumonia Viral	Modelo 2	87.19%	82.85%	80.55%	81.69%	71.84%	85.69%
Outros Vírus x Covid-19	Modelo 3	99.16%	99.99%	98.68%	99.33%	98.21%	99.34%

Fonte: Autoria própria.

Como mencionado anteriormente na seção 5.3.2, os modelos foram treinados, testados e validados com imagens de Raio-X de vários datasets, dessa forma o aprendizado dos modelos se torna uma tarefa desafiadora por ter uma variedade de imagens grande. Porém com as técnicas usadas descritas na seção 5.3.2, os modelos tiveram bons desempenhos se comparados com trabalhos da Tabela 13. Os modelos foram treinados com dados desbalanceado e para minimizar esse problema a técnica de aumento de imagem foi usada, seção 4.2.12, com isso é possível analisar nas Tabelas 3, 4 e nas Figuras 27, 28, 29, que os modelos tiveram bons desempenho mesmo com os dados desbalanceado.

Uma opção bastante usada para avaliar um modelo de rede neural, podendo ser vista também nesses trabalhos (SOUSA et al., 2020a; SARAIVA. et al., 2019; SARAIVA et al., 2019; SARAIVA et al., 2019), é a matriz de confusão. Uma matriz de confusão é uma tabela frequentemente usada para descrever o desempenho de um modelo de classificação em um conjunto de dados de teste para os quais os verdadeiros valores são conhecidos. Os valores nas tabelas constituem dos verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Os verdadeiros positivos e falsos positivos são valores nas quais a rede neural classificou corretamente, enquanto os valores verdadeiros negativos e falsos negativos teve um equívoco na classificação. Nas figuras 27, 28 e 29 pode-se observar as matrizes de confusão para cada rede. Para cada matrizes dessas, os valores positivos estão dispostos na diagonal principal, do mesmo modo, na diagonal secundária, estão dispostos os valores negativos classificados pela rede.

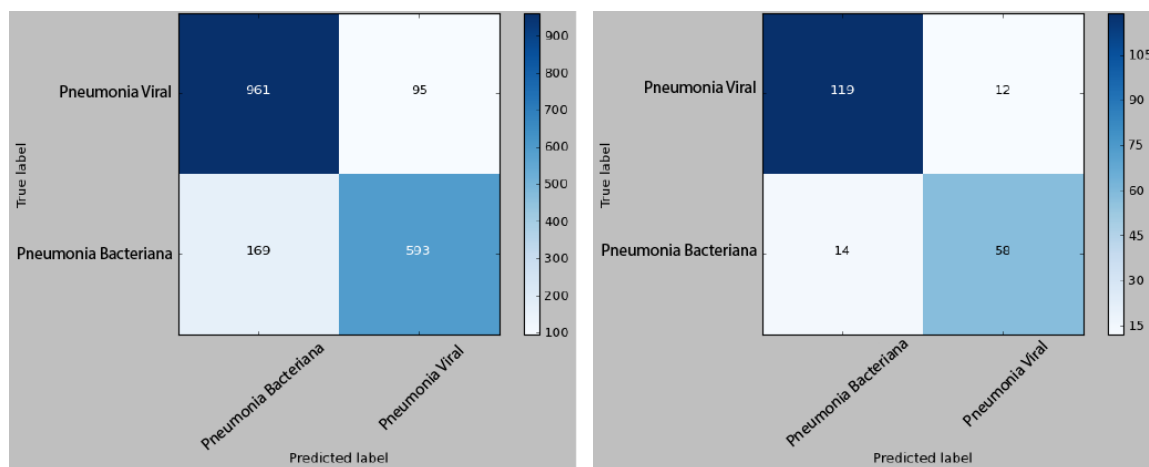
Figura 27 – Matriz de confusão da classificação Normal x Pneumonia (Modelo 1).



Fonte: Autoria própria.

Figura 28 – Matriz de confusão da classificação Pneumonia Viral x Pneumonia Bacteriana (Modelo 2).

(a) Matriz de confusão dos dados de **Teste**. (b) Matriz de confusão dos dados de **validação**.



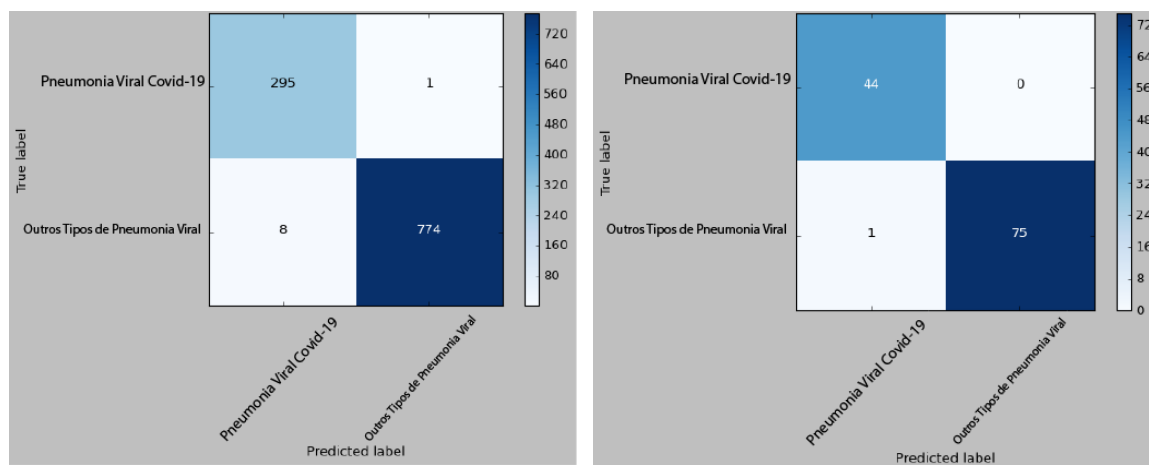
Fonte: Autoria própria.

Os dados usados para o desenvolvimento dos modelos foram divididos em três subconjuntos (Treinamento, Teste e Validação), seção 5.3.2. Após usar a otimização Bayesiana para encontrar os hiperparâmetros ótimos, os modelos são treinados e testados, logo após isso o modelo é avaliado com o conjunto de dados de validação, esse conjunto de validação o modelo só tem contato depois de treinado e testado. Com isso é possível analisar o quão bom o modelo pode generalizar os dados de classificação, como pode-se observar nas Tabelas 3, 4, os modelos obtiveram um desempenho semelhantes aos dados de teste.

Nas matrizes de confusão das 27, 28 e 29, é possível analisar a quantidade de acertos e erros nos conjuntos de teste e validação, apenas o Modelo 2 obteve um desempenho abaixo dos demais modelos, porém os resultados do mesmo se comparado os resultados de outros modelos da literatura, Tabela 13, obteve um desempenho promissor. Dessa forma é possível observar que mesmo com os conjuntos de dados desbalanceado os modelos obtiveram desempenho bons se comparado ao estado da arte.

Figura 29 – Matriz de confusão da classificação Pneumonia por outros Vírus x Pneumonia por Covid-19 (Modelo 3).

(a) Matriz de confusão dos dados de **teste**. (b) Matriz de confusão dos dados de **validação**.



Fonte: Autoria própria.

Na Tabela 5 pode-se observar a descrição dos recursos e tamanho dos três modelos usados no aplicativo CNN-Pulmona. Os resultados dispostos nesta tabela são compostos de uma média dos resultados obtida entre os três modelos de redes neurais, já que os números acerca de cada modelo diferem pouca variação.

Tabela 5 – Resultados do uso computacional do aplicativo CNN-Pulmona.

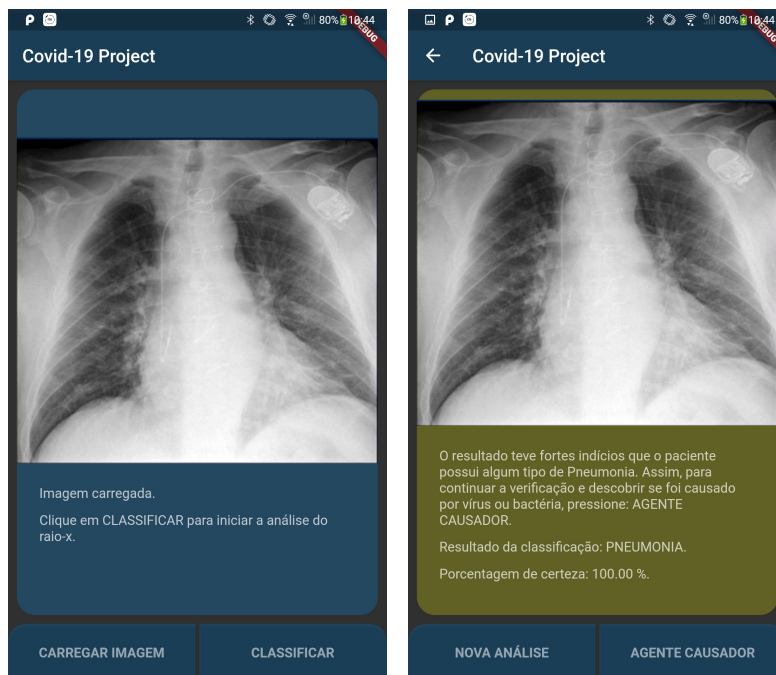
Método de quantização	Uso de memória RAM	Tempo de processamento	Uso médio do processador	Tamanho final em MB	Perda de acurácia
Quantização de faixa dinâmica da CNN	4.0 MB	845 milissegundos	8%	2.5 MB	0.0%
Quantização de número inteiro completo da CNN	4.11 MB	557 milissegundos	6,4%	2,65 MB	0.4%

Fonte: Autoria própria.

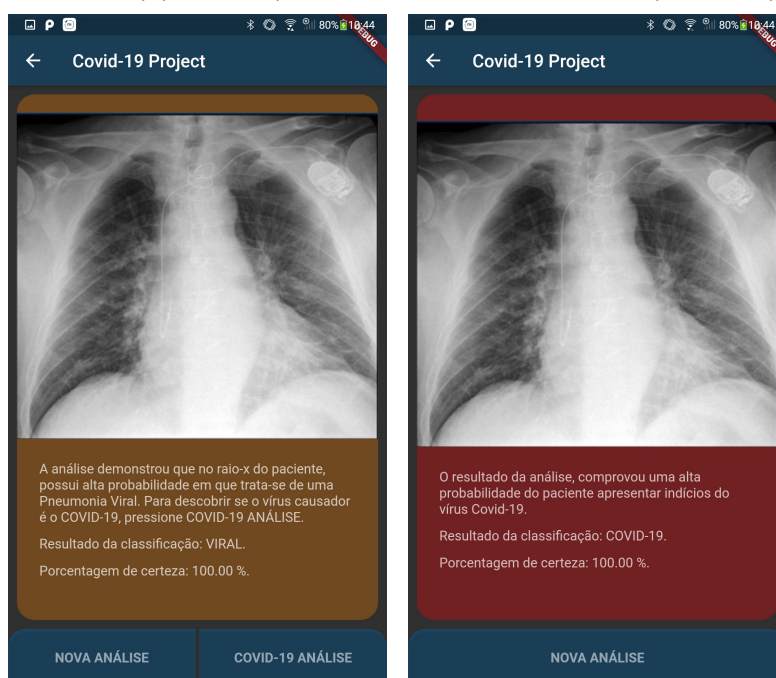
De acordo com a Tabela 5 é possível observar os recursos usados para fazer o carregamento dos modelos do aplicativo CNN-Pulmona. Assim, além do total de memória RAM consumida pelo sistema e uso médio do processador do *smartphone*, tem-se também o tempo que as redes neurais demoram para fazer a tarefa de carregar o modelo e classificar uma imagem de Raio-X. A partir disso, pode-se analisar que o usado do sistema CNN-Pulmona em um *smartphone*, consome poucos recursos, além da rapidez do processo de classificação. O *smartphone* utilizado para os testes foi o Zenfone 4, que possui processador 4x 2,2 GHz + 4x 1,8 GHz e 4 GB de RAM.

Figura 30 – Exemplo de uma classificação para um Raio-X possuindo indícios para o vírus Covid-19. Em cada estágio, é possível observar a classe para a qual o modelo prediz, assim como a taxa probabilidade de ser dessa classe.

- (a) Primeiro estágio do aplicativo em que o usuário irá carregar uma imagem de Raio-X. (b) Segundo estágio em que o aplicativo irá detectar se há presença de pneumonia (modelo 1).



- (c) Terceiro estágio responsável por detectar o agente causador da pneumonia (vírus ou bactéria) (modelo 2). (d) Quarto estágio em que se for detectado uma pneumonia viral (esse exemplo), irá verificar se possui indícios ou não de Covid-19 (modelo 3).



Fonte: Autoria própria.

No aplicativo CNN-Pulmona possui descrições a partir de cada detecção dos modelos propostos de acordo com a Figura 17 na Seção 5.3.2, de acordo com o modelo em cascata. Cada etapa tem dois possíveis resultados em que para cada um dos resultados, possui uma descrição no aplicativo para auxiliar o usuário.

As descrições para cada resultado das etapas pode ser vista logo abaixo (exemplo de uma classificação pode ser vista na Figura 30):

- **Etapa 1**

- Para o resultado do Raio-X Normal, possui a seguinte descrição:

”No resultado da classificação do Raio-X, não teve nenhum indício que possui alguma doença relacionada a Pneumonia.”

- Para o resultado do Raio-X possuindo Pneumonia, possui a seguinte descrição:

”O resultado teve fortes indícios que o paciente possui algum tipo de Pneumonia. Assim, para continuar a verificação e descobrir se foi causado por vírus ou bactéria, pressione: AGENTE CAUSADOR.”

- **Etapa 2**

- Para o resultado do Raio-X como Viral, possui a seguinte descrição:

”A análise demonstrou que no Raio-X do paciente possui alta probabilidade em que trata-se de uma Pneumonia Viral. Para descobrir se o vírus causador é o COVID-19, pressione COVID-19 ANÁLISE.”

- Para o resultado do Raio-X como bactéria, possui a seguinte descrição:

”A análise demonstrou que no Raio-X do paciente, possui altos indícios que, trata-se de uma pneumonia causada por uma bactéria.”

- **Etapa 3**

- Para o resultado do Raio-X como não detectado Covid-19, possui a seguinte descrição:

”No resultado demonstrou que no Raio-X do paciente possui um tipo de Pneumonia, mas há altas chances de não se tratar do Covid-19, e sim outro vírus.”

- Para o resultado do Raio-X como possuindo Covid-19, possui a seguinte descrição:

”O resultado da análise, comprovou uma alta probabilidade do paciente apresentar indícios do vírus COVID-19.”

## 6.2 RESULTADOS DA CLASSIFICAÇÃO DE SINAIS DE ECG (CNN-CARDIO)

Nas tabelas 6 e 7 é possível observar as métricas usadas para a validação do modelo usado no desenvolvimento do aplicativo CNN-Cardio, tanto na base de dados de teste quanto na validação. Observa-se que a partir dos resultados, o modelo obteve números excelentes na validação do modelo, podendo ser comparado com trabalhos na literatura utilizando a mesma base de dados do método proposto neste trabalho, podendo ser visto a comparação dos trabalhos de acordo com a tabela 14.

Tabela 6 – Resultados da CNN antes da quantização para cada classe com os dados de **Teste**.

Classe	Precisão	ACC	Recall	F1	MCC	ROC
Batimento Normal	0.99	0.99	1.00	0.99	0.96	0.98
Batimento supraventricular prematuro	0.92	0.99	0.84	0.88	0.87	0.92
Contração ventricular prematura	0.97	1.00	0.96	0.96	0.96	0.98
Fusão de batimento ventricular e normal	0.84	1.00	0.73	0.78	0.78	0.87
Batida inclassificável	0.99	1.00	0.99	0.99	0.99	0.99
<b>Macro average</b>	<b>0.94</b>	<b>0.99</b>	<b>0.99</b>	<b>0.92</b>	<b>0.91</b>	<b>0.95</b>
<b>Micro average</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>

Fonte: Autoria própria.

Tabela 7 – Resultados da CNN antes da quantização para cada classe com os dados de **Validação**.

Classe	Precisão	ACC	Recall	F1	MCC	ROC
Normal Beat	0.99	0.99	1.00	0.99	0.96	0.97
Supraventricular premature beat	0.91	0.99	0.82	0.86	0.86	0.91
Premature ventricular contraction	0.96	1.00	0.96	0.96	0.96	0.98
Fusion of ventricular and normal beat	0.90	1.00	0.71	0.80	0.80	0.85
Unclassifiable beat	1.00	1.00	0.99	0.99	0.99	0.99
<b>Macro average</b>	<b>0.95</b>	<b>0.99</b>	<b>0.99</b>	<b>0.92</b>	<b>0.91</b>	<b>0.94</b>
<b>Micro average</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>

Fonte: Autoria própria.

Os dados de processamento e uso de memória foram extraídos usando a ferramenta de criação de perfil do Android Studio, que fornece uso detalhado de recursos relacionados ao aplicativo. A Tabela 8 descreve o uso de memória RAM pelo modelo de classificação, o tempo de processamento necessário para avaliar uma amostra, o tamanho final do modelo e a perda de ACC devido à conversão. Um Google pixel XL foi usado com 2 GB de RAM, Android 9 (API 28) e um Quad-core, emulado.

Conforme mencionado nas seções 4.2.10, 5.2, dois métodos de quantização foram implementados: quantização de faixa dinâmica e quantização inteira de pe-

Tabela 8 – Dados de processamento e uso de memória do aplicativo CNN-Cardio.


Método de quantização	Uso de memória RAM	Tempo de processamento	Média de uso do processador	Tamanho final em MB	Perda de Acurácia
Quantização de faixa dinâmica da CNN	3.3 MB	840 milissegundos	9%	0.164 MB	0.0%
Quantização de número inteiro completo da CNN	3.4 MB	512 milissegundos	7%	0.175 MB	0.4%

Fonte: Autoria própria.


sos e ativações. O tamanho do modelo antes da seção de quantização era de 1,9 MB, após a quantização o modelo passou a ter o tamanho de 0,164 MB e 0,175 MB, essa diferença pode ser analisada na Tabela 8. Com isso é possível perceber a redução no tamanho do modelo após a quantização de aproximadamente 90% de redução no tamanho do modelo, esta redução significativa no tamanho do modelo é crucial para o desenvolvimento da aplicação móvel proposta, pois também permite uma redução no custo computacional necessário para a aplicação funcionar em um dispositivo móvel.

Figura 31 – Exemplo de classificação móvel (Classes batimento normal e fusão de batimento ventricular e normal).

(a) Classificação Móvel de Batimento Normal.



(b) Classificação Móvel Fusão de batimento ventricular e normal.




Fonte: Autoria própria.

Como pode ser visto na Figura 23 da seção 5.4.1, o conjunto de dados está desequilibrado com mais de 60% das amostras de sinal pertencentes à classe 0 (batimento normal). Para analisar a eficiência do modelo em relação à classificação de cada classe, são utilizadas as métricas de avaliação do modelo para cada classe. Nas Tabelas 6, 7, é possível analisar os resultados das métricas para cada classe.

Na Figura 32 é possível observar as matrizes de confusão da classificação CNN antes da quantização para os dados de validação e teste, com isso é possível analisar como a rede está acertando a classificação para cada classe, também é possível analisar quais as classes estão sendo classificadas de forma errada, pode-se observar que o erro de classificação é bastante baixo.

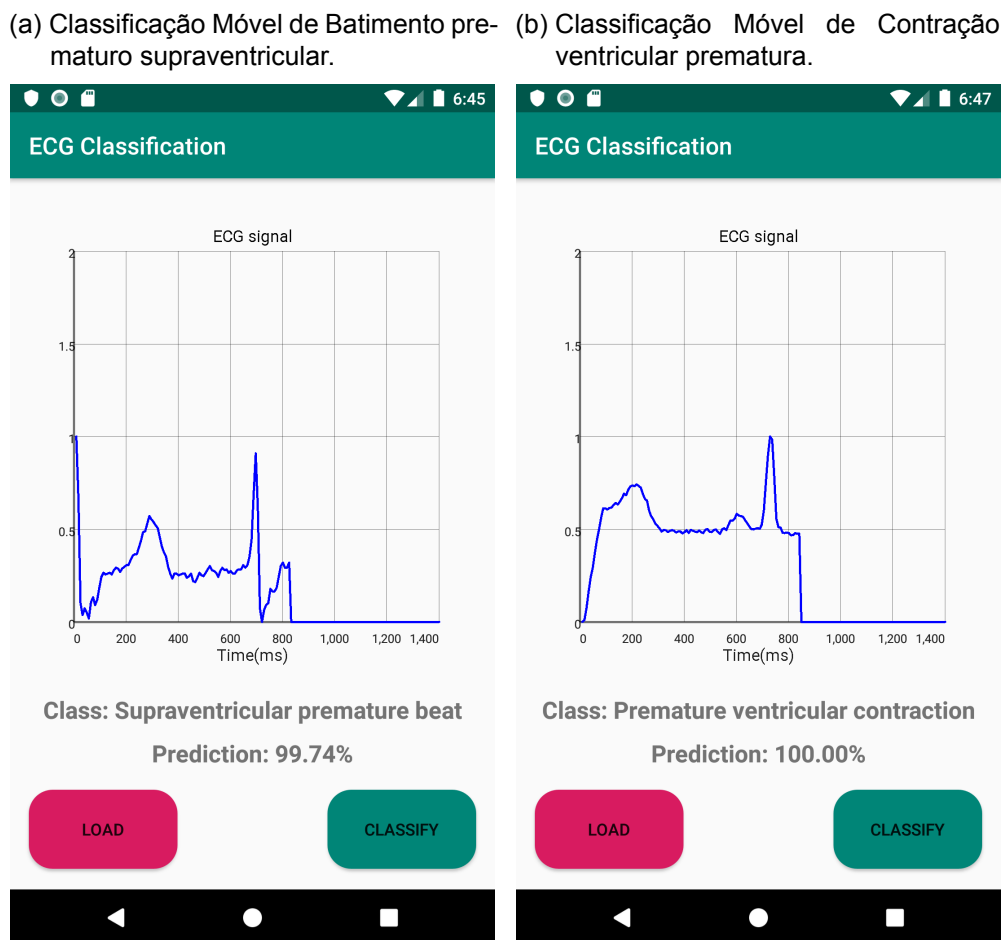
Figura 32 – Matriz de confusão da CNN antes da quantização.



Fonte: Autoria própria.

De acordo com as Figuras 31, 33, pode-se observar a interface e a tela inicial do aplicativo. No início, possui um gráfico onde será visualizado o sinal, que foi carregado pelo usuário. O eixo  $X$  do gráfico representa o momento em que o sinal analisado foi registrado. O eixo  $Y$ , por sua vez, consiste na amplitude do sinal. O aplicativo possui uma interface simples e intuitiva que funciona da seguinte forma: para carregar um sinal, o usuário deve clicar no botão *CARREGAR*, que será direcionado ao explorador de arquivos do Android, para selecionar o sinal desejado e que deve estar em texto CSV formato. Com o sinal carregado, o aplicativo está pronto para a classificação, que será dada após clicar no botão *CLASSIFICAR*. O resultado será mostrado abaixo do gráfico do sinal, que terá a classe para a qual o sinal foi classificado e abaixo terá o percentual de certeza da predição.

Figura 33 – Exemplo de classificação móvel (Classes Batimento prematuro supraventricular e Contração ventricular prematura).



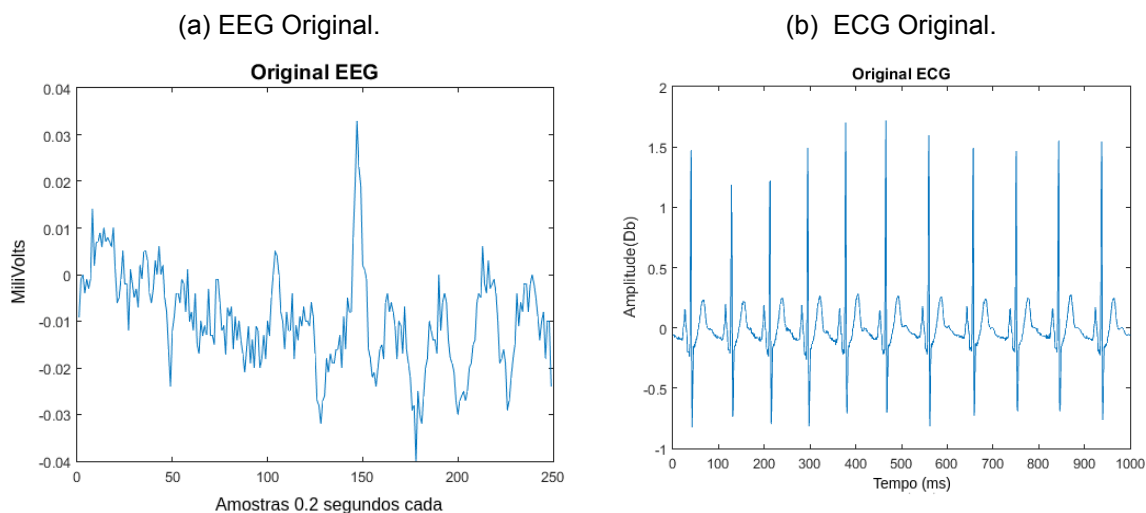
Fonte: Autoria própria.

## 6.3 RESULTADOS DA COMPRESSÃO DE SINAIS

Como explicado anteriormente na Seção 5.5 cada sinal se comporta de maneira diferente de acordo com a técnica de compressão à qual foi submetido abaixo será mostrado os resultados de todos os sinais utilizados e suas respectivas tabelas de erros e fidelidade para com o sinal original.

Na Figura 34 temos a leitura de um EEG e um ECG originais sendo as Figuras 34 (a) e 34 (b) respectivamente os sinais sem ruído adicionados ou repetidos, nos sinais originais observados existem peculiaridades que serão observadas de acordo com a transformada a qual serão submetidos.

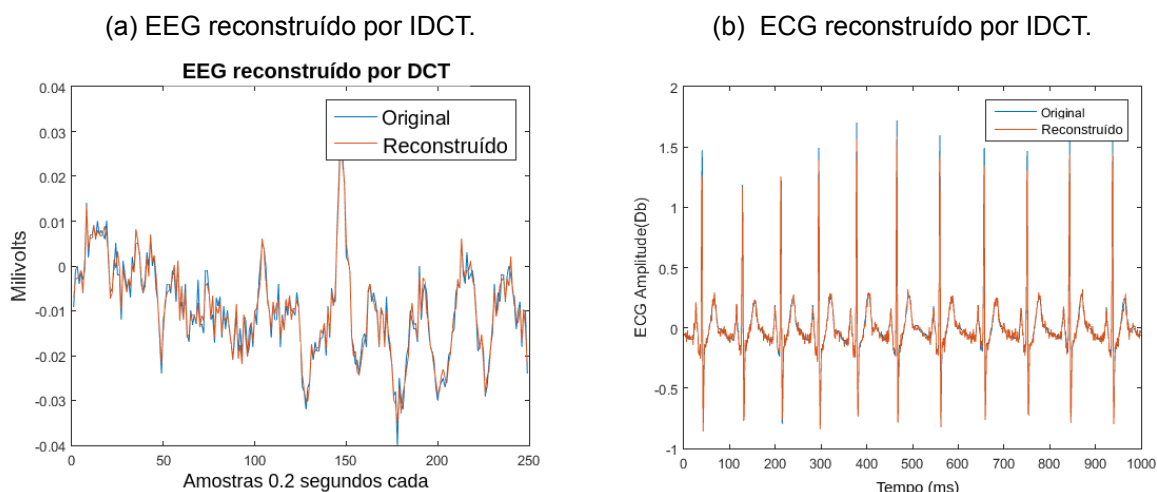
Figura 34 – EEG e ECG originais.



Fonte: Autoria própria.

A Figura 35 é mostrado os sinais ECG e EEG antes e depois da reconstrução por DCT e IDCT respectivamente, como observado na Figura 35 a diferença de comportamento entre os sinais ECG e EEG em suas reconstruções, a reconstrução do sinal ECG é mais similar ao sinal original se comparado com o reconstrução do EEG.

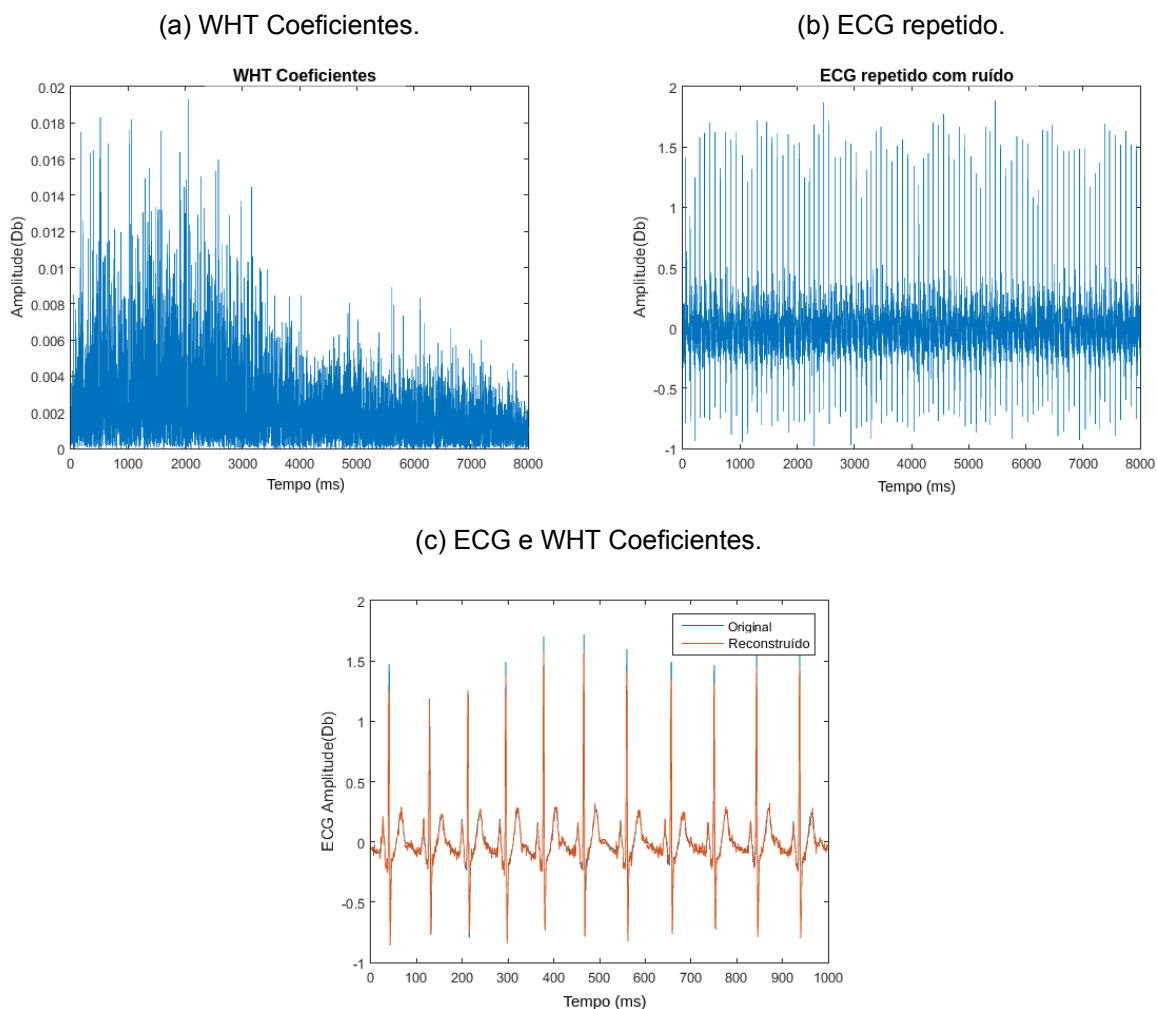
Figura 35 – Sinais reconstruídos por IDCT.



Fonte: Autoria própria.

Na Figura 36 é mostrado o processo de compressão e reconstrução por FWHT e IFWHT respectivamente na Figura 36 (a) temos os coeficientes WHT obtidos do sinal ECG que foi repetido e adicionado um ruído aleatório, como mostra as Figuras 36 (b) e 36 (c) temos o sinal obtidos seus coeficientes WHT.

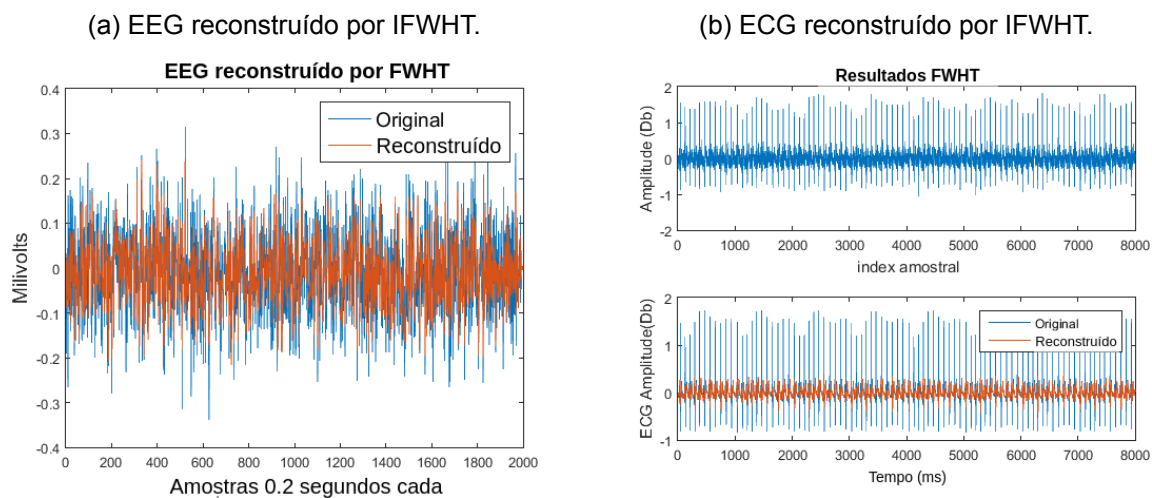
Figura 36 – Processo de compressão e reconstrução por FWHT.



Fonte: Autoria própria.

Na Figura 37 são mostrados os sinais ECG e EEG em comparação com suas versões repetidas e com ruído aleatório adicionado, nessa figura vemos que o ECG se comportou melhor pois ele obteve uma reconstrução a qual o ruído não foi recuperado como o sinal, já no caso do EEG o sinal claramente foi reconstruído com o ruído o que diminui a similaridade.

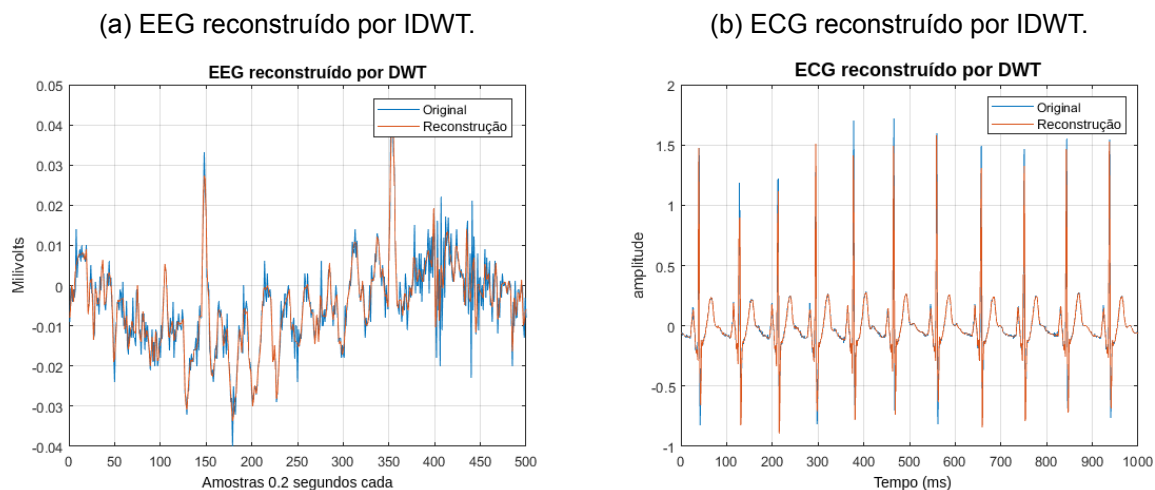
Figura 37 – Sinais reconstruídos por FWHT.



Fonte: Autoria própria.

Os sinais ECG e EEG reconstruídos por DWT e IDWT são mostrados na Figura 38 em comparação com seus sinais originais, nessa figura o EEG mostra maiores falhas quando aplicado a DCT e o ECG mostra poucas falhas porem os seus picos foram levemente prejudicados.

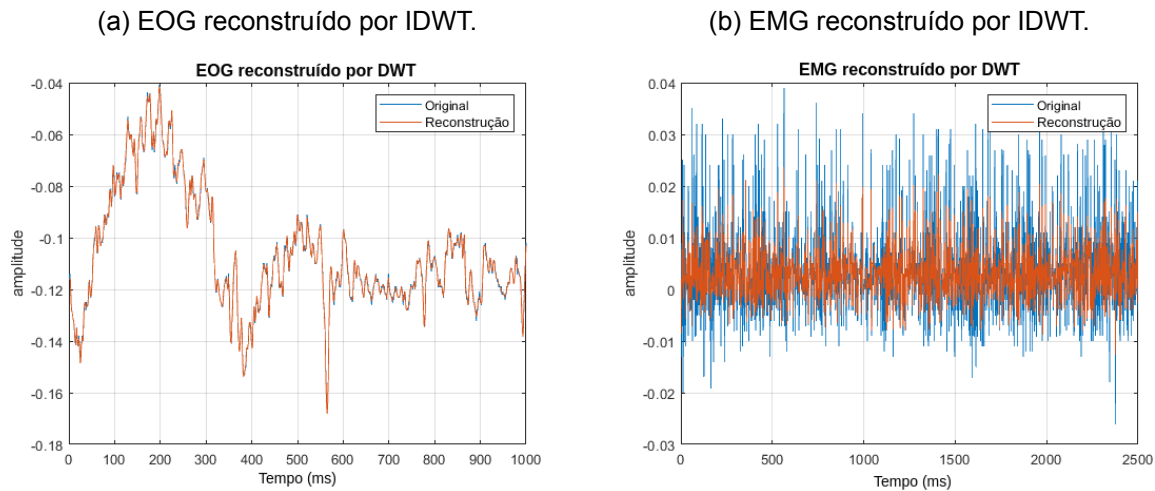
Figura 38 – Sinais reconstruídos por IDWT.



Fonte: Autoria própria.

Na Figura 39 são mostrados os resultados da compressão e reconstrução por DWT nos sinais EOG e EMG, é possível que o EOG se comporta melhor com a DWT do que o EMG, de acordo com as imagens, a similaridade do EOG é excelente já o EMG tem um estado completamente diferente com várias partes de seu sinal prejudicadas.

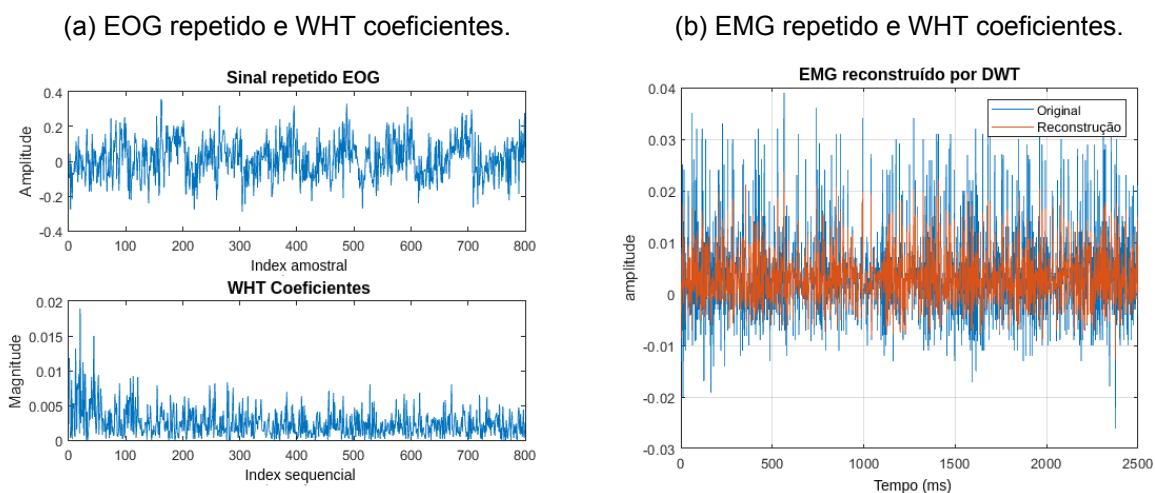
Figura 39 – Sinais reconstruídos por IDWT.



Fonte: Autoria própria.

Na Figura 40 é mostrado o processo de compressão e reconstrução por FWHT e IFWHT respectivamente na Figura 40 (a) temos os coeficientes WHT obtidos dos sinais EOG e EMG que foram repetido e um ruído aleatório foi adicionado como mostram as Figuras 40 (a) e (b) nas quais temos os sinais obtidos seus coeficientes WHT.

Figura 40 – Processo de compressão e reconstrução por FWHT.

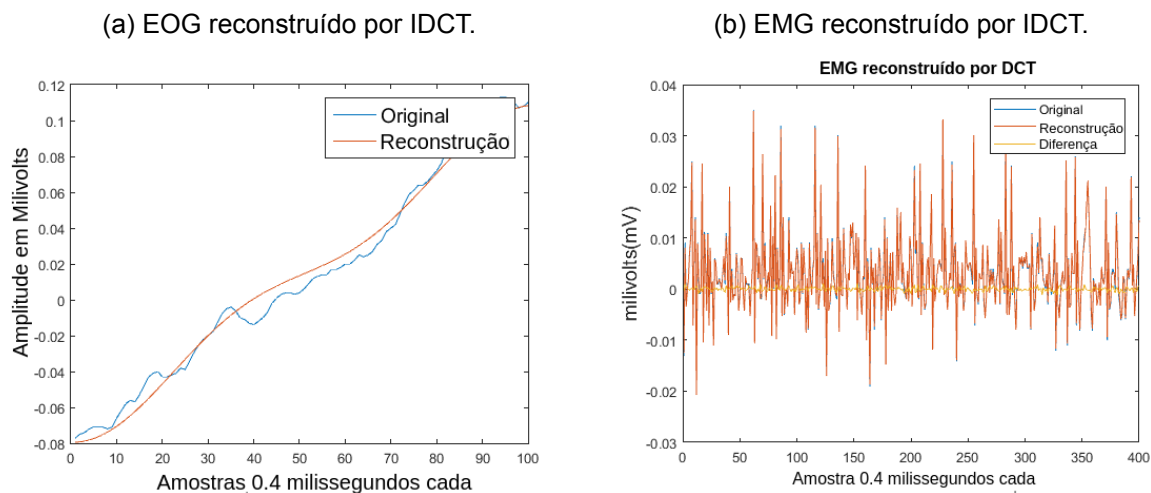


Fonte: Autoria própria.

Na Figura 41 os sinais EOG e EMG reconstruídos por DCT e IDCT são mostrados em comparação com seus sinais originais, nota-se que o EOG não se comporta bem com a DCT ao contrário do EMG que teve uma ótima reconstrução com a DCT,

além disso a reconstrução do EMG teve os picos completamente restaurados como pode-se ver na Figura 41 (b).

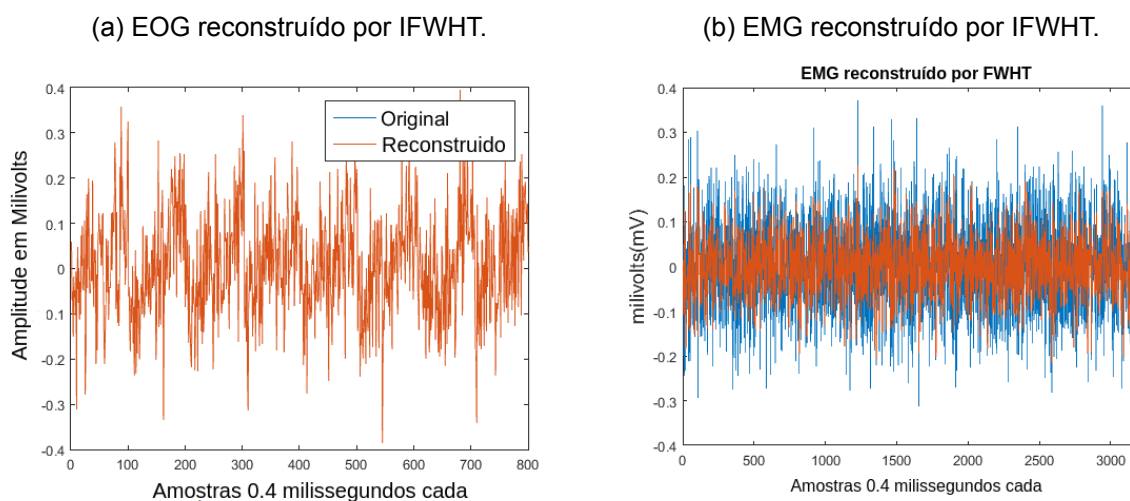
Figura 41 – Sinais reconstruídos por IDCT.



Fonte: Autoria própria.

Na Figura 42 trata-se dos sinais EMG e EOG reconstruídos por IFWHT em comparação com seus sinais repetidos e com ruído aleatório adicionados ao EOG nesse caso teve uma ótima reconstrução ao contrário do EMG como observado na figura os picos do EOG foram restaurados enquanto os do EMG tem falhas o que atrapalha na similaridade entre os sinais.

Figura 42 – Sinais reconstruídos por IFWHT.




Fonte: Autoria própria.

Os sinais EOG e EMG reconstruídos por DWT e IDWT são mostrados na

43 em comparação com seus sinais originais, nesse caso ambos os sinais se comportam bem, o EOG teve uma reconstrução quase perfeita enquanto o EMG teve uma boa reconstrução embora haja uma perda nos picos, o sinal original se assemelha ao reconstruído sem que o reconstruído tenha sido recuperado com o ruído que foi adicionado.

Figura 43 – Sinais reconstruídos por IDWT.



Fonte: Autoria própria.

Na Tabela 9 tem-se os resultados dos métodos estatísticos mencionados na seção 5.5.1 que indicam a similaridade e a taxa de erros do sinal EEG, quando os mesmos são comparados com seus sinais originais, nesse caso, temos o sinal EEG após ser comprimido e reconstruído por todas as transformadas usadas, observamos uma taxa de similaridade grande tendo como base o SNR de 17.0 e um erro absoluto baixo, o MAE teve resultado de 0.001, o que mostra que o sinal se comportou bem à transformada DCT. Com relação aos sinal EEG reconstruído com FWHT, o mesmo não se comportou bem obtendo uma taxa de similaridade bem baixa quando comparada ao sinal original com um SNR de apenas 3.38 e um erro Absoluto de 0.05.

Também é possível analisar na Tabela 9 os resultados do sinal EEG quando aplicado à transformada DWT, mostrando uma boa similaridade com um SNR de 10.0 e erros baixos de 0.002 no MAE e de 0.00001 no MSE porém quando comparados com os resultados obtidos na DCT com o mesmo sinal a similaridade deixa a desejar, o sinal se comporta bem com a DWT porém a DCT obteve melhores resultados quando aplicada no EEG.

Tabela 9 – Resultados das métricas para as técnicas de compressão no sinal **EEG**.

Transformada	PSNR	SNR	MAE	MSE
DCT	24.397133	17.035322	0.001603	0.000004
FWHT	13.351736	3.380488	0.053888	0.004512
DWT	21.695940	10.090911	0.002685	0.000014

Na Tabela 10 temos os resultados dos métodos estatísticos das transformadas aplicados no sinal EOG, com isso é possível perceber que os resultados PSNR de 24.8 usado a DCT que indica uma similaridade excelente e um MSE de 0.00004 que indica uma taxa de erro baixa, isso significa um bom comportamento do sinal com a transformada DCT. Quando aplicado a FWHT no sinal EOG, o PSNR obteve o resultado de 13.9 que indica pouca similaridade, e MAE foi de 0.07 bem maior quando comparado com a DCT. Aplicando a técnica de compressão DWT, temos uma taxa de similaridade excelente, pois o PSNR teve um resultado de 35.5 o que indica uma similaridade bem maior quando comparado com as outras duas transformadas, o que indica um sinal quase perfeito quando comparado ao original.

Tabela 10 – Resultados das métricas para as técnicas de compressão no sinal **EOG**.

Transformada	PSNR	SNR	MAE	MSE
DCT	24.876553	19.1117	0.005583	0.000043
FWHT	13.90701	-4.374118	0.078406	0.009601
DWT	35.542825	44.000589	0.000531	0.000000

Na Tabela 11 são mostrados os resultados estatísticos de erro e similaridade do sinal EMG após passar pelas transformadas, o sinal se comportou bem com um PSNR de 39.2 a similaridade é bem alta e um MSE menor que 0.00000 com a aplicação da DCT, o que indica uma taxa de erros muito baixa. Usando a FWHT o sinal se comportou bem, com PSNR de 25.7 mostrou uma boa similaridade porém mesmo com sua compressão sendo maior a DCT ainda teve um resultado melhor que a FWHT. Aplicando a DWT por sua vez o sinal não se comportou bem, com similaridade pior que a FWHT com um PSNR de 16.2 que é uma diferença notável quando comparado ao resultado de 39.2 da DCT.

Tabela 11 – Resultados das métricas para as técnicas de compressão no sinal **EMG**.

Transformada	PSNR	SNR	MAE	MSE
DCT	39.214499	27.158767	0.000299	0.000000
FWHT	25.723057	17.778790	0.052583	0.004576
DWT	16.201291	2.831526	0.004285	0.000036

Na Tabela 12 são mostrados os resultados estatísticos de erro e similaridade entre os sinais ECG reconstruídos e originais quando aplicado as transformadas.

Na compressão de sinais do ECG, a técnica de FWHT obteve vantagem com relação as demais técnicas avaliadas neste trabalho. O sinal reconstruído utilizando o FWHT aproxima-se do sinal original e sua compressão é muito mais eficiente. Já na compressão de sinais EEG tendo como base o PSNR, o DWT resultou em 21.6, Tabela 9, enquanto o DCT teve 24,3, Tabela 9, uma diferença notável. O DCT provou ser eficaz com uma reconstrução muito precisa do EOG comprimido, além da necessidade de repetição do sinal.

Tomando como exemplo os dados de ECG analisados, o FWHT obteve vantagem porque o sinal reconstruído se aproximou do sinal original e sua compressão foi muito mais eficiente. Usando o PSNR como exemplo, o FWHT resultou em 24.7, enquanto o DCT teve 25.2, uma diferença desprezível, Tabela 12. Esses e mais resultados estatísticos podem ser observados nas tabelas, comprovando com as estatísticas que diferentes transformações funcionam de maneira diferente em cada tipo de sinal biomédico.

Tabela 12 – Resultados das métricas para as técnicas de compressão no sinal **ECG**.

<b>Transformada</b>	<b>PSNR</b>	<b>SNR</b>	<b>MAE</b>	<b>MSE</b>
DCT	25.188	8.660	0.755	0.008
FWHT	24.667	8.091	0.080	0.010
DWT	27.199	10.623	0.024	0.005

## 7 DISCUSSÃO

Neste capítulo de discussão são interpretados os resultados com relação as principais questões iniciais desta pesquisa tratados na introdução e estabelecido a explicação com base nos resultados constatados no capítulo anterior.

Os desafios citados no capítulo de introdução são respondidos nessa seção, primeiramente, foram elaboradas quatro questões de pesquisa, descritas a seguir, para facilitar a compreensão das metodologias adotadas e dos resultados obtidos.

- **Q1:** Quais são os desafios de automatizar a exploração de dados com modelos de classificação para implantação em dispositivos móveis?
  - De acordo com (WU et al., 2016), muitas vezes é um desafio executar redes neurais em dispositivos móveis e embarcados, pois tais modelos necessitam de um grande poder computacional, que na maioria das vezes não são encontrados nestes dispositivos.
  - Para resolver esse problema foram implementados e analisados dois métodos de quantização de modelos pós-treinamento, esses métodos visam diminuir o custo computacional de forma significativa, para que assim esses modelos possam ser executados em dispositivos móveis.
  - De acordo com os resultados demonstrados nas seções 6.1, 6.2, os métodos de quantização utilizados se mostraram eficientes, obtendo uma redução significativa com pouca perda de precisão dos modelos, isso pode ser analisado nas Tabelas 5, 8.
- **Q2:** Quais os modelos de classificação são mais adequados para analisar imagens de CXR e sinal de ECG em dispositivos móveis Android?
  - Isso é uma questão de projeto, pois depende muito de quais aspectos são importantes para a aplicação final, na resposta da questão Q1 foram apresentadas três características a serem avaliadas em cada modelo que podem ser otimizadas.
  - Para as aplicações móveis apresentadas neste trabalho, foram usados modelos conhecidos como CNNs, os mesmos se mostraram eficientes para a tarefa de classificação, tanto de ECG como também CXR, de acordo com os resultados demonstrados, porém um comparativo de quais modelos são mais adequados para essas tarefas até o presente momento não existe na literatura.

- **Q3:** Quais são os impactos na precisão de resultados das análises das imagens e sinais e que a redução foi alcançada com os modelos de CNN?
  - Foram analisados dois métodos de quantização usados para a redução do custo computacional das aplicações móveis, como podem ser analisados nas Tabelas 5, 8. O método de quantização dinâmica não obteve uma redução significativa de desempenho, com um percentual de 0% de perda na precisão. Já o método de quantização total de pesos e ativações também obteve uma redução de custo computacional, porém esse método apresenta uma média de perda de acurácia de 0.4%.
  
- **Q4:** Qual a estratégia de compressão de sinais possibilita o melhor armazenamento das informações em base de dados e transmissão do ECG em dispositivos móveis Android?
  - De acordo com os experimentos realizados neste trabalho, para a compressão de sinais do ECG, a técnica de FWHT obteve vantagem com relação as demais técnicas avaliadas. O sinal reconstruído utilizando o FWHT aproxima-se do sinal original e sua compressão é muito mais eficiente, isso pode ser analisado nas Tabela 12.

Abaixo serão discutidos os resultados obtidos com os modelos implementados para a análise de dados biomédicos, também é realizado um comparativo com outros trabalhos recentes da literatura, dessa forma é demonstrada as principais contribuições realizadas pelo presente trabalho.

Os resultados da avaliação no capítulo anterior demonstraram que as aplicações dos modelos propostos tiveram bons desempenhos com relação aos objetivos deste trabalho. A aplicação proposta de aprendizado profundo CNN-Pulmona pode ser utilizada na classificação de imagens de Raio-X em vários estágios de forma precisa e otimizada, conforme ilustrado na Figura 30. Já a aplicação de aprendizado profundo CNN-Cardio, pode identificar diferentes arritmias de forma rápida e precisa, Figuras 31, 33. Todas essas aplicações podem ser usadas sem necessidade de uma conexão com a internet, podendo ser executadas em um dispositivo Android, facilitando assim o uso das mesmas.

A tarefa de classificação de imagens de Raio-X mostra-se uma tarefa desafiadora, com isso muitos estudos anteriores propuseram modelos de aprendizagem profunda eficazes para realizar esta tarefa crucial usando conjuntos de dados de imagens, (LUJÁN-GARCÍA et al., 2020), (KARAR, 2020), (MAHMUD, 2020), mas não sugeriram uma opção prática final para a supervisão médica de acordo com seu ambiente clínico. Neste trabalho é proposto um app CNN-Cardio, uma aplicação final capaz de ser usadas por médicos como um sistema auxiliador de diagnóstico, conforme mostrado nas

Figura 30. Esse sistema pode ser facilmente treinado novamente em um novo conjunto de dados de imagens, adicionando ou selecionando outros modelos de aprendizado profundo em cascata, para identificar com precisão infecções por COVID-19 e doenças pulmonares em imagens de Raios-X de tórax.

Em (KACHUEE; FAZELI; SARRAFZADEH, 2018), é proposto um método usando CNN para classificação da frequência cardíaca, este estudo teve uma acurácia média de 93,4% na classificação das arritmias. Além disso, sugere-se um método de transferência do aprendizado adquirido para a tarefa de classificação do infarto do miocárdio. Em (ACHARYA et al., 2017b), uma CNN de 9 camadas é desenvolvida para identificar automaticamente 5 categorias diferentes de batimentos cardíacos de ECG, com uma precisão de 93,5%. Nas Tabelas 6 e 7, é possível verificar que o desempenho do método proposto pelo presente trabalho supera a precisão da classificação de (KACHUEE; FAZELI; SARRAFZADEH, 2018) e (ACHARYA et al., 2017b). Vale ressaltar também que ambos os trabalhos comparativos não implementam uma aplicação final para as CNNs propostas. Já este trabalho desenvolve um aplicativo móvel para auxiliar no diagnóstico de diferentes arritmias.

Nas Tabelas 13, 14 é possível analisar comparações com alguns trabalhos relevantes da literatura, onde foi realizado classificações de dados biomédicos semelhantes aos usados neste trabalho. Com isso é possível notar na Tabela 13 que (KARAR, 2020) obteve um desempenhos de 99% na classificação de imagens de CXR (Covid-19 x Normal, Pneumonia Viral, Pneumonia Bacteriana), porém também é possível notar que a quantidade imagens usadas é muito pequena se comparado com a usada nesta Tese. Com isso existe um grande indicativo que os resultados de (KARAR, 2020) são resultados inconsistentes, onde o modelo usado deve ter tido um *Overfitting* aprendendo muito bem apenas os poucos dados usados, como os modelos usados por (KARAR, 2020) não foram submetidos a teste com outros conjuntos de dados não é possível saber a real precisão desses modelos. Já na Tabela 14 é possível analisar os trabalhos que realizaram a classificação de sinal ECG usando a mesma base de dados usada nesta tese, existem bons resultados na literatura como pode ser observado, porém esses trabalhos não apresentam um aplicação final para os modelos de classificação de ECG.

Tabela 13 – Trabalhos relacionados que realizaram a classificação de imagens de Raio-X.

Autor	Ano	Técnica e Classificação	Classes e quantidade de imagens	Acurácia (%)
(KARAR, 2020)	2020	Covid-19 x (Normal, Pneumonia Viral, Pneumonia Bacteriana)	- Normal - 79 - Pneumonia Covid-19 - 69 - Pneumonia Bacteriana - 79 - Pneumonia Viral - 79	99.90%
(KARAR, 2020)	2020	Pneumonia Viral x (Normal, Pneumonia Bacteriana)	- Normal - 79 - Pneumonia Bacteriana - 79 - Pneumonia Viral - 79	99.90%
(KARAR, 2020)	2020	Pneumonia Bacteriana x Normal	- Normal - 79 - Pneumonia Bacteriana - 79	99.90%
(MAHMUD, 2020)	2020	Coronet (Covid-19 x Pneumonia Viral x Normal x Pneumonia Bacteriana)	- Normal - 310 - Pneumonia Covid-19 - 284 - Pneumonia Bacteriana - 330 - Pneumonia Viral - 327	89.60%
(KHAN, 2020)	2020	CovXNet (Pneumonia por Covid-19 x Pneumonia por outros Vírus)	- Pneumonia Bacteriana - 305 - Pneumonia Viral - 305	87.30%
Método Proposto	2020	MobileNet-otimizada (Normal x Pneumonia)	- Normal - 2.917 - Pneumonia Covid-19 - 1.160 - Pneumonia Bacteriana - 2.742 - Pneumonia Viral - 2.834	98%
Método Proposto	2020	MobileNet-otimizada (Pneumonia Viral x Pneumonia Bacteriana)	- Pneumonia Covid-19 - 1.160 - Pneumonia Bacteriana - 2.742 - Pneumonia Viral - 2.834	85.47%
Método Proposto	2020	MobileNet-otimizada (Pneumonia por Covid-19 x Pneumonia por outros Vírus)	- Pneumonia Covid-19 - 1.160 - Pneumonia Viral - 2.834	99.16%

Tabela 14 – Trabalhos relacionados que realizaram a classificação com o mesmo conjunto de dados (MIT-BIH).

Autor	Ano	Técnica	Performance (Acurácia)
(MARTIS et al., 2012)	2012	LS-SVM with RBF kernel	98.11%
(MARTIS et al., 2013)	2013	NN	94.52%
(ZHANG; LUO, 2014)	2014	Combined SVM	87.88%
(HUANG et al., 2014)	2014	Ensemble of SVM	93.90%
(ELHAJ et al., 2016)	2016	SVM-RBF	98.91%
		NN	98.90%
(ACHARYA et al., 2017b)	2017	CNN	94.03%
(YANG et al., 2018b)	2018	Linear SVM	97.94%
(OH et al., 2018)	2018	CNN-LSTM	98.10%
(PANDEY; JANGHEL, 2019)	2019	CNN	98.30%
Método Proposto	2020	CNN-otimizada	98.69%

## 8 CONCLUSÃO

Este trabalho demonstrou o uso de modelos computacionais para a otimização de análise de dados biomédicos, em que se mostraram capazes de minimizar os problemas dos cenários apresentados; com isso, conclui-se que o aplicativo móvel CNN-Pneumonia é capaz de classificar imagens de CXR em diferentes estágios (Normal, Pneumonia Bacterina, Pneumonia por Covid-19, Pneumonia por outros vírus). O método de classificação em cascata possibilitou a divisão das classificações em diferentes estágios; dessa forma, foi possível obter 99,16% de precisão na classificação de imagens com suspeita de Covid-19. Com o processo de quantização, foi possível obter uma redução significativa no custo computacional das CNNs, possibilitando executar com eficiência o processo de classificação em um dispositivo móvel. No CNN-Cardio, implementou-se uma CNN que se mostrou eficiente para validação dos resultados. Além disso, propôs-se uma aplicação móvel capaz de classificar 5 tipos diferentes de batimentos cardíacos, sendo a primeira classe normal, não classificável, e as demais são arritmias. Este método produziu resultados satisfatórios, com mais de 99% de média de precisão.

Em uma comparação direta entre as transformadas analisadas, comprovou-se que o comportamento dos sinais é diferente para cada tipo de transformada, comprovando estatisticamente que transformadas diferentes funcionam de forma diferente em cada tipo de sinal biomédico, tomando-se como exemplo os dados de ECG analisados; o FWHT obtido apresentou vantagem em relação às outras transformadas, pois o sinal reconstruído se mostrou bastante semelhante ao sinal original e sua compressão foi muito mais eficiente. Analisando os resultados das compressões, observa-se que, a diferença do sinal reconstruído para o sinal original é bastante pequena, a ponto de ser considerada desprezível. Por exemplo, com a métrica PSNR avaliando a compressão do sinal ECG, o DCT obteve o resultado de 25,18, o FWHT obteve 24,66 e o DWT obteve 27,19; com isso, podemos concluir que diferença entre o sinal reconstruído e o sinal original é muito pequena.

O método DCT provou ser eficaz, com uma reconstrução muito precisa do EOG comprimido. Conforme foi demonstrado, o gráfico do DCT é relativamente próximo ao do EOG original, tomando-se como exemplo os erros, que foram mais baixos em comparação com o FWHT. Os resultados estatísticos podem ser observados nas tabelas, comprovando que diferentes transformadas atuam de maneira diferente em cada tipo de sinal biomédico. Tendo em vista os resultados obtidos, observa-se que as técnicas de compressão discutidas têm particularidades distintas.

Conforme mencionado anteriormente, as aplicações apresentadas neste trabalho obtiveram bons resultados, alcançado os objetivos propostos. Nos aplicativos CNN-Pumona e CNN-Cardio, foi demonstrada a viabilidade do uso desses em dispositivos móveis com poucos recursos computacionais. Dessa forma, as pesquisas apresentadas nesta Tese representam contribuições originais para a Área de Engenharia Biomédica, experimentalmente comprovadas por meio de implementações computacionais compatíveis com dispositivos móveis. Uma das limitações desta Tese está relacionada com a realização de testes em ambientes clínicos com a supervisão de profissionais especializados; entretanto, esses testes estão previstos para serem realizados em breve, bem como foram inseridos como sugestão de trabalhos futuros. Também como trabalhos futuros, pretende-se implementar a funcionalidade de enviar a base de dados de ECG no aplicativo CNN-Cardio, utilizando as técnicas de compressão de sinais apresentada pelo presente trabalho.

# REFERÊNCIAS

- ABADI, M. et al. Tensorflow: A system for large-scale machine learning. In: *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)*. Savannah, GA: USENIX Association, 2016. p. 265–283. ISBN 978-1-931971-33-1. Disponível em: <<https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>>.
- ACHARYA, U. R. et al. Application of deep convolutional neural network for automated detection of myocardial infarction using ecg signals. *Information Sciences*, Elsevier, v. 415, p. 190–198, 2017.
- ACHARYA, U. R. et al. A deep convolutional neural network model to classify heartbeats. *Computers in biology and medicine*, Elsevier, v. 89, p. 389–396, 2017.
- ALFAOURI, M.; DAQROUQ, K. Ecg signal denoising by wavelet transform thresholding. *American Journal of applied sciences*, v. 5, n. 3, p. 276–281, 2008.
- ANDRADE, D. C. et al. Infecção por streptococcus pneumoniae em crianças com ou sem pneumonia radiologicamente confirmada. *Jornal de Pediatria*, SciELO Brasil, v. 94, n. 1, p. 23–30, 2018.
- APOSTOLOPOULOS, I. D.; MPESIANA, T. A. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, Springer, p. 1, 2020.
- APPATHURAI, A. et al. A study on ecg signal characterization and practical implementation of some ecg characterization techniques. *Measurement*, Elsevier, v. 147, p. 106384, 2019.
- ARAUJO-FILHO, J. d. A. B. et al. COVID-19 pneumonia: what is the role of imaging in diagnosis? *Jornal Brasileiro de Pneumologia*, scielo, v. 46, 00 2020. ISSN 1806-3713. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1806-37132020000201003&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-37132020000201003&nrm=iso)>.
- AYODELE, T. O. Types of machine learning algorithms. In: ZHANG, Y. (Ed.). *New Advances in Machine Learning*. Rijeka: IntechOpen, 2010. cap. 3. Disponível em: <<https://doi.org/10.5772/9385>>.
- BALOGLU, U. B. et al. Classification of myocardial infarction with multi-lead ecg signals and deep cnn. *Pattern Recognition Letters*, Elsevier, v. 122, p. 23–30, 2019.
- BANASCHEWSKI, B.; HOFMANN, T. Inhaled antibiotics for mycobacterial lung disease. *Pharmaceutics*, Multidisciplinary Digital Publishing Institute, v. 11, n. 7, p. 352, 2019.
- BÖHM, S.; SCHREIBER, S. *Mobile App Marketing: A Conjoint-based Analysis on the Importance of App Store Elements*. Nice, France: Citeseer, 2014.

BORIANI, G. et al. Evaluation of fusion beat detection with a new ventricular automatic capture algorithm in icds. *Pacing and clinical electrophysiology*, Wiley Online Library, v. 28, p. S263–S266, 2005.

BOTTOU, L.; CURTIS, F. E.; NOCEDAL, J. Optimization methods for large-scale machine learning. *Siam Review*, SIAM, v. 60, n. 2, p. 223–311, 2018.

BOWERS, A. J.; ZHOU, X. Receiver operating characteristic (roc) area under the curve (auc): A diagnostic measure for evaluating the accuracy of predictors of education outcomes. *Journal of Education for Students Placed at Risk (JESPAR)*, Taylor & Francis, v. 24, n. 1, p. 20–46, 2019.

BRAMBILA, A. P. *Detecção automática de fibrilação atrial através de modelos Markovianos*. Tese (Doutorado) — Universidade de São Paulo, 2008.

BRENTANO, V. B. et al. Interpretando a radiografia de tórax na emergência. *Acta méd.(Porto Alegre)*, p. 8–8, 2014.

BROWN, M. et al. Iscev standard for clinical electro-oculography (eog) 2006. *Documenta ophthalmologica*, Springer, v. 113, n. 3, p. 205–212, 2006.

BRUNO, D. et al. *Learning model for fraud detection in credit cards*. 2018.

CARRATALA, J. et al. Risk factors for nosocomial legionella pneumophila pneumonia. *American journal of respiratory and critical care medicine*, American Public Health Association, v. 149, n. 3, p. 625–629, 1994.

CASALI, F. X-ray digital radiography and computed tomography for cultural heritage. *Archeometriai Muhely*, p. 24–28, 2006.

CHA, Y.-M. et al. Premature ventricular contraction-induced cardiomyopathy: a treatable condition. *Circulation: Arrhythmia and Electrophysiology*, Am Heart Assoc, v. 5, n. 1, p. 229–236, 2012.

CHEN, Y.-H. et al. Eyeriss: An energy-efficient reconfigurable accelerator for deep convolutional neural networks. *IEEE Journal of Solid-State Circuits*, IEEE, v. 52, n. 1, p. 127–138, 2017.

CHOWDHURY, M. E. et al. Can ai help in screening viral and covid-19 pneumonia? *arXiv preprint arXiv:2003.13145*, 2020.

COHEN, J. P.; MORRISON, P.; DAO, L. Covid-19 image data collection. *arXiv 2003.11597*, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>.

COHEN, J. P. et al. Covid-19 image data collection: Prospective predictions are the future. *arXiv 2006.11988*, 2020. Disponível em: <<https://github.com/ieee8023/covid-chestxray-dataset>>.

CONOVER, M. B. *Understanding electrocardiography*. Santa Cruz, California: Elsevier Health Sciences, 2002.

CUNHA, B. A. Cytomegalovirus pneumonia: community-acquired pneumonia in immunocompetent hosts. *Infectious disease clinics of North America*, Elsevier, v. 24, n. 1, p. 147, 2010.

- DANIELE, O. et al. Stroke and cardiac arrhythmias. *Journal of Stroke and Cerebrovascular Diseases*, Elsevier, v. 11, n. 1, p. 28–33, 2002.
- DAS, H.; NAIK, B.; BEHERA, H. S. An experimental analysis of machine learning classification algorithms on biomedical data. In: KUNDU, S. et al. (Ed.). *Proceedings of the 2nd International Conference on Communication, Devices and Computing*. Singapore: Springer Singapore, 2020. p. 525–539. ISBN 978-981-15-0829-5.
- DAXBOECK, F.; KRAUSE, R.; WENISCH, C. Laboratory diagnosis of mycoplasma pneumoniae infection. *Clinical Microbiology and Infection*, Elsevier, v. 9, n. 4, p. 263–273, 2003.
- DEY, N. et al. Developing residential wireless sensor networks for ecg healthcare monitoring. *IEEE Transactions on Consumer Electronics*, IEEE, v. 63, n. 4, p. 442–449, 2017.
- DOKE, P. et al. Using cnn with bayesian optimization to identify cerebral micro-bleeds. *Mach. Vis. Appl.*, Springer, v. 31, n. 5, p. 36, 2020.
- DOWD, F. J. Arrhythmias. In: ENNA, S.; BYLUND, D. B. (Ed.). *xPharm: The Comprehensive Pharmacology Reference*. New York: Elsevier, 2007. p. 1. ISBN 978-0-08-055232-3. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B978008055232360618X>>.
- EBERHART, R. C.; DOBBINS, R. W. Introduction. In: EBERHART, R. C.; DOBBINS, R. W. (Ed.). *Neural Network PC Tools*. San Diego: Academic Press, 1990. p. 1 – 8. ISBN 978-0-12-228640-7. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9780122286407500064>>.
- ELHAJ, F. A. et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ecg signals. *Computer methods and programs in biomedicine*, Elsevier, v. 127, p. 52–63, 2016.
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, Nature Publishing Group, v. 542, n. 7639, p. 115, 2017.
- FARIAS, L. d. P. A. G. d. et al. Imaging findings in COVID-19 pneumonia. *Clinics*, scielo, v. 75, 00 2020. ISSN 1807-5932. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1807-59322020000100417&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1807-59322020000100417&nrm=iso)>.
- FENG, N. et al. A probabilistic process neural network and its application in ecg classification. *IEEE Access*, IEEE, v. 7, p. 50431–50439, 2019.
- FIGUEIREDO, L. T. M. Pneumonias virais: aspectos epidemiológicos, clínicos, fisiopatológicos e tratamento. *Jornal Brasileiro de pneumologia*, SciELO Brasil, v. 35, n. 9, p. 899–906, 2009.
- FIGUEIREDO, L. T. M. Viral pneumonia: epidemiological, clinical, pathophysiological and therapeutic aspects. *Jornal Brasileiro de Pneumologia*, Citeseer, v. 35, n. 9, 2009.
- FRID-ADAR, M. et al. Gan-based synthetic medical image augmentation for increased cnn performance in liver lesion classification. *Neurocomputing*, Elsevier, v. 321, p. 321–331, 2018.

- FURLANELLO, F. et al. Illicit drugs and cardiac arrhythmias in athletes. *European Journal of Cardiovascular Prevention & Rehabilitation*, SAGE Publications Sage UK: London, England, v. 14, n. 4, p. 487–494, 2007.
- GAO, T.; WANG, G. Chest x-ray image analysis and classification for covid-19 pneumonia detection using deep cnn. *medRxiv*, Cold Spring Harbor Laboratory Press, 2020.
- GARG, M. et al. Spectrum of imaging findings in pulmonary infections. part 1: Bacterial and viral. *Polish Journal of Radiology*, v. 84, p. 205–213, 2019. ISSN 1899-0967. Disponível em: <<http://dx.doi.org/10.5114/pjr.2019.85812>>.
- GIANFRANCHI, L. et al. Fusion beat in patients with heart failure treated with left ventricular pacing: may ecg morphology relate to mechanical synchrony? a pilot study. *Cardiovascular Ultrasound*, BioMed Central, v. 6, n. 1, p. 1–9, 2008.
- GOLDBERGER, A. L. et al. Physiobank, physiokit, and physionet: components of a new research resource for complex physiologic signals. *Circulation*, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000.
- HAKIM, F.; TLEYJEH, I. Severe adenovirus pneumonia in immunocompetent adults: a case report and review of the literature. *European Journal of Clinical Microbiology & Infectious Diseases*, Springer, v. 27, n. 2, p. 153–158, 2008.
- HARRINGTON, P. *Machine Learning in Action*. USA: Manning Publications Co., 2012. ISBN 1617290181.
- HEIDARI, M. et al. Improving the performance of cnn to predict the likelihood of covid-19 using chest x-ray images with preprocessing algorithms. *International Journal of Medical Informatics*, Elsevier, p. 104284, 2020.
- HUANG, C. et al. Clinical features of patients infected with 2019 novel coronavirus in wuhan, china. *The lancet*, Elsevier, v. 395, n. 10223, p. 497–506, 2020.
- HUANG, H. et al. A new hierarchical method for inter-patient heartbeat classification using random projections and rr intervals. *Biomedical engineering online*, Springer, v. 13, n. 1, p. 90, 2014.
- HUANG, P. et al. Use of chest ct in combination with negative rt-pcr assay for the 2019 novel coronavirus but high clinical suspicion. *Radiology*, Radiological Society of North America, v. 295, n. 1, p. 22–23, 2020.
- HUBARA, I. et al. Quantized neural networks: Training neural networks with low precision weights and activations. *The Journal of Machine Learning Research*, JMLR. org, v. 18, n. 1, p. 6869–6898, 2017.
- INSTRUMENTATION, A. for the Advancement of M. et al. Testing and reporting performance results of cardiac rhythm and st segment measurement algorithms. *ANSI/AAMI EC38*, v. 1998, 1998.
- ISLAM, M. Z.; ISLAM, M. M.; ASRAF, A. A combined deep cnn-lstm network for the detection of novel coronavirus (covid-19) using x-ray images. *Informatics in Medicine Unlocked*, Elsevier, v. 20, p. 100412, 2020.

IZARD, S. G. et al. Applications of virtual and augmented reality in biomedical imaging. *Journal of medical systems*, Springer, v. 43, n. 4, p. 102, 2019.

JACOB, B. et al. Quantization and training of neural networks for efficient integer-arithmetic-only inference. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Los Alamitos, CA, USA: IEEE Computer Society, 2018. p. 2704–2713. Disponível em: <<https://doi.ieeecomputersociety.org/10.1109/CVPR.2018.00286>>.

JAFRI, H. S. et al. Respiratory syncytial virus induces pneumonia, cytokine response, airway obstruction, and chronic inflammatory infiltrates associated with long-term airway hyperresponsiveness in mice. *Journal of Infectious Diseases*, The University of Chicago Press, v. 189, n. 10, p. 1856–1865, 2004.

JOORABCHI, M. E.; MESBAH, A.; KRUCHTEN, P. Real challenges in mobile app development. In: *2013 ACM / IEEE International Symposium on Empirical Software Engineering and Measurement*. Baltimore, MD, USA: IEEE, 2013. p. 15–24.

KACHUEE, M.; FAZELI, S.; SARRAFZADEH, M. Ecg heartbeat classification: A deep transferable representation. In: IEEE. *2018 IEEE International Conference on Healthcare Informatics (ICHI)*. New York, NY, USA, 2018. p. 443–444.

KARAR. Cascaded deep learning classifiers for computer-aided diagnosis of covid-19 and pneumonia diseases in x-ray scans. *Complex & Intelligent Systems*, Springer, p. 1–13, 2020.

KARTHIK, R.; MENAKA, R.; HARIHARAN, M. Learning distinctive filters for covid-19 detection from chest x-ray using shuffled residual cnn. *Applied Soft Computing*, Elsevier, p. 106744, 2020.

KHAN. Coronet: A deep neural network for detection and diagnosis of covid-19 from chest x-ray images. *Computer Methods and Programs in Biomedicine*, Elsevier, p. 105581, 2020.

KOCHHÄUSER, S. et al. Supraventricular premature beats and short atrial runs predict atrial fibrillation in continuously monitored patients with cryptogenic stroke. *Stroke*, v. 45, n. 3, p. 884–886, 2014. Disponível em: <<https://www.ahajournals.org/doi/abs/10.1161/STROKEAHA.113.003788>>.

KOURETAS, I.; PALIOURAS, V. Simplified hardware implementation of the softmax activation function. In: IEEE. *2019 8th International Conference on Modern Circuits and Systems Technologies (MOCAS)*. Thessaloniki, Greece, Greece, 2019. p. 1–4.

KOURIS, A.; VENIERIS, S. I.; BOUGANIS, C.-S. Cascade<sup>^</sup> cnn: Pushing the performance limits of quantisation in convolutional neural networks. In: IEEE. *2018 28th International Conference on Field Programmable Logic and Applications (FPL)*. Dublin, Ireland, 2018. p. 155–157.

KRAWCZYK, B. Learning from imbalanced data: open challenges and future directions. *Progress in Artificial Intelligence*, Springer, v. 5, n. 4, p. 221–232, 2016.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Commun. ACM*, Association for Computing Machinery,

New York, NY, USA, v. 60, n. 6, p. 84–90, maio 2017. ISSN 0001-0782. Disponível em: <<https://doi.org/10.1145/3065386>>.

KROFT, L. J. et al. Added value of ultra-low-dose computed tomography, dose equivalent to chest x-ray radiography, for diagnosing chest pathology. *Journal of thoracic imaging*, Wolters Kluwer Health, v. 34, n. 3, p. 179, 2019.

KUMAR, G.; PAWAR, U.; O'REILLY, R. Arrhythmia detection in ecg signals using a multilayer perceptron network. 2019.

LABHANE, G. et al. Detection of pediatric pneumonia from chest x-ray images using cnn and transfer learning. In: IEEE. *2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE)*. Jaipur, India, 2020. p. 85–92.

LANA, R. M. et al. Emergência do novo coronavírus (sars-cov-2) e o papel de uma vigilância nacional em saúde oportuna e efetiva. *Cadernos de Saúde Pública*, SciELO Public Health, v. 36, p. e00019620, 2020.

LI, J. et al. Deep reinforcement learning for dialogue generation. *arXiv preprint arXiv:1606.01541*, 2016.

LI, T.; ZHOU, M. Ecg classification using wavelet packet entropy and random forests. *Entropy*, Multidisciplinary Digital Publishing Institute, v. 18, n. 8, p. 285, 2016.

LIAN, Y.; HO, P. C. Ecg noise reduction using multiplier-free fir digital filters. In: IEEE. *Proceedings 7th International Conference on Signal Processing, 2004. Proceedings. ICSP'04. 2004*. Beijing, China, 2004. v. 3, p. 2198–2201.

LIANG, J. et al. Car detection and classification using cascade model. *IET Intelligent Transport Systems*, IET, v. 12, n. 10, p. 1201–1209, 2018.

LIU, H. et al. Clinical and ct imaging features of the covid-19 pneumonia: Focus on pregnant women and children. *Journal of infection*, Elsevier, 2020.

LIU, J. et al. Classification of ecg arrhythmia using cnn, svm and lda. In: SUN, X.; PAN, Z.; BERTINO, E. (Ed.). *Artificial Intelligence and Security*. Cham: Springer International Publishing, 2019. p. 191–201. ISBN 978-3-030-24265-7.

LUJÁN-GARCÍA, J. E. et al. Fast covid-19 and pneumonia classification using chest x-ray images. *Mathematics*, Multidisciplinary Digital Publishing Institute, v. 8, n. 9, p. 1423, 2020.

MAHMUD. Covxnet: A multi-dilation convolutional neural network for automatic covid-19 and other pneumonia detection from chest x-ray images with transferable multi-receptive feature optimization. *Computers in biology and medicine*, Elsevier, v. 122, p. 103869, 2020.

MARRIE, T. J. et al. A controlled trial of a critical pathway for treatment of community-acquired pneumonia. *Jama*, American Medical Association, v. 283, n. 6, p. 749–755, 2000.

MARTIS, R. J. et al. Application of higher order cumulant features for cardiac health diagnosis using ecg signals. *International journal of neural systems*, World Scientific, v. 23, n. 04, p. 1350014, 2013.

- MARTIS, R. J. et al. Application of principal component analysis to ecg signals for automated diagnosis of cardiac health. *Expert Systems with Applications*, Elsevier, v. 39, n. 14, p. 11792–11800, 2012.
- MIYASHITA, N.; YAMAUCHI, Y. Bacterial pneumonia in elderly japanese populations. *Japanese clinical medicine*, SAGE Publications Sage UK: London, England, v. 9, p. 1179670717751433, 2018.
- MO, P. et al. Clinical characteristics of refractory covid-19 pneumonia in wuhan, china. *Clinical Infectious Diseases*, 2020.
- MOHSEN, A.; MCKENDRICK, M. Varicella pneumonia in adults. *European Respiratory Journal*, Eur Respiratory Soc, v. 21, n. 5, p. 886–891, 2003.
- MOONS, B. et al. Minimum energy quantized neural networks. In: IEEE. *2017 51st Asilomar Conference on Signals, Systems, and Computers*. Pacific Grove, CA, USA, 2017. p. 1921–1925.
- NG, M.-Y. et al. Imaging profile of the covid-19 infection: radiologic findings and literature review. *Radiology: Cardiothoracic Imaging*, Radiological Society of North America, v. 2, n. 1, p. e200034, 2020.
- OH, S. L. et al. Automated diagnosis of arrhythmia using combination of cnn and lstm techniques with variable length heart beats. *Computers in biology and medicine*, Elsevier, v. 102, p. 278–287, 2018.
- OPTIMIZE scikit. <https://scikit-optimize.github.io/stable>. 2020.
- OZTURK, T. et al. Automated detection of covid-19 cases using deep neural networks with x-ray images. *Computers in Biology and Medicine*, Elsevier, p. 103792, 2020.
- PANDEY, A. et al. A multistage deep residual network for biomedical cyber-physical systems. *IEEE Systems Journal*, IEEE, v. 14, n. 2, p. 1953–1962, 2019.
- PANDEY, S. K.; JANGHEL, R. R. Automatic detection of arrhythmia from imbalanced ecg database using cnn model with smote. *Australasian physical & engineering sciences in medicine*, Springer, v. 42, n. 4, p. 1129–1139, 2019.
- PANTELOPOULOS, A.; BOURBAKIS, N. Design of the new prognosis wearable system-prototype for health monitoring of people at risk. In: \_\_\_\_\_. *Advances in Biomedical Sensing, Measurements, Instrumentation and Systems*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 29–42. ISBN 978-3-642-05167-8. Disponível em: <[https://doi.org/10.1007/978-3-642-05167-8\\_3](https://doi.org/10.1007/978-3-642-05167-8_3)>.
- PAYNE, R. *Beginning App Development with Flutter: Create Cross-Platform Mobile Apps*. Apress, 2019. ISBN 9781484251805. Disponível em: <<https://books.google.com.br/books?id=iTLXgEACAAJ>>.
- PEYRANI, P. et al. The burden of community-acquired bacterial pneumonia in the era of antibiotic resistance. *Expert review of respiratory medicine*, Taylor & Francis, v. 13, n. 2, p. 139–152, 2019.
- PONTES, F. J. et al. Design of experiments and focused grid search for neural network parameter optimization. *Neurocomputing*, Elsevier, v. 186, p. 22–34, 2016.

RAMALINGAM, S.; GARZIA, F. Facial expression recognition using transfer learning. In: *2018 International Carnahan Conference on Security Technology (ICCST)*. Montreal, QC, Canada: IEEE, 2018. p. 1–5. ISSN 2153-0742.

RIQUELME, R. et al. Influenza pneumonia: a comparison between seasonal influenza virus and the h1n1 pandemic. *European Respiratory Journal*, Eur Respiratory Soc, v. 38, n. 1, p. 106–111, 2011.

RUSSAKOVSKY, O. et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*, Springer, v. 115, n. 3, p. 211–252, 2015.

RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. Englewood Cliffs, New Jersey: Malaysia; Pearson Education Limited,, 2016.

SALAMON, J.; BELLO, J. P. Deep convolutional neural networks and data augmentation for environmental sound classification. *IEEE Signal Processing Letters*, IEEE, v. 24, n. 3, p. 279–283, 2017.

SALAVATIAN, S. et al. Premature ventricular contractions activate vagal afferents and alter autonomic tone: implications for premature ventricular contraction-induced cardiomyopathy. *American Journal of Physiology-Heart and Circulatory Physiology*, v. 317, n. 3, p. H607–H616, 2019. PMID: 31322427. Disponível em: <<https://doi.org/10.1152/ajpheart.00286.2019>>.

SANDLER, M. et al. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT, USA: IEEE, 2018. p. 4510–4520.

SARAIVA, A. et al. Compression of electrocardiographs comparative study between the walsh hadamard transform and discrete cosine transform. In: . Antalya: 7th International Conference on Advanced Technologies, 2018.

SARAIVA, A. et al. Filtering of cardiac signals with mathematical morphology for qrs detection. In: *Proceedings of ICAT'18, 7th International Conference on Advanced Technologies*. Antalya: Proceedings of ICAT'18, 7th International Conference on Advanced Technologies, 2019. p. 1008–1017.

SARAIVA, A. et al. Mobile multirobot manipulation by image recognition. 2018.

SARAIVA, A. et al. Models of learning to classify x-ray images for the detection of pneumonia using neural networks. 2019.

SARAIVA, A. A. et al. Identification of exonic regions in dna sequences an approach using cross-correlation and noise suppression by discrete cosine transform. *Research, Society and Development*, v. 9, n. 9, p. e883998173–e883998173, 2020.

SARAIVA, A. A. et al. Electroencephalography applied compression algorithms qualitative analysis. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, Taylor & Francis, v. 8, n. 4, p. 367–373, 2020.

SARAIVA., A. A. et al. Comparative study of compression techniques applied in different biomedical signals. In: INSTICC. *Proceedings of the 12th International Joint Conference on Biomedical Engineering Systems and Technologies - Volume 4: BIOSIGNALS*,. Prague, Czech Republic: SciTePress, 2019. p. 132–138. ISBN 978-989-758-353-7.

SARAIVA, A. A. et al. Comparative study between the walsh hadamard transform and discrete cosine transform. In: *7th International Conference on Advanced Technologies*. Antalya: SciTePress, 2018.

SARAIVA., A. A. et al. Classification of images of childhood pneumonia using convolutional neural networks. In: INSTICC. *Proceedings of the 12th International Joint Conference on Biomedical Engineering Systems and Technologies - Volume 2: BIOIMAGING*,. Prague, Czech Republic: SciTePress, 2019. p. 112–119. ISBN 978-989-758-353-7.

SARAIVA, A. A. et al. Models of learning to classify x-ray images for the detection of pneumonia using neural networks. In: *BIOIMAGING*. Prague, Czech Republic: SciTePress, 2019.

SARAIVA, A. A. et al. Navigation of quadruped multirobots by gesture recognition using restricted boltzmann machines. In: *Memorias de Congresos UTP*. Panama City, Panama: CLAWAR, 2018. p. 431–438.

SATTAR, S. B. A.; SHARMA, S. Bacterial pneumonia. *StatPearls [Internet]*, StatPearls Publishing, 2020.

SCHEIBLAUER, H. et al. Interactions between bacteria and influenza a virus in the development of influenza pneumonia. *Journal of Infectious Diseases*, The University of Chicago Press, v. 166, n. 4, p. 783–791, 1992.

SEFEROVIĆ, P. et al. Cardiac arrhythmias and conduction disturbances in autoimmune rheumatic diseases. *Rheumatology*, Oxford University Press, v. 45, n. suppl\_4, p. iv39–iv42, 2006.

SERRA, A.; GALDI, P.; TAGLIAFERRI, R. Chapter 13 - multiview learning in biomedical applications. In: KOZMA, R. et al. (Ed.). *Artificial Intelligence in the Age of Neural Networks and Brain Computing*. Academic Press, 2019. p. 265 – 280. ISBN 978-0-12-815480-9. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B978012815480900013X>>.

SHAHIN, M. A.; MAIER, H. R.; JAKSA, M. B. Data division for developing neural networks applied to geotechnical engineering. *Journal of Computing in Civil Engineering*, American Society of Civil Engineers, v. 18, n. 2, p. 105–114, 2004.

SHAKER, A. M. et al. Generalization of convolutional neural networks for ecg classification using generative adversarial networks. *IEEE Access*, IEEE, v. 8, p. 35592–35605, 2020.

SHERF, L.; JAMES, T. N. The mechanism of aberration in late atrioventricular junctional beats. *The American journal of cardiology*, Elsevier, v. 29, n. 4, p. 529–539, 1972.

SHIH, H.-T. et al. Frequency and significance of cardiac arrhythmias in chronic obstructive lung disease. *Chest*, Elsevier, v. 94, n. 1, p. 44–48, 1988.

SNOEK, J.; LAROCHELLE, H.; ADAMS, R. P. Practical bayesian optimization of machine learning algorithms. In: PEREIRA, F. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012. v. 25,

p. 2951–2959. Disponível em: <<https://proceedings.neurips.cc/paper/2012/file/05311655a15b75fab86956663e1819cd-Paper.pdf>>.

SNOEK, J. et al. *Scalable Bayesian Optimization Using Deep Neural Networks*. 2015.

SOUSA, J. V. M. et al. Classification of pneumonia images on mobile devices with quantized neural network. *Research, Society and Development*, v. 9, n. 10, p. e889108382–e889108382, 2020.

SOUSA, J. V. M. et al. Comparison between transforms a behavior qualitative analysis of various biomedical signals. *Research, Society and Development*, v. 9, n. 10, p. e3179108657–e3179108657, 2020.

SOUSA, L. A. N. d. et al. Aquisição e processamento do eletrocardiograma para auxílio ao diagnóstico de arritmias cardíacas. Universidade Federal Rural do Semi-Árido, 2018.

SOUSA, S. et al. Robotic control with pattern recognition by dynamic image segmentation. 08 2018.

SRINIVASAN, N. T.; SCHILLING, R. J. Sudden cardiac death and arrhythmias. *Arrhythmia & electrophysiology review*, Radcliffe Cardiology, v. 7, n. 2, p. 111, 2018.

SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014.

VAYÁ, M. de la I. et al. Bimcv covid-19+: a large annotated dataset of rx and ct images from covid-19 patients. *arXiv preprint arXiv:2006.01174*, 2020.

VENTOLA, C. L. Mobile devices and apps for health care professionals: uses and benefits. *Pharmacy and Therapeutics*, MediMedia, USA, v. 39, n. 5, p. 356, 2014.

VIKMAN, S. et al. Heart rate turbulence after atrial premature beats before spontaneous onset of atrial fibrillation. *Journal of the American College of Cardiology*, *Journal of the American College of Cardiology*, v. 45, n. 2, p. 278–284, 2005.

WAMBOLDT, R. et al. Cardiac arrhythmias secondary to hormone therapy in trans women. *Expert Review of Cardiovascular Therapy*, Taylor & Francis, v. 17, n. 5, p. 335–343, 2019.

WANG ALEXANDER WONG, Z. Q. L. P. M. A. C. L.; GUNRAJ, H. Actualmed covid-19 chest x-ray dataset initiative. 2020. Disponível em: <<https://github.com/agchung/Actualmed-COVID-chestxray-dataset>>.

WANG ALEXANDER WONG, Z. Q. L. P. M. A. C. L.; GUNRAJ, H. Figure 1 covid-19 chest x-ray dataset initiative. 2020. Disponível em: <<https://github.com/agchung/Figure1-COVID-chestxray-dataset>>.

WANG, Y. et al. Cellular mechanism of premature ventricular contraction–induced cardiomyopathy. *Heart Rhythm*, Elsevier, v. 11, n. 11, p. 2064–2072, 2014.

WIT, A. L.; ROSEN, M. R. Pathophysiologic mechanisms of cardiac arrhythmias. *American heart journal*, Elsevier, v. 106, n. 4, p. 798–811, 1983.

- WORLD HEALTH, O. World, health, organization pneumonia. <https://www.who.int/en/news-room/fact-sheets/detail/pneumonia> , (accessed 20.02.14), 2016. Disponível em: <<https://www.who.int/en/news-room/fact-sheets/detail/pneumonia>>.
- WU, J. et al. Quantized convolutional neural networks for mobile devices. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA: IEEE, 2016. p. 4820–4828.
- WU, Y. et al. Convolution neural network based transfer learning for classification of flowers. In: *2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP)*. Shenzhen, China: IEEE, 2018. p. 562–566.
- XIONG, Z.; STILES, M. K.; ZHAO, J. Robust ecg signal classification for detection of atrial fibrillation using a novel neural network. In: IEEE. *2017 Computing in Cardiology (CinC)*. Rennes, France, 2017. p. 1–4.
- YAFFE, M.; ROWLANDS, J. X-ray detectors for digital radiography. *Physics in Medicine & Biology*, IOP Publishing, v. 42, n. 1, p. 1, 1997.
- YANG, J. et al. A novel electrocardiogram arrhythmia classification method based on stacked sparse auto-encoders and softmax regression. *International Journal of Machine Learning and Cybernetics*, Springer, v. 9, n. 10, p. 1733–1740, 2018.
- YANG, W. et al. Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine. *Computers in biology and medicine*, Elsevier, v. 101, p. 22–32, 2018.
- YEH, Y.-C.; WANG, W.-J. Qrs complexes detection for ecg signal: The difference operation method. *Computer methods and programs in biomedicine*, Elsevier, v. 91, n. 3, p. 245–254, 2008.
- ZHAI, P. et al. The epidemiology, diagnosis and treatment of covid-19. *International journal of antimicrobial agents*, Elsevier, p. 105955, 2020.
- ZHANG, X. et al. Deep neural network hyperparameter optimization with orthogonal array tuning. In: SPRINGER. *International Conference on Neural Information Processing*. Sydney, Australia, 2019. p. 287–295.
- ZHANG, Y. et al. A multilayer perceptron based smart pathological brain detection system by fractional fourier entropy. *Journal of medical systems*, Springer, v. 40, n. 7, p. 173, 2016.
- ZHANG, Z.; LUO, X. Heartbeat classification using decision level fusion. *Biomedical Engineering Letters*, Springer, v. 4, n. 4, p. 388–395, 2014.
- ZHOU, T. et al. Unsupervised learning of depth and ego-motion from video. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI, USA: IEEE, 2017. p. 6612–6619.
- ZIHLMANN, M.; PEREKRESTENKO, D.; TSCHANNEN, M. Convolutional recurrent neural networks for electrocardiogram classification. In: IEEE. *2017 Computing in Cardiology (CinC)*. Rennes, France, 2017. p. 1–4.

# APÊNDICE A – Artigo 1 publicado

Research, Society and Development, v. 9, n. 10, e889108382, 2020  
(CC BY 4.0) | ISSN 2525-3409 | DOI: <http://dx.doi.org/10.33448/rsd-v9i10.8382>

**Classification of Pneumonia images on mobile devices with Quantized Neural Network**

**Classificação de imagens de Pneumonia em dispositivos móveis com Rede Neural  
Quantizada**

**Clasificación de imágenes de neumonía en dispositivos móviles con red neuronal  
cuantificada**

Received: 09/11/2020 | Reviewed: 09/13/2020 | Accept: 09/17/2020 | Published: 09/19/2020

**José Vigno Moura Sousa**

ORCID: <https://orcid.org/0000-0002-5164-360X>

Universidade Brasil, Brasil

E-mail: [josevigno@prp.uespi.br](mailto:josevigno@prp.uespi.br)

**Vilson Rosa de Almeida**

ORCID: <https://orcid.org/0000-0001-9077-2941>

Universidade Brasil, Brasil

E-mail: [vilson.almeida@universidadebrasil.edu.br](mailto:vilson.almeida@universidadebrasil.edu.br)

**Aratã Andrade Saraiva**

ORCID: <https://orcid.org/0000-0002-3960-697X>

Universidade Estadual do Piauí, Brasil

E-mail: [aratasaraiva@gmail.com](mailto:aratasaraiva@gmail.com)

**Domingos Bruno Sousa Santos**

ORCID: <https://orcid.org/0000-0003-4018-242X>

Universidade Estadual do Piauí, Brasil

E-mail: [domingosbruno@prp.uespi.br](mailto:domingosbruno@prp.uespi.br)

**Pedro Mateus Cunha Pimentel**

ORCID: <https://orcid.org/0000-0002-5291-0810>

Universidade Estadual do Piauí, Brasil

E-mail: [pedrocunha@prp.uespi.br](mailto:pedrocunha@prp.uespi.br)

**Luciano Lopes de Sousa**

ORCID: <https://orcid.org/0000-0003-0551-4804>

Universidade Estadual do Piauí, Brasil

E-mail: [lucianoelps@prp.uespi.br](mailto:lucianoelps@prp.uespi.br)

# APÊNDICE B – Artigo 2 publicado

Research, Society and Development, v. 9, n. 10, e3179108657, 2020  
(CC BY 4.0) | ISSN 2525-3409 | DOI: <http://dx.doi.org/10.33448/rsd-v9i10.8657>

**Comparison between transforms a behavior qualitative analysis of various biomedical signals**

**Comparação entre transformadas uma análise qualitativa do comportamento de vários sinais biomédicos**

**Comparación entre transformadas un análisis cualitativo de comportamiento de diversas señales biomédicas**

Received: 09/21/2020 | Reviewed: 09/22/2020 | Accept: 09/26/2020 | Published: 09/27/2020

**José Vigno Moura Sousa**

ORCID: <https://orcid.org/0000-0002-5164-360X>

Universidade Brasil, Brasil

E-mail: [josevigno@prp.uespi.br](mailto:josevigno@prp.uespi.br)

**Vilson Rosa de Almeida**

ORCID: <https://orcid.org/0000-0001-9077-2941>

Universidade Brasil, Brasil

E-mail: [vilson.almeida@universidadebrasil.edu.br](mailto:vilson.almeida@universidadebrasil.edu.br)

**Aratã Andrade Saraiva**

ORCID: <https://orcid.org/0000-0002-3960-697X>

Universidade Estadual do Piauí, Brasil

E-mail: [aratasaraiva@gmail.com](mailto:aratasaraiva@gmail.com)

**Felipe Miranda de Jesus Castro**

ORCID: <https://orcid.org/0000-0002-7751-9455>

Universidade Estadual do Piauí, Brasil

E-mail: [fenris@prp.uespi.br](mailto:fenris@prp.uespi.br)

**Domingos Bruno Sousa Santos**

ORCID: <https://orcid.org/0000-0003-4018-242X>

Universidade Estadual do Piauí, Brasil

E-mail: [domingosbruno@prp.uespi.br](mailto:domingosbruno@prp.uespi.br)

**Pedro Mateus Cunha Pimentel**

ORCID: <https://orcid.org/0000-0002-5291-0810>

Universidade Estadual do Piauí, Brasil

E-mail: [pedrocunha@prp.uespi.br](mailto:pedrocunha@prp.uespi.br)

# APÊNDICE C – Artigo 3 em *preprint*

Vigno *et al.*

## RESEARCH

# Mobile Device ECG Classification using quantized Neural Networks

Sousa Vigno<sup>1,2\*†</sup>  
 , Vilson Almeida<sup>2</sup>  
 , Santos Domingos<sup>1</sup>  
 , Costa Nator<sup>3</sup>  
 , Sousa Lopes<sup>1</sup>  
 and Pimentel Pedro<sup>1</sup>

\*Correspondence:

[josevigno@prp.uespi.br](mailto:josevigno@prp.uespi.br)

<sup>2</sup>Universidade Brazil,Rua Carolina

Fonseca, 584 - Itaquera,

08230-030, São Paulo - SP,Brazil

Full list of author information is

available at the end of the article

†Equal contributor

### Abstract

In this paper, a novel method for classifying electrocardiogram signals in mobile devices is proposed, which classifies different arrhythmias according to the Association for the Advancement of Medical Instrumentation standard EC57. A convolutional neural network has been constructed, trained and validated with the MIT-BIH Arrhythmia Dataset, which has 5 different classes: normal beat, supraventricular premature beat, premature ventricular contraction, fusion of ventricular and normal beat, unclassifiable beat. Once trained and validated, the model is subjected to a post-training quantization stage using the TensorFlow Lite conversion method. The obtained results were satisfactory, before and after the quantization, the convolutional neural network obtained an accuracy of 98.5%. With the quantization technique it was possible to obtain a significant reduction in model size, thus enabling the development of the mobile application, this reduction was approximately 90% compared to the original model size.

**Keywords:** ECG; Quantization; CNN; Mobile

## 1 Introduction

Cardiovascular diseases are one of the leading causes of death worldwide. This type of pathology affects the cardiovascular system, specifically the blood vessels and the heart. There is a growing rate of the population suffering from cardiovascular diseases, including arrhythmia [1]. Sudden death caused by cardiac arrhythmia is a major public health problem worldwide, accounting for 15% to 20% of all deaths. It is estimated that 180,000 to 300,000 sudden cardiac deaths occur in the US annually [2].

In the clinical diagnosis of heart disease, arrhythmia indicates a severe change in heartbeat function and may cause a stroke or sudden cardiac death if left untreated [3]. For detection of cardiac anomalies, the use of electrocardiogram (ECG) is a fundamental diagnosis. This clinical analysis can perform the monitoring of cardiovascular diseases, where this procedure is done manually. However, there are several problems with manually analyzing ECG signals, such as: similarity to other time series data, difficulty in detecting and categorizing different waveform and signal morphology. For a human being, this task is time-consuming and error-prone [4], [5].

1  
2  
3  
4  
5  
6  
7  
8  
9  
10  
11  
12  
13  
14  
15  
16  
17  
18  
19  
20  
21  
22  
23  
24  
25  
26  
27  
28  
29  
30  
31  
32  
33  
34  
35  
36  
37  
38  
39  
40  
41  
42  
43  
44  
45  
46  
47  
48  
49  
50  
51  
52  
53  
54  
55  
56  
57  
58  
59  
60  
61  
62  
63  
64  
65