

**UNIVERSIDADE DE SÃO PAULO**

Instituto de Ciências Matemáticas e de Computação

## **Deteccção de Arritmia Cardíaca a partir de Sinais ÉCG numa Abordagem Intra-paciente**

**Manoel Victor Florencio de Souza**

Monografia - MBA em Inteligência Artificial e Big Data



SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

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

**Manoel Victor Florencio de Souza**

## **Detecção de Arritmia Cardíaca a partir de Sinais ECG numa Abordagem Intra-paciente**

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Caetano Mazzoni  
Ranieri

**Versão original**

**São Carlos**

**2024**

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTA TRABALHO,  
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E  
PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi, ICMC/USP, com os dados  
fornecidos pelo(a) autor(a)

S856m	<p>Souza, M. V. F. Detecção de Arritmia Cardíaca a partir de Sinais ECG numa Abordagem Intra-paciente / Manoel Victor Florencio de Souza ; Caetano Mazzoni Ranieri. – São Carlos, 2024. 56 p. : il. (algumas color.) ; 30 cm.</p> <p>Monografia (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universi- dade de São Paulo, 2024.</p> <p>1. Sinais ECG. 2. Análise Intra-paciente. 3. Redes Neurais Convolucionais. I. Ranieri, Caetano Mazzoni, orient. II. Título.</p>
-------	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------



*Este trabalho é dedicado aos meus pais, minhas irmãs Joseanne e Victoria  
e meu amor Larissa.*

## AGRADECIMENTOS

Aos meus pais, que mesmo não entendendo bem a área que escolhi seguir, sempre apoiaram a continuar meus estudos.

Ao meu amor Larissa por acompanhar o desenvolvimento do trabalho, revisar os textos e me apoiar infinitamente.

Às minhas irmãs Joseanne e Victoria pelo apoio, inspiração e desabafos.

Aos meus melhores amigos Lucas, pelas conversas animadas e sugestões certeiras, e Neto pelas críticas duras, “*hooks*” errados e gargalhadas.

Às minhas primas Bruna e Andrea por me inspirarem a pensar no próximo e plantar a sementinha da curiosidade da ciência e da docência na minha mente.

Às minhas cachorrinhas Lili, Lin e Mily pela companhia e carinho sem fim.

Ao meu orientador Prof. Dr. Caetano Mazzoni Ranieri, pela disponibilidade, paciência e calma que me guiou durante o desenvolvimento deste trabalho.

E a todos que passaram pela minha trajetória e deixaram boas lembranças.





*“ Ter medo não é algo ruim, foi o meu medo que me trouxe até aqui.”*  
*Kanehito Yamada, Frieren e a Jornada para o Além, Eisen.*



## RESUMO

Souza, M. V. F. **Detecção de Arritmia Cardíaca a partir de Sinais ECG numa Abordagem Intra-paciente.** 2024. 56p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

Sístole e diástole se referem a ondas elétricas emitidas pelos movimentos do coração e sua anormalidade pode caracterizar doença cardíaca. Busca-se entendê-las para identificação de possíveis irregularidades no comportamento do coração do paciente ou indivíduo. Até o momento a previsão de irregulares ainda não é possível, sendo apenas detecção quando esta ocorre. Um método para detecção de arritmia cardíacas é através da análise do sinal de eletrocardiograma que ainda depende muito da experiência do examinador. Para isso é treinado uma rede neural convolucional baseada em modelos funcionais para classificar sinais de ECG com arritmia. 5 redes baseadas em transferência de aprendizado foram treinadas a partir de uma base de dados pública, desbalanceada e rotulada de sinais ECG. Aquela que apresentou melhor performance comparada a *baseline* consistindo uma rede neural convolucional treinada do zero com sinais ECG pré-processados por transformadas de Fourier de tempo curto usando os mesmos dados de treinamento. O modelo inteligente final obteve um F1-Score de 91.67 % para o conjunto de teste contra 88.39% da *baseline*, além de superá-la na classificação de cada uma das 4 classes. Observou-se também que a aplicação de transferência de aprendizado mitigou o problema de baixo número de exemplos na base de dados e melhorou o aprendizado dos modelos inteligentes testados. Assim, foi possível treinar uma rede neural convolucional baseada na arquitetura MobileNet capaz de detectar arritmia cardíaca a partir de sinais ECG com F1-Score maior que a *baseline* definida e com ligeira dificuldade para detecção de sinais que não apresentam um comportamento padrão como Ruído e Outro.

**Palavras-chave:** Sinais ECG. Análise Intra-paciente. Redes Neurais Convolucionais.



## ABSTRACT

Souza, M. V. F. **Detecção de Arritmia Cardíaca a partir de Sinais ECG numa Abordagem Intra-paciente.** 2024. 56p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2024.

Systole and diastole refer to electrical waves emitted by the heart's movements and their abnormality may characterize heart disease. The goal is to understand them to identify possible irregularities in the behavior of the patient's or individual's heart. Forecasting irregularities is not yet possible only detect them when they occur. One method for detecting cardiac arrhythmia is analyzing the electrocardiogram signal, which still depends heavily on the examiner's experience. For this purpose, a convolutional neural network based on foundational models is trained to classify ECG signals with arrhythmia. Five networks based on transfer learning were trained from a public, unbalanced and labeled database of ECG signals. The one that best performed was compared to a baseline consisting of a convolutional neural network trained from scratch with ECG signals preprocessed by short-time Fourier transformation using the same training data. The final intelligent model obtained an F1-Score of 91.67% on the test set against 88.39% for the baseline, in addition to outperforming it in the classification of each of the 4 classes. It was also observed that the application of transfer learning mitigated the problem of a low number of examples in the database and improved the understanding of the tested intelligent models. Thus, it was possible to train a convolutional neural network based on the MobileNet foundational model capable of detecting cardiac arrhythmia from ECG signals with F1-Score higher than the defined baseline and with slight difficulty in detecting signals that do not present a standard behavior such as Noise and Other.

**Keywords:** ECG signals. Intra-patient Analysis. Convolutional Neural Networks.



## LISTA DE FIGURAS

Figura 1 – Exemplo de ECG normal . . . . .	25
Figura 2 – Complexo QRS . . . . .	26
Figura 3 – Exemplo de transformada de Fourier . . . . .	27
Figura 4 – Tipos de Aprendizado de Máquina . . . . .	29
Figura 5 – Exemplo de Classificação. Fonte: (COCK, 2015) . . . . .	30
Figura 6 – Neurônio Perceptron. Fonte: (DUKOR, 2018) . . . . .	31
Figura 7 – Rede Neural de Múltiplas Camadas . . . . .	32
Figura 8 – Aprendizado Profundo. Fonte: (CONSULTING, 2018) . . . . .	33
Figura 9 – Arquitetura de uma Rede CNN. Adaptado de (VEEN, 2016) . . . . .	34
Figura 10 – Ilustração de uma operação <i>Average Pooling</i> . Fonte: (KHOSLA, 2023) . . . . .	34
Figura 11 – Arquitetura VGG16 . . . . .	36
Figura 12 – <i>Pipeline</i> da Proposta. . . . .	41
Figura 13 – Exemplos de ECG para as classes FA, RSR, Ruído e Outro para o paciente P2. Imagem criada pelo autor. . . . .	42
Figura 14 – Distribuição das classes de ECG. Imagem criada pelo autor. . . . .	43
Figura 15 – Arquitetura da modelo Baseline. Adaptada de (GUPTA; BHASKARPAN- DIT; GUPTA, 2021). . . . .	44





## LISTA DE TABELAS

Tabela 1 – Relatório de Classificação do modelo VGG16 . . . . .	46
Tabela 2 – Matriz de confusão do modelo VGG16 . . . . .	46
Tabela 3 – Relatório de Classificação do modelo ResNet50 . . . . .	47
Tabela 4 – Matriz de confusão do modelo ResNet50 . . . . .	47
Tabela 5 – Relatório de Classificação do modelo ResNet152V2 . . . . .	47
Tabela 6 – Matriz de confusão do modelo ResNet152V2 . . . . .	48
Tabela 7 – Relatório de Classificação do modelo NASNetLarge . . . . .	48
Tabela 8 – Matriz de confusão do modelo NASNetLarge . . . . .	48
Tabela 9 – Relatório de Classificação do modelo MobileNet . . . . .	48
Tabela 10 – Matriz de confusão do modelo MobileNet . . . . .	49
Tabela 11 – Avaliação MobileNet por Paciente. . . . .	49
Tabela 12 – Tabela Comparativa entre modelos avaliados . . . . .	50



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
<b>1.1</b>	<b>Contextualização, Motivação e Lacunas</b>	<b>21</b>
<b>1.2</b>	<b>Objetivos</b>	<b>22</b>
1.2.1	Objetivo Geral	22
1.2.2	Objetivos Específicos	22
<b>1.3</b>	<b>Organização do texto</b>	<b>22</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>25</b>
<b>2.1</b>	<b>Cardiologia</b>	<b>25</b>
<b>2.2</b>	<b>Processamento Digital de Sinais</b>	<b>26</b>
2.2.1	Transformada de Fourier de Tempo Curto	27
<b>2.3</b>	<b>Aprendizado de Máquina</b>	<b>28</b>
2.3.1	Tipos de Aprendizado	28
2.3.2	Aprendizado Supervisionado	29
2.3.3	Classificação Supervisionada	29
2.3.4	Modelos Conexionistas	29
<b>2.4</b>	<b>Redes Neurais Artificiais</b>	<b>30</b>
2.4.1	Neurônio Artificial	30
2.4.2	Redes Perceptron de Múltiplas Camadas	31
2.4.3	Algoritmo Retro-propagação	31
2.4.4	Função de Ativação	32
2.4.5	Aprendizado Profundo	33
2.4.6	Rede Neural Convolucional	34
2.4.7	Transferência de Aprendizado	35
2.4.8	Arquiteturas CNN para transferência de aprendizado	35
2.4.8.1	VGG	36
2.4.8.2	ResNet	36
2.4.8.3	MobileNet	37
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>39</b>
<b>4</b>	<b>METODOLOGIA</b>	<b>41</b>
<b>4.1</b>	<b>Proposta</b>	<b>41</b>
<b>4.2</b>	<b>Base de Dados</b>	<b>42</b>
4.2.1	Eletrocardiograma	42
<b>4.3</b>	<b>Pré-processamentos</b>	<b>43</b>

4.3.1	Processamento de Sinais . . . . .	43
4.4	<b>Baseline</b> . . . . .	44
4.5	<b>Arquiteturas baseadas em Redes Profundas</b> . . . . .	44
4.5.1	Modelos fundacionais . . . . .	44
5	<b>AVALIAÇÃO EXPERIMENTAL</b> . . . . .	45
5.1	<b>Configuração Experimental</b> . . . . .	45
5.1.1	Configuração Padrão de Topo de Rede Neural . . . . .	45
5.1.2	Arquitetura VGG16 . . . . .	46
5.1.3	Arquitetura ResNet50 . . . . .	47
5.1.4	Arquitetura ResNet152V2 . . . . .	47
5.1.5	Arquitetura NASNetLarge . . . . .	47
5.1.6	Arquitetura MobileNet . . . . .	48
5.2	<b>Análise de classificação Intra-usuário</b> . . . . .	48
5.3	<b>Resultados e Discussões</b> . . . . .	49
6	<b>CONCLUSÕES</b> . . . . .	51
	<b>Referências</b> . . . . .	53

# 1 INTRODUÇÃO

## 1.1 Contextualização, Motivação e Lacunas

De acordo com a Sociedade Brasileira de Arritmias Cardíacas (SOBRAC), a arritmia cardíaca é uma anomalia na geração ou na condução do estímulo elétrico do coração (SOBRAC, *Acesso 2024*). De acordo com a Sociedade Brasileira de Cardiologia (SBC), entre os anos de 2000 e 2018 foi registrado que 6.755.551 pessoas faleceram de doenças cardiovasculares no Brasil (SBC, *Acesso 2024*). Ainda segundo a SBC, foi estimado 384.291 óbitos de 01 de Janeiro até o dia 14 de Dezembro de 2021, que em 2022 teria chegado em 354.447 até o dia 17 de Novembro, tendo ultrapassado a marca de 400 até o final do ano e que em 2023 foi de 296.000 até o dia 28 de Agosto.

Segundo National Heart, Lung and Blood Institute (NIH), os principais fatores de risco são: (i) Idade; (ii) Ambiente em que o indivíduo vive; (iii) Histórico Familiar; (iv) Hábitos Diários (fumo, consumo de álcool ou de drogas ilícitas); (v) Etnia; (vi) Gênero e (vii) Histórico de cirurgia cardíaca (NIH, *Acesso 2024*). Neste contexto, alguns dos maiores desafios são a individualidade do ritmo, frequência e atividade cardíaca, já que não necessariamente o padrão de arritmia analisado em um indivíduo será igual ao padrão de outro (PANDEY; JANGHEL, 2021) e mesmo o padrão de um indivíduo pode variar dependendo da atividade que estiver exercendo, seja dormindo, em repouso, caminhando ou correndo.

O desafio de detecção de arritmia cardíaca a partir de dados de ECG já vêm sendo explorado na literatura com o uso de modelos computacionais baseados em aprendizado de máquina clássicos, como a aplicação de k vizinhos mais próximos (KNN) (KUTLU; KUNTALP, 2011), máquina de vetores de suporte (SVM) (KUMAR; PACHORI; ACHARYA, 2017), árvore de decisão (DT) (LIN; WANG; CHUNG, 2010) e classificadores bayesianos (ABAWAJY; KELAREV; CHOWDHURY, 2013). Porém os esforços têm se voltado para detecção de arritmia cardíaca a partir de redes neurais profundas (EBRAHIMI *et al.*, 2020; ANSARI *et al.*, 2023), com o objetivo de eliminar a necessidade da extração manual de atributos, que geralmente exige conhecimento especializado (ANSARI *et al.*, 2023).

Desta forma, para resolver alguns dos desafios mencionados foram propostas diversas abordagens como em (NG *et al.*, 2023) que propõe o uso de uma Rede Neural Convolucional Siamesa utilizando segmentos de 30 segundos de dados de ECG através de uma abordagem de alternância de domínio entre bases de dados e pré-treinamento do classificador e então ajustando no novo domínio, já Chen *et al.* utiliza uma combinação de uma rede neural convolucional (CNN) com uma rede *Long Short-Term Memory* (LSTM) para classificação de segmentos de 10 segundos de sinais de ECG em 6 classes distintas, em (KUMAR *et al.*,

2022a) é apresentado uma arquitetura que combina camadas convolucionais com camadas *Bidirectional LSTM* (BiLSTM) e tem como dados de entrada tanto segmentos de sinais ECG, quanto intervalos RR (RRI) e características contextuais do paciente como: tipo de atividade que está exercendo e posição do corpo.

Apesar das performances promissoras nas abordagens citadas acima, nenhuma delas considera a aplicação das informações de sinais ECG do usuário num formato intra-paciente levando em consideração as individualidades do comportamento de ritmo, frequência e atividade cardíaca.

Sendo assim este estudo vem para investigar os diferentes padrões de comportamento do eletrocardiograma presentes em diferentes indivíduos com o objetivo de reduzir a confusão de classificação de tipos de arritmia cardíaca considerando suas especificidades a partir de modelos computacionais baseados em aprendizado de máquina, utilizando dados de eletrocardiogramas (ECG) numa abordagem intra-paciente.

## **1.2 Objetivos**

### **1.2.1 Objetivo Geral**

Projetar, implementar e avaliar o emprego de técnicas de pré-processamento e modelos computacionais baseados em aprendizado de máquina capazes de, a partir de dados de ECG identificar a ocorrência de arritmia cardíaca de forma intra-paciente.

### **1.2.2 Objetivos Específicos**

- Investigar bases de dados que possuem dados de ECG de usuários separados por indivíduo ou pacientes (ex. CACHET-CADB (KUMAR *et al.*, 2022b)).
- Avaliar diferentes métodos de pré-processamento de dados de ECG;
- Avaliar o desempenho de diferentes modelos inteligentes supervisionados para detecção de arritmia cardíaca a partir de métricas já estabelecidas na área como Acurácia, Precisão, Revocação e F1-Score, comparado-as com as métricas relatadas de outros trabalhos encontrados na literatura.
- Investigar parâmetros e hiper-parâmetros dos modelos computacionais baseados em aprendizado de máquina mais adequados para o problema proposto.

## **1.3 Organização do texto**

No Capítulo 2 são apresentados os fundamentos teóricos necessários para compreensão dos conceitos tratados neste trabalho. O capítulo descreve conceitos da cardiologia suas sub-áreas, os profissionais responsáveis e suas atividades, exames para detecção de

doenças, em especial a arritmia cardíaca e então detalha seu surgimento e diagnóstico, a importância e composição do sinal de eletrocardiograma, para então comentar como são tratados esses sinais através de abordagens de processamento digital de sinais como Transformada de Fourier e Wavelet e por fim uma breve descrição das arquiteturas e modelos inteligentes usados no estado da arte para identificação de arritmia.

No Capítulo 3, detalham-se alguns trabalhos relacionados que apresentaram bons resultados na área para bases de dados iguais ou similares, quais abordagens de pré-processamentos são adequadas e apresentaram bons resultados e quais arquiteturas tem boa performance na classificação de sinais ECG em contexto intra-paciente.

No Capítulo 4 trata da metodologia utilizada nos experimentos deste trabalho, bem como a proposta de sistema, a base de dados utilizada, os pré-processamentos estudados na literatura que fazem sentido com o proposto, um modelo *baseline* que apresentou bons resultados em trabalhos anteriores e por fim as arquiteturas baseadas em redes profundas utilizadas nos testes.

No Capítulo 5 são descritos os resultados dos treinamentos e avaliações dos modelos propostos para o problema, a configuração experimental de como o treinamento foi conduzido a fim de não haver preferências por um modelo A ou B, uma análise de classificação intra-usuário com o modelo que apresentou os melhores resultados e então uma discussão sobre os resultados alcançados.

Por fim no capítulo 6 são levantadas algumas considerações a cerca das comparações feitas nos experimentos, vantagens da abordagem utilizada, alguns pontos a serem levados em consideração que acarreta uma baixa performance de forma geral e sugestão de próximos passos da pesquisa em questão como uso dados de outros tipos para agregar informação contextual.





## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são descritos os fundamentos necessários para compreensão deste trabalho. Na Seção 2.1 estão inclusos os conceitos de cardiologia, ocorrência de anomalias que afetam o coração, métodos utilizados para diagnóstico de arritmia cardíaca como o ECG e o uso de dados ambulatoriais para enriquecimento do diagnóstico de arritmias cardíacas. Na Seção 2.2 é apresentada uma breve descrição dos métodos de processamento de sinais de ECG como Transformada de Fourier de Tempo Curto. Na Seção 2.3 são descritos os tipos de aprendizagem de máquina e como podem ser utilizados para classificação de arritmia cardíaca. Por fim, na Seção 2.4 são detalhados os modelos de aprendizagem de máquina conhecidos como Redes Neurais artificiais, desde seu funcionamento até as arquiteturas mais utilizadas para diagnóstico de arritmias, dentre elas as CNNs e LSTMs.

### 2.1 Cardiologia

A cardiologia é a área da medicina responsável pelo estudo, prevenção e tratamento de patologias que acometem o coração e os vasos sanguíneos, podendo ser dividida em 2 principais sub-áreas: Cardiologia Clínica ou Não-invasiva e Cardiologia Invasiva (H9J, 2020).

Os cardiologistas clínicos são os profissionais que realizam os atendimentos dos pacientes para diagnosticar e orientar sobre exames para então sugerir os tratamentos necessários. Entre estes exames está o Eletrocardiograma (ECG) que se trata de um exame clínico que avalia a atividade elétrica do coração por meio de eletrodos. Com os dados obtidos o cardiologista pode verificar se está havendo ou não alguma anomalia no ritmo cardíaco do indivíduo (LAVOISIER, 2021).

Segundo (CARNEIRO *et al.*, 2012), a arritmia cardíaca é resultado de uma anormalidade na geração ou condução do impulso elétrico levando a uma contração não rítmica. Ainda segundo Carneiro *et al.* o diagnóstico inicia-se com análise do histórico clínico do paciente, então a realização de um exame físico e com o registro eletrocardiográfico (ECG) durante sua ocorrência.




Figura 1 – Exemplo de ECG normal

O sinal ECG é reconhecido pelo padrão de onda retratado pelas letras P-QRS-T, a onda em si é referenciada como complexo QRS (TEICH *et al.*, 2000) como ilustrado na Figura 2. A onda P representa a despolarização atrial e subsequente contração, o complexo QRS compreende 3 pontos e reflete a despolarização ventricular, enquanto a onda T representa o período de repolarização ventricular e reflete que o miocárdio ventricular retornou ao repouso (KINGSLEY; LEWIS; MARSON, 2005).




Figura 2 – Complexo QRS

Apesar de ser um dos principais métodos para detecção de arritmia cardíaca, o ECG não apresenta todos os detalhes necessários para detecção automática dessa doença, ocasionando muitos falsos positivos quando capturados de pacientes em ambiente livre (KUMAR *et al.*, 2022a), ainda segundo Kumar et al. 62% dos casos de falso-positivos são relacionados com variáveis ambulatoriais de contexto do paciente, como atividade física sendo realizada, mudança de posição do corpo e realização de movimentos com aceleração súbita. Assim, faz-se desejável o uso destas informações com o fim de enriquecimento da qualidade da detecção automática de arritmia cardíaca.

## 2.2 Processamento Digital de Sinais

Processamento Digital de Sinais (PDS) é uma área do conhecimento que compreende teoria, aplicações, algoritmos e implementações fundamentais de processamento ou transferência de informação contidas em diferentes formatos, podendo ser físico, simbólico ou abstrato amplamente designados como sinais e que usam matemática estatística e computacional, técnicas para representação, modelagem, análise, síntese, descoberta, sensoramento, aquisição, extração de características para se ter o entendimento de um fenômeno que está sendo verificado (MOURA, 2009).

Para realizar essa extração de informações dos dados primeiro ele deve ser capturados por um sensor e então processado de uma maneira que agregue informação ou que o torne mais amigável para um profissional da área em questão possa analisá-lo de forma

mais eficiente e então aplicar técnicas de PDS, enriquecendo com informações para então o diagnóstico ou sugestão de diagnóstico seja feito de forma confiável.

O sinal ECG geralmente possui muitas oscilações causadas seja pelas variáveis de contexto ou por mal posicionamento dos eletrodos. Os ruídos no sinal pode causar erro na avaliação sobre o paciente e reduz a confiança do diagnóstico, para isto é recomendado a aplicação de alguns dos métodos processamento de sinais de como filtro de Butterworth (KUMAR *et al.*, 2022a) para remoção de interferências de baixa frequência.

Também são usadas outros métodos para processamento do ECG com o objetivo de enriquecimento de informações como o uso transformada de Fourier (HUANG *et al.*, 2019; RUBIN *et al.*, 2018; XIA *et al.*, 2018) para análise de frequência e amplitude de ondas com características variáveis ao longo do tempo e a transformada Wavelet (RAJPUT *et al.*, 2019) usada para descrever características morfológicas do ECG representando informações de tempo e frequência em diferentes resoluções.

### 2.2.1 Transformada de Fourier de Tempo Curto

A Transformada de Fourier de Tempo de Discreto ou de Tempo Curto, do inglês *Short-Time Fourier Transformation* ou STFT, é uma técnica para a análise de frequência em uma distribuição de sinal, ou seja, resulta nas frequências decompostas a partir do tempo. A análise é baseada em janelas deslizantes de tempo curto, portanto mostra características de frequência do sinal.

De acordo com Haykin e Van Veen a STFT pode ser usada para computar eficientemente a saída de um sistema caracterizado por uma resposta ao impulso de tamanho finito. Sistema de tempo curto são frequentemente usados para filtrar sinais e as saídas dos filtros relacionam-se com a entrada através da soma de convolução (HAYKIN; VEEN, 2001).




Figura 3 – Exemplo de transformada de Fourier

## 2.3 Aprendizado de Máquina

Aprendizado de Máquina (AM), Aprendizado Indutivo ou *Machine Learning*, é uma área da computação, mais especificamente da Inteligência Artificial, em que segundo Mitchel em (MITCHELL, 1997) trata da capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência. Em outras palavras, o software aprende, a partir dos eventos vistos anteriormente, a resolver problemas similares aos de sua base de conhecimento melhorando sua eficiência de acordo com a quantidade e a qualidade dos exemplos apresentados a ele.

Os modelos inteligentes baseados em AM são beneficiados pela aplicação de algoritmos de PDS, mesmo que seja possível passar dados sem processamento para o modelo, geralmente um modelo treinado com dados enriquecidos obtém um melhor desempenho (ZHANG; ZHANG; YANG, 2003). Sinais ECGs são suscetíveis a ruído e artefatos que afetam o formato de onda e a precisão da análise, portanto técnicas de processamento de sinais robustas se mostram necessárias para uma interpretação confiável (ANSARI *et al.*, 2023).

### 2.3.1 Tipos de Aprendizado

Os tipos de aprendizado divergem entre si em vários aspectos, dentre eles o formato da base de conhecimento, avaliação da eficiência do modelo inteligente e tipos de problemas capazes de serem resolvidos. Entre eles podem ser definidos 3 tipos principais de aprendizado de máquina: *Aprendizado Supervisionado*, *Aprendizado Não-Supervisionado* e *Aprendizado por Reforço* (LUDERMIR, 2021).

O *Aprendizado Supervisionado* envolve a aprendizagem de um modelo a partir dos exemplos de suas entradas e saídas. Da classificação de conteúdo em imagens e detecção de eventos sonoros são problemas clássicos deste tipo de aprendizado, no contexto deste trabalho a detecção de arritmia cardíaca está contida neste tipo de aprendizado, mais especificamente em classificação supervisionada.

O *Aprendizado Não-Supervisionado* envolve a aprendizagem de padrões nos eventos da base de conhecimento, quando não são fornecidos valores de saída específicos. Por exemplo, uma loja de departamentos pode agrupar diferentes tipos de clientes que a frequentam, a partir de suas preferências de compra.

O *Aprendizado por Reforço*, neste tipo um agente inteligente deve aprender uma política a partir de do sucesso e do fracasso, obtendo recompensas e castigos de acordo com suas ações. Por exemplo, no jogo de xadrez, o modelo inteligente iria ter como entrada as regras do jogo, jogar e no fim iria receber sua recompensa ou punição de acordo com seu desempenho.

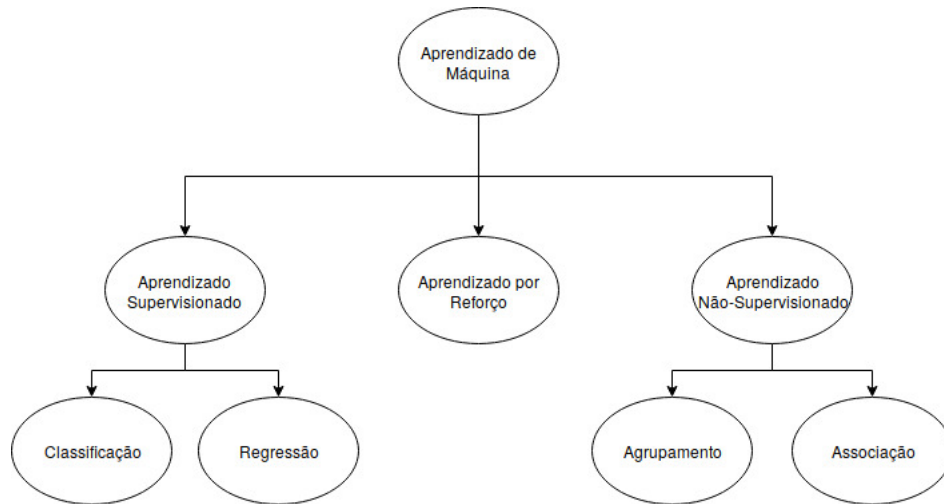


Figura 4 – Tipos de Aprendizado de Máquina

### 2.3.2 Aprendizado Supervisionado

O aprendizado supervisionado, como dito anteriormente, trata da tentativa do encontro do modelo que melhor descreve o domínio que se está tratando, tendo suas entradas em forma de características do problema e sua saída em forma de uma ou mais classes ou valor numérico. A forma da saída varia de acordo com o tarefa em questão, que são a classificação e regressão (BRINK; RICHARDS; FETHEROLF, 2016).

### 2.3.3 Classificação Supervisionada

Nesta tarefa, o modelo possui o objetivo de, a partir dos exemplos na base de dados, realizar a inferência de qual classe ou categoria o novo exemplo melhor se encaixa ou se assemelha, com este exemplo sendo classificado com uma ou mais das classes conhecidas (LUDERMIR, 2021).

Neste tipo de tarefa, o modelo inteligente é treinado com as características dos exemplos do domínio de interesse e com sua(s) classe(s), se ajustando de acordo com o erro que apresenta.

Dentre as abordagens de modelos baseados em classificação supervisionada temos os métodos simbólicos, conexionistas, genéticos e estocásticos para aprendizado de máquina (LUGER, 2013). De acordo com Ansari et al. os modelos conexionistas são os que vêm apresentando os resultados no estado do arte nas tarefas de detecção e classificação de arritmia a partir de sinais ECG.

### 2.3.4 Modelos Conexionistas

Modelos neurais ou sistemas conexionistas utilizam de sistemas de componentes simples por meio de um processo de adaptação pelo qual as conexões entre os componentes




Figura 5 – Exemplo de Classificação.  
Fonte: (COCK, 2015)

são ajustadas, portanto o processamento nesses sistemas é distribuído por meio de conjuntos de camadas de neurônios artificiais (LUGER, 2013).

## 2.4 Redes Neurais Artificiais

Em (BRAGA; FERREIRA; LUDERMIR, 2007), é descrito que as Redes Neural Artificiais, ou simplesmente RNA, são sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). RNAs são modelos inteligentes baseados em Aprendizado de Máquina Conexionista que passam pela fase de aprendizagem, em que o conjunto de exemplos é apresentado para a rede, a qual extrai características necessárias para representar a informação fornecida.

### 2.4.1 Neurônio Artificial

O modelo proposto por Rosenblatt em (ROSENBLATT, 1958), conhecido como *perceptron*, ou neurônio artificial, era composto por um conjunto de variáveis de entrada, um conjunto de pesos vinculado a cada variável de entrada e por uma função de ativação. Embora essa topologia original possuía três níveis, ela é conhecida como perceptron de camada única, já que somente o nível de saída apresenta propriedades adaptativas.

O neurônio possui a limitação de que somente é possível ter um bom desempenho se o problema em que ele está sendo utilizado for linearmente separável e para situações não linearmente separáveis com o XOR não é possível de ser solucionado com um único neurônio (NITTA, 2003). Para resolver este problema, foram propostas as Rede Perceptron de Múltiplas Camadas.

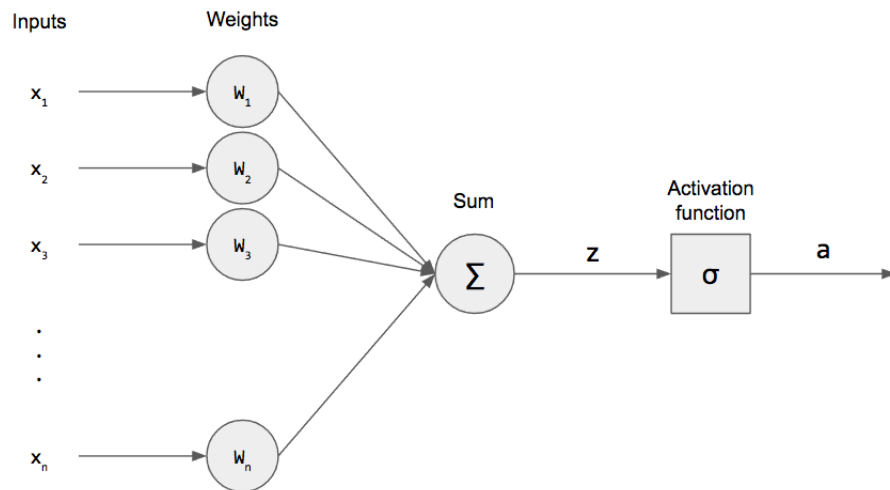


Figura 6 – Neurônio Perceptron.  
Fonte: (DUKOR, 2018)

#### 2.4.2 Redes Perceptron de Múltiplas Camadas

As Redes Perceptron de Múltiplas Camadas (MLP, do inglês *multilayer perceptron*) apresentam uma ou mais camadas intermediárias de neurônios artificiais e uma camada de saída (FACELI *et al.*, 2011). Segundo Cybenko em (CYBENKO, 1989), uma rede com uma camada intermediária pode implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função (DUDA; HART; STORK, 2012).

Neste modelo inteligente, a rede possui 3 partes fundamentais: a camada de entrada, uma ou mais camadas ocultas e a camada de saída. A camada de entrada é onde as características presentes na base de conhecimento serão apresentadas à rede MLP, então estes atributos de entrada são processados nas camadas ocultas e a rede apresenta uma resposta na camada de saída, é comum que o número de neurônios na camada de saída esteja associado a uma das classes presentes no conjunto de dados (caso seja um problema de classificação) e tenha apenas 1 neurônio se for uma tarefa de regressão (FACELI *et al.*, 2011).

Para treinamento de redes neurais em problemas de classificação supervisionada é mais comum que seja usado o algoritmo de retro-propagação proposto por (RUMELHART *et al.*, 1988).

#### 2.4.3 Algoritmo Retro-propagação

O Algoritmo de Retro-propagação, por ser supervisionado, utiliza pares de entradas e saídas para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Essas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para




Figura 7 – Rede Neural de Múltiplas Camadas

definir a saída da rede para um exemplo de entrada a partir de uma função de ativação. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões (BRAGA; FERREIRA; LUDERMIR, 2007).

Apesar de uma rede neural com duas camadas ter a capacidade de aproximar qualquer função, alguns problemas reais estão em espaços dimensionais maiores ou terem a necessidade de um tratamento de dados diferente, por exemplo, em imagens a localização espacial dos *pixels* faz diferença durante a classificação da mesma. Dessa forma se faz necessário tomar algumas alternativas, como por exemplo aumentar o número de camadas ocultas, aumentar o número de neurônios nas camadas ou aplicar algum pré-processamento nos dados de entrada para que então possam ser passados para a RNA.

#### 2.4.4 Função de Ativação

As funções de ativação são funções que determinam o que um neurônio irá passar durante a fase *forward* para o neurônio seguinte e para calcular o erro da rede durante a fase *backward*. As 4 mais usadas são a Sigmóide, Tangente Hiperbólica, ReLU(*Rectified Linear Unit*) e Softmax (BRAGA; FERREIRA; LUDERMIR, 2007).

A função Sigmóide, usa da Equação 2.1:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$

Intuitivamente, significa que quando o logit é pequeno, a saída da função é muito próxima a 0. Quando o logit é grande, a saída fica perto de 1. Entre esses dois extremos, a função assume um formato de S.



A função Tangente Hiperbólica possui um formato similar, no entanto em vez de variar de 0 a 1, ela varia entre -1 e 1 e possui a Equação 2.2.

$$f(x) = \tanh(x) \quad (2.2)$$

A função ReLU, retorna o maior número entre a saída do neurônio e 0, tendo a Equação 2.3.

$$f(x) = \max(0, x) \quad (2.3)$$

Softmax, Softargmax ou Função Exponencial Normalizada é uma função que possui uma vetor de N posições de números reais como argumento de entrada e normaliza em uma distribuição de probabilidades consistentes de N probabilidades proporcional ao número de entradas. Isto é, antes de aplicar a softmax, o vetor pode ter quaisquer valores arbitrários, no entanto após a aplicação do softmax os valores somarão 1, assim podem ser interpretados como probabilidades (BISHOP, 2006), a fórmula desta função de ativação se dá por Equação 2.4 .

$$\sigma(x_j) = \frac{e^{x_j}}{\sum_i e^{x_i}} \quad (2.4)$$

#### 2.4.5 Aprendizado Profundo

Aprendizado Profundo (do inglês *Deep Learning*) é uma sub-área de Aprendizado de Máquina e da Inteligência Artificial, como ilustrado na Figura 8, que emprega algoritmos para processar dados e imitar o processamento feito pelo cérebro humano. Foi a partir desta área do conhecimento que tornou-se possível grandes avanços nas áreas de visão computacional, reconhecimento de fala, processamento de linguagem natural e reconhecimento de áudio (DSA, 2019).



Figura 8 – Aprendizado Profundo. Fonte: (CONSULTING, 2018)

### 2.4.6 Rede Neural Convolucional

As Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Networks*) são modelos derivados das RNAs com um pré-processamento inspirado no córtex visual de animais, muitos populares para abordar o tema de visão computacional (VASCONCELOS; CLUA, 2017).

A diferença entre uma CNN e uma RNA convencional é usarem de camadas convolucionais, cujas unidades realizam uma operação de convolução cujo filtro é aprendido durante a otimização da rede, portanto difere de neurônios do tipo Perceptron, que produz uma combinação linear entre as entradas e um vetor de pesos (GOODFELLOW; BENGIO; COURVILLE, 2017). Em questão estrutural a CNN possui uma RNA, a diferença consta no pré-processamento dos dados que são entregues a rede neural, os dados passam pelos filtros convolucionais e então por camadas de redução de dimensionalidade para então os dados serem passados para a RNA de fato, como pode ser visto na Figura 9.




Figura 9 – Arquitetura de uma Rede CNN. Adaptado de (VEEN, 2016)

As camadas de redução de dimensionalidade, também conhecidas como camadas de *pooling*, tem como função substituir a saída da camada convolucional com uma estatística calculada a partir das saídas adjacentes (GOODFELLOW; BENGIO; COURVILLE, 2017), por exemplo a variação *Average Pooling* retorna a média das saídas dentro de uma vizinhança retangular. Uma ilustração pode ser visualizada na Figura 10.




Figura 10 – Ilustração de uma operação *Average Pooling*. Fonte: (KHOSLA, 2023)

#### 2.4.7 Transferência de Aprendizado

A arquitetura CNN é uma das mais conhecidas atualmente tanto para problemas de visão computacional e pode ser utilizada sem grandes perdas de performance em problemas de processamento de sinais. Porém, o seu uso apresenta alguns desafios como necessidade de poder computacional para treinar os milhares de parâmetros pertencentes a rede e necessidade de uma base de dados grande e robusta o suficiente para que não haja sub-ajuste do modelo aos dados. Segundo Silva (2018) , a capacidade de convergência de uma CNN é influenciada pela inicialização de seus pesos ao iniciar o seu treinamento. Por isso, a etapa de definir valores iniciais é importante para obtenção de bons resultados, ainda que acabe tornando-se subjetiva a depender do conhecimento de quem a manipula (SANTOS *et al.*, 2019).

Uma das soluções propostas é o uso de pesos obtidos a partir de um treinamento prévio em outro banco de dados para inicializar um novo modelo. Essa abordagem é conhecida como transferência de aprendizado. Dessa maneira, a inicialização dos pesos é efetiva e o modelo pode convergir mais rápido exigindo menos dados, além de poder ser utilizado para problemas que compartilham similaridades (SANTOS *et al.*, 2019; VOGADO *et al.*, 2019). Utilizando desta solução é possível diminuir a necessidade de retrainar todos os parâmetros, bem como utilizar as configurações já existentes na rede previamente (YOSINSKI *et al.*, 2014).

Várias arquiteturas CNN foram treinadas no banco de imagens *ImageNet* (DENG *et al.*, 2009), um banco de dados com mais de 15 milhões de imagens separadas em mais de 22 mil classes proposto em 2009. Esses pesos podem ser reutilizados em outros modelos para classificar outras bases de dados, ao invés de inicializar os pesos com valores gerados de forma aleatória.

Existem duas formas principais de se utilizar a transferência de aprendizado. A primeira compreende na extração das camadas densas originais e no congelamento do restante das camadas com seus respectivos pesos e então adicionar outra configuração de camadas densas. A segunda forma de transferência de aprendizado é o ajuste fino que exige o retrainamento de toda ou parte da rede original com os novos dados. Para o contexto deste trabalho estaremos utilizando da primeira abordagem.

#### 2.4.8 Arquiteturas CNN para transferência de aprendizado

Pesquisas na área de aprendizado profundo para classificação de imagens começou em 2012 com a introdução da AlexNet, a qual introduziu a camada de ativação ReLU (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). A exploração desse tipo de rede neural alcançou resultados mais precisos e eliminou a análise de cada imagem baseada em engenharia de recursos. Logo, outras arquiteturas apareceram, tais como, ResNet, MobileNet, e outras, as quais introduziram características eficientes para classificação de imagens.

### 2.4.8.1 VGG

Proposta em 2014 por Simonyan e Zisserman, venceu a competição ImageNet daquele ano com acurácia Top 5 de 92.7%, em seu trabalho propuseram seu uso com variação de profundidade de 16 ou 19 camadas com aproximadamente 138 milhões de parâmetros. Uma visão geral de sua estrutura pode ser visualizada na Imagem 11. Na construção deste modelo, foi levado em consideração o uso de filtros convolucionais 3x3 e camadas de pooling de 2x2 ao longo de toda a sua arquitetura em detrimento do tamanho do modelo.




Figura 11 – Arquitetura VGG16

### 2.4.8.2 ResNet

ResNet, também conhecida como rede residual, foi apresentada por He et al. (2016) quando venceu a competição ImageNet daquele ano com acurácia Top 5 de 94.29% utilizando aproximadamente um total de 25 milhões de parâmetros. Comparada a outras arquiteturas, como a Inception, ela acaba sendo muito mais “profunda”, pois ela pode atingir até 152 camadas. A ResNet possui uma conexão única chamada de conexão residual, que é uma conexão aplicada entre as camadas convolucionais que garante que durante a execução da retropropagação, os pesos aprendidos das camadas anteriores não sejam diminuídos o decaimento do gradiente. O principal benefício desta rede é o uso destas conexões, pois possibilita a utilização de muitas camadas, além de diminuir a quantidade de parâmetros extras. As principais desvantagens são a utilização de tamanhos únicos para filtros para que possa ser efetuada a soma em cada bloco residual e a necessidade de

treinamento com grandes conjuntos de dados. Três versões desta rede foram apresentadas e elas diferem no número de camadas: ResNet50, ResNet101 e ResNet152.

#### 2.4.8.3 MobileNet

O modelo MobileNet foi proposta por Howard (2017) e é uma arquitetura de rede neural convolucional projetada para ser leve e eficiente para aplicativos de visão móveis e integrados. Difere de outros modelos em termos de design e casos de uso devido às suas características e vantagens únicas.

Ao utilizar convoluções separáveis em profundidade, o modelo MobileNet alcança um bom equilíbrio entre precisão e eficiência. Ele pode alcançar uma precisão semelhante a modelos maiores e mais caros computacionalmente, exigindo menos recursos, tornando-o adequado para dispositivos com recursos limitados, como telefones celulares e sistemas integrados. Essa escolha de design permite inferência em tempo real em dispositivos com poder computacional limitado.

Outra vantagem do modelo MobileNet é sua flexibilidade e escalabilidade. Ele oferece um parâmetro chamado "multiplicador de largura" que permite aos usuários negociar entre tamanho e precisão do modelo. Ao ajustar o multiplicador de largura, pode-se controlar o número de canais em cada camada da rede, aumentando ou diminuindo a escala do modelo. Essa flexibilidade permite que o modelo MobileNet seja facilmente personalizado para diferentes casos de uso e cenários de implantação, acomodando uma ampla gama de requisitos computacionais.



### 3 TRABALHOS RELACIONADOS

Diversos trabalhos vêm atuando na identificação automática de arritmia cardíaca em sinais ECG a partir de modelos inteligentes baseados em aprendizado de máquina, havendo uma tendência a utilização de aprendizado profundo nesta tarefa (ANSARI *et al.*, 2023), entre as arquiteturas mais utilizadas estão as Redes Neurais Convolucionais (CNN), Redes Neurais Recorrentes (RNN), Redes *Long Short-term Memory* (LSTM), Unidade Recorrente Fechada ou *Gated Recurrent Unit* (GRU), as Redes Profundas de Crenças ou *Deep Belief Network* e as redes *Transformers* (ANSARI *et al.*, 2023).

Em (HUANG *et al.*, 2019) é utilizado um modelo baseado em CNN a partir de espectrogramas para realizar a detecção de arritmia cardíaca em sinais ECG e as divide em 5 categorias Batimento Normal (NOR), Bloqueio do ramo esquerdo do feixe de His (LBB), Bloqueio do ramo direito do feixe de His (RBB), Contração Ventricular Prematuro (PVC) e Contração Atrial Prematura (APC).

Ng *et al.* (2023) adota uma abordagem de transferência de aprendizado num contexto *few-shot* para detecção de fibrilação atrial personalizada utilizando registros ECG dos pacientes com um modelo baseado em redes neurais siamesas.

Já Kumar *et al.* (2022) propõe um modelo híbrido para detecção de fibrilação atrial utilizando de camadas convolucionais 1D e em sequência camadas LSTM em cima dos sinais ECG puros numa abordagem de captura de sinais livres a partir de dispositivos vestíveis.





## 4 METODOLOGIA

Neste capítulo é descrita a metodologia utilizada no desenvolvimento deste trabalho. Na Seção 4.1 estão inclusos a *pipeline* proposta contendo o pré-processamentos dos dados, separação de treinamento e teste destes dados para os classificadores e então a comparação com o modelo *baseline*. Na Seção 4.2 será detalhado o tipo de dados utilizado pelos modelos para classificação de arritmia, passando pelas configurações de captura dos sinais ECG. Na Seção 4.3 serão detalhados os pré-processamentos utilizados para os sinais de ECG. Na Seção 4.4 será detalhado qual arquitetura, já estabelecida na literatura, foi considerada o *baseline* comparativo. Por fim, na Seção 4.5 serão detalhadas as topologias de redes profundas testadas para o problema.

### 4.1 Proposta

A proposta desse trabalho é utilizar os dados rotulados presentes em (KUMAR *et al.*, 2022b) no treinamento de modelos baseados em aprendizado profundo projetados a fim de obter um modelo capaz de identificar ausência ou ocorrência de arritmia cardíaca em um conjunto de dados formado por sinais ECG do paciente. Um diagrama da configuração dessa proposta, bem como a pipeline seguida neste trabalho, é ilustrada na Figura 12.

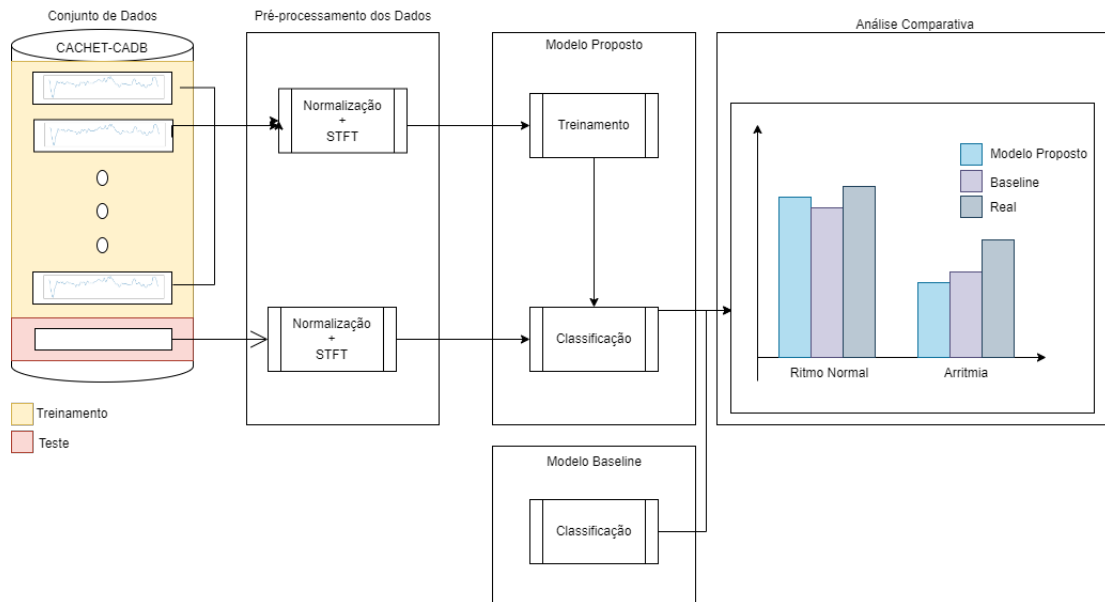


Figura 12 – *Pipeline* da Proposta.

Neste pipeline, será obtido o conjunto de dados formado por sinais de eletrocardiograma do paciente e divididos em treino e teste. Ambos os subconjuntos são pré-processados, sendo que os sinais ECG além de normalizados é calculado o STFT. Posterior ao pré-processamento, o modelo proposto será treinado utilizando o conjunto de dados de

treinamento e avaliados com o conjunto de teste. Por fim, o resultado obtido do modelo proposto será comparado ao resultado do baseline e uma análise será realizada.

## 4.2 Base de Dados

O conjunto de dados foi obtido a partir de Kumar et al. (2022) e consiste de 2 tipos diferentes de informações, o primeiro são os dados de ECG em paralelo a dados contextuais compostos de informações sobre a atividade que está sendo exercida pelo paciente, posicionamento do corpo (ex. deitado, em pé, sentado) e nível de estresse.

### 4.2.1 Eletrocardiograma

Os sinais ECG foram capturados ao longo de 259 dias de forma consensual de 24 pacientes e totalizam 1602 trechos de 10 segundos de sinais, capturados em uma frequência de 1024 Hz, sob condições livres de vida e locomoção e anotados por 2 cardiologistas qualificados em 4 classes distintas, sendo elas Fibrilação Atrial (FA), Ritmo Sinusal Regular (RSR), Ruído e Outro em que podem ser observadas nos trechos de sinais ECG do paciente P2 na Figura 13 e a distribuição das classes como um todo no conjunto de dados na Figura 14.

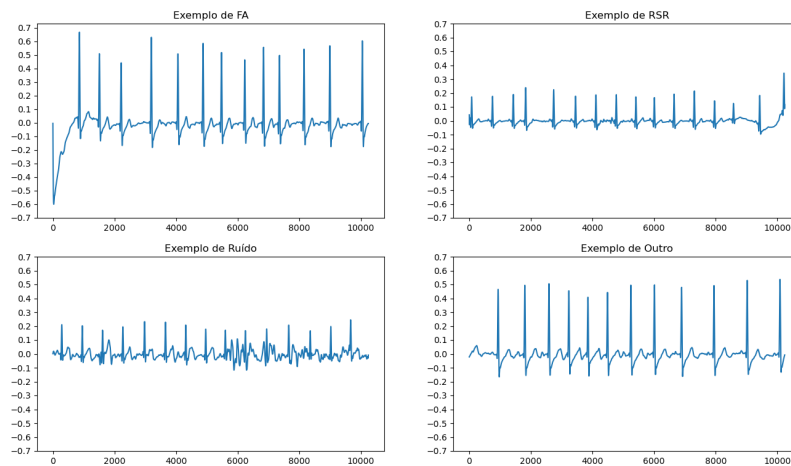


Figura 13 – Exemplos de ECG para as classes FA, RSR, Ruído e Outro para o paciente P2. Imagem criada pelo autor.

Com base na Figura 14, pode-se observar que as classes não são igualmente distribuídas, sendo que a classe FA representa cerca de 46.63% do conjunto de dados. Essa característica do conjunto de dados pode prejudicar o treinamento de um modelo computacionais baseado em aprendizado de máquina, pois as classes minoritárias podem acabar sendo ignoradas devido a sua baixa representatividade no conjunto total. Portanto deverão

ser levados em consideração alguns fatores para minimização deste desbalanceamento como o uso de diferentes pesos para as classes.




Figura 14 – Distribuição das classes de ECG. Imagem criada pelo autor.

### 4.3 Pré-processamentos

Neste trabalho a etapa de pré-processamento foi realizada levando em consideração somente os dados de eletrocardiograma da base de dados. O eletrocardiograma, como explicado em maiores detalhes na Sub-seção 2.2, foi aplicada a Transformada de Fourier de Tempo Curto (STFT) através das bibliotecas *Scipy*<sup>1</sup> e *Librosa*<sup>2</sup>.

#### 4.3.1 Processamento de Sinais

Para pré-processamento dos sinais ECG foi necessário transformar o dado em uma representação bi-dimensional. Assim, os sinais ECG foram transformados em espectrogramas 2D de tempo-frequência usando a STFT descrita na Equação 4.1, onde  $x[n]$  representa o sinal ECG e  $w[n]$  a função de janelamento. No método proposto, foi adotado o janelamento Hanning, no qual a definição se dá pela Equação 4.2 com tamanho de janela igual a 512, onde  $M$  se trata do número de amostras.

<sup>1</sup> <https://scipy.org>

<sup>2</sup> <https://librosa.org/doc/latest/index.html>

$$STFTx[n] = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (4.1)$$

$$w(n) = \begin{cases} 0.5 \cdot [1 - \cos(\frac{2\pi n}{M-1})], & \text{se } 0 \leq n \leq M-1 \\ 0, & \text{senão} \end{cases} \quad (4.2)$$

#### 4.4 Baseline

O modelo *baseline* utilizado foi o proposto (NG *et al.*, 2023), que é baseado em Redes Neurais Siamesas e foi utilizado para realizar a extração de características do sinal ECG e então passar para um classificador linear realizar a classificação da instância observada, sua arquitetura é apresentada na Figura 15.




Figura 15 – Arquitetura da modelo Baseline. Adaptada de (GUPTA; BHASKARPANDIT; GUPTA, 2021).

#### 4.5 Arquiteturas baseadas em Redes Profundas

Nesta Seção serão apresentadas as arquiteturas consideradas para treinamento e classificação dos sinais ECG, na Sub-seção 4.5.1 serão descritos quais arquiteturas fundacionais foram utilizadas para realizar a classificação dos sinais ECG transformados em espectrogramas como descrita na Seção 4.3.1.

##### 4.5.1 Modelos fundacionais

Os modelos funcionais, ou seja, aqueles em que foram utilizados as camadas de extração de características já treinadas a partir do ImageNet, foram as versões VGG16, ResNet50, ResNet152V2, NASNetLarge e MobileNet, disponibilizados de forma gratuita pela API do Keras<sup>3</sup> com um topo de rede comum composto por uma camada de achata-mento, 2 camadas densas de configurações [512, 256] e função de ativação *ReLU* e então uma camada de saída com 4 neurônios e função de ativação *Softmax* referente a cada uma das classes.

<sup>3</sup> <https://keras.io/api/applications/>

## 5 AVALIAÇÃO EXPERIMENTAL

Neste capítulo está descrita a avaliação experimental deste trabalho. Na Seção 5.1 será apresentada a configuração experimental padrão para todos os modelos inteligentes treinados para classificação de arritmias cardíacas a partir de sinais ECG, sendo estes apresentados nas sub-seções adequadas. Por fim, na Seção 5.3 será apresentada uma tabela comparativa dos modelos avaliados ao lado da linha de base a partir das métricas Precisão, Revocação e *F1-Score*.

### 5.1 Configuração Experimental

Os testes foram realizados a partir de uma configuração experimental padrão a todas as arquiteturas baseadas em CNN avaliadas, sendo composto um vetor de entrada composto de 1602 exemplos de sinais ECG, que então foi inicialmente filtrado a partir de filtro *Butterworth* a fim de eliminar possíveis ruídos para então ser normalizado entre 0 e 1 e então calculado a STFT para cada sinal como detalhado na Sub-seção 4.3.1.

Para fim de treinamento e avaliação do modelo foi separado 1 paciente por vez para ser o conjunto de teste e os sinais dos demais foram utilizados para treinamento dos modelos, resultado em 24 treinamentos e avaliações de modelos totalizando ao final 1602 classificações para cada arquitetura considerada.

A avaliação então foi feita em 2 momentos sendo o primeiro a partir da análise do relatório de classificação e da matriz de confusão a fim de verificar a distribuição de erros dos modelos entre as 4 classes, estes serão apresentados na sub-seções seguintes, e por fim o cálculo das métricas de performance Precisão, Revocação e *F1-Score* que serão apresentadas na Seção 5.3.

#### 5.1.1 Configuração Padrão de Topo de Rede Neural

Como características padrões para as 5 arquiteturas de redes neurais convolucionais profundas que foram avaliadas nos experimentos deste capítulo podemos citar o uso de 3 chamadas de sistema durante o treinamento dos modelos e 1 topo de camadas densas e de saída comuns a todas as arquiteturas consideradas.

Sobre as chamadas de sistemas foram elas: 1) parada antecipada (*early stopping*) monitorando a perda de validação com uma paciência de épocas, ou seja, se o modelo não apresentar melhorias na variável monitorada durante 10 épocas de treinamento, este será encerrado mesmo que não tenha alcançado o número de épocas máximo de 100; 2) ponto de verificação (*checkpoint*) que salva o modelo em disco após uma época em que a perda de validação foi reduzida, esta gravação é realizada se e somente se a perda de

validação for reduzida não havendo reescrita de arquivo em caso de deterioração desta métrica; e 3) Redução de Taxa de Aprendizado num Platô novamente monitorando a perda de validação, com paciência de 4 épocas para uma redução de 50% do valor atual, ou seja, se for detectado que nas últimas 4 épocas não houve melhora na métrica de perda de validação, então o valor da taxa de aprendizado é reduzido pela metade.

Em questão de alterações de arquitetura dos modelos, após a camadas de extração de características de cada arquitetura foi acrescentada uma camada de achatamento (*Flatten*), uma camada densa com 512 neurônios e função de ativação ReLU, uma camada densa com 256 neurônios e função de ativação ReLU e por fim uma camada de saída com 4 neurônios e função de ativação softmax a fim de resultar na classe inferida.

Para compilação do modelo foi considerado o otimizador Adam Ponderado, função de perda entropia cruzada categórica e métricas de monitoramento acurácia e perda do modelo ao longo das épocas de treinamento.

Por fim todas as arquiteturas foram avaliadas segundo seus relatórios de classificação, matriz de confusão, precisão, revocação e F1-Score para cada 1 dos 24 sujeitos da base de dados sob um regime de treinamento e avaliação de treinamento de 23 sujeitos e o último para teste.

### 5.1.2 Arquitetura VGG16

A primeira arquitetura avaliada foi a VGG16 que apresentou nos seus relatórios de classificação e matriz de confusão os resultados apresentados nas tabelas 1 e 2, respectivamente, após treinamento e inferência sobre cada paciente.

	Precisão	Revocação	F1-Score	Número de Exemplos
FA	0.96	0.96	0.96	747
RSR	0.90	0.97	0.93	615
Ruído	0.98	0.85	0.91	221
Outro	1.00	0.16	0.27	19
Acurácia			0.94	1602
Média Macro	0.96	0.73	0.77	1602
Média Ponderada	0.94	0.94	0.93	1602

Tabela 1 – Relatório de Classificação do modelo VGG16

	FA	RSR	Ruído	Outro
FA	714	33	0	0
RSR	16	598	1	0
Ruído	7	26	188	0
Outro	5	9	2	3

Tabela 2 – Matriz de confusão do modelo VGG16

### 5.1.3 Arquitetura ResNet50

A segunda arquitetura avaliada foi a ResNet50 que apresentou nos seus relatórios de classificação e matriz de confusão os resultados apresentados nas tabelas 3 e 4, respectivamente, após treinamento e inferência sobre cada paciente.

	Precisão	Revocação	F1-Score	Número de Exemplos
FA	0.97	0.87	0.92	747
RSR	0.79	0.99	0.88	615
Ruído	0.99	0.71	0.83	221
Outro	1.00	0.21	0.35	19
Acurácia			0.88	1602
Média Macro	0.94	0.69	0.74	1602
Média Ponderada	0.90	0.88	0.88	1602

Tabela 3 – Relatório de Classificação do modelo ResNet50

	FA	RSR	Ruído	Outro
FA	648	99	0	0
RSR	7	607	1	0
Ruído	7	56	158	0
Outro	5	10	0	4

Tabela 4 – Matriz de confusão do modelo ResNet50

### 5.1.4 Arquitetura ResNet152V2

A terceira arquitetura avaliada foi a ResNet152V2 que apresentou nos seus relatórios de classificação e matriz de confusão os resultados apresentados nas tabelas 5 e 6, respectivamente, após treinamento e inferência sobre cada paciente.

	Precisão	Revocação	F1-Score	Número de Exemplos
FA	0.95	0.95	0.95	747
RSR	0.93	0.94	0.93	615
Ruído	0.95	0.97	0.96	221
Outro	0.83	0.26	0.40	19
Acurácia			0.94	1602
Média Macro	0.91	0.78	0.81	1602
Média Ponderada	0.94	0.94	0.94	1602

Tabela 5 – Relatório de Classificação do modelo ResNet152V2

### 5.1.5 Arquitetura NASNetLarge

A NASNetLarge foi a quarta arquitetura avaliada e apresentou nos seus relatórios de classificação e matriz de confusão os resultados apresentados nas tabelas 7 e 8, respectivamente, após treinamento e inferência sobre cada paciente.

	FA	RSR	Ruído	Outro
FA	707	34	6	0
RSR	34	577	3	1
Ruído	3	3	215	0
Outro	4	8	2	5

Tabela 6 – Matriz de confusão do modelo ResNet152V2

	Precisão	Revocação	F1-Score	Número de Exemplos
FA	0.92	0.76	0.83	747
RSR	0.75	0.92	0.82	615
Ruído	0.96	0.95	0.95	221
Outro	0.60	0.47	0.53	19
Acurácia			0.84	1602
Média Macro	0.81	0.77	0.78	1602
Média Ponderada	0.85	0.84	0.84	1602

Tabela 7 – Relatório de Classificação do modelo NASNetLarge

	FA	RSR	Ruído	Outro
FA	564	180	2	1
RSR	42	565	5	3
Ruído	5	5	209	2
Outro	4	5	1	9

Tabela 8 – Matriz de confusão do modelo NASNetLarge

### 5.1.6 Arquitetura MobileNet

Por fim, a MobileNet foi a quinta e última arquitetura avaliada, apresentando nos seus relatórios de classificação e matriz de confusão os resultados apresentados nas tabelas 9 e 10, respectivamente, após treinamento e inferência sobre cada paciente.

	Precisão	Revocação	F1-Score	Número de Exemplos
FA	0.99	0.94	0.96	747
RSR	0.92	0.98	0.95	615
Ruído	0.99	0.98	0.98	221
Outro	1.00	0.63	0.77	19
Acurácia			0.96	1602
Média Macro	0.97	0.88	0.92	1602
Média Ponderada	0.96	0.96	0.96	1602

Tabela 9 – Relatório de Classificação do modelo MobileNet

## 5.2 Análise de classificação Intra-usuário

Para este experimento foi utilizada a arquitetura da MobileNet para se analisar seus resultados de forma usuário por usuário, tendo em vista que objetiva-se uma alta



	FA	RSR	Ruído	Outro
FA	701	45	1	0
RSR	8	605	2	0
Ruído	0	5	216	0
Outro	2	5	0	12

Tabela 10 – Matriz de confusão do modelo MobileNet

performance intra-usuário, assim os resultados para cada usuário pode ser visualizado na Tabela 11, a tabela apresenta então o resultado do modelo MobileNet para cada um dos 24 pacientes presentes na base de dados mostrando a quantidade de exemplos por classe (Suporte), a métrica F1-Score para cada classe, se houver, e então a Acurácia geral do paciente em questão, quando não houver casos para aquela classe nos registros do Paciente será considerado "Não se aplica"(n.a.).

Paciente	Suporte	FA	RSR	Ruído	Outro	Acurácia
P01	208	1.0	n.a.	1.0	1.0	1.0
P02	70	0.67	0.99	1.0	1.0	0.99
P03	139	0.98	n.a.	1.0	n.a.	0.96
P04	20	0.92	0.92	1.0	n.a.	0.95
P05	91	0.99	n.a.	1.0	n.a.	0.98
P06	44	1.00	0.99	n.a.	0.86	0.98
P07	82	0.93	0.99	1.0	1.0	0.99
P08	33	n.a.	1.0	1.0	n.a.	1.0
P09	107	n.a.	0.98	0.67	0.0	0.96
P10	32	n.a.	1.0	1.0	n.a.	1.0
P11	75	n.a.	n.a.	n.a.	1.0	1.0
P12	25	n.a.	1.0	1.0	n.a.	1.0
P13	31	1.0	1.0	1.0	1.0	1.0
P14	94	n.a.	1.0	1.0	n.a.	1.0
P15	95	0.98	n.a.	n.a.	n.a.	0.98
P17	178	0.99	n.a.	1.0	n.a.	0.99
P18	118	n.a.	1.0	1.0	n.a.	1.0
P19	54	1.0	1.0	1.0	n.a.	1.0
P21	10	n.a.	1.0	1.0	1.0	1.0
P23	14	n.a.	1.0	1.0	n.a.	1.0
PNSR-1	18	n.a.	0.91	0.96	n.a.	0.94
PNSR-3	33	n.a.	0.98	1.0	n.a.	0.97
PNSR-4	31	n.a.	0.98	1.0	n.a.	0.97

Tabela 11 – Avaliação MobileNet por Paciente.

### 5.3 Resultados e Discussões

Tendo sido treinados e avaliados com os mesmos conjuntos de dados pré-processados, o modelo *Baseline* e os modelos profundos baseados em transferência de aprendizado tem seus resultados comparadas na tabela 12.

Arquitetura	Precisão (%)	Revocação (%)	F1-Score (%)
<i>Baseline</i>	96.11	81.82	88.39
VGG16	96.11	73.42	76.95
ResNet50	93.79	69.50	74.28
ResNet152V2	91.44	78.02	81.02
NASNetLarge	80.71	77.33	78.42
MobileNet	<b>97.22</b>	<b>88.28</b>	<b>91.67</b>

Tabela 12 – Tabela Comparativa entre modelos avaliados

Esse resultado mostra que a MobileNet obteve maiores F1-Score entre todas as arquiteturas testadas sob as mesmas condições de pré-processamento, arquitetura, treinamento e avaliação. Este é um resultado curioso devido ao fato de ser a rede de menor profundidade entre as baseadas em transferência de aprendizado, isso pode ter sido uma vantagem já que devido ao fato da base de dados ter poucos exemplos, apenas 1602, não seria possível treinar um modelo profundo sem uso de transferência de aprendizado com uma performance considerável, como foi o caso com o modelo *Baseline*.

Interessante também notar que não só a MobileNet superou as demais arquiteturas num contexto global como também no contexto local de cada uma das classes consideradas, obtendo um desempenho de 0.96 na classe Fibrilação Atrial (FA), 0.95 na classe Ritmo Sinusal Regular (RSR), 0.98 na classe Ruído e 0.77 na classe Outro.

Ainda vale notar que a classe Outro e Ruído não tem um comportamento padrão como as classes Fibrilação Atrial (FA) e Ritmo Sinusal Regular (RSR), já que são classes que indicam ou erro de leitura ou ocorrência de outros fenômenos que não comportam nas demais classes, em especial a classe Outro gerou resultados baixos para todos os modelos, isso pode ser devido ao fato de se ter uma baixa representatividade de exemplos num geral, representado apenas 0.74% da base total, como pelo seu comportamento irregular.

## 6 CONCLUSÕES

Através do estudo de arquiteturas e técnicas na literatura combinado com diversos testes e análises foi possível obter uma rede rasa capaz de atingir uma acurácia de 94.42% na classificação de sinais de eletrocardiograma em: Fibrilação Atrial, Ritmo Sinusal Regular, Ruído e Outro.

O uso de transferência de aprendizado não só proporcionou uma maior robustez da rede, mas também mitigou o problema do desbalanceamento de classes que existia no conjunto de treinamento. Um indicativo desse último resultado foi sua capacidade de obter um bom valor de acurácia para todas as classes e não se ajustando somente para a classe majoritária (Fibrilação Atrial).

A fim de avaliar os modelos propostos, foi considerado um *baseline* para referência. Esse *baseline* simplesmente consistiu em modelo de rede neural convolucional treinado com as janelas STFT extraídas do conjunto de dados. A comparação resultou em um F1-Score de 3.28% maior para o modelo MobileNet em relação ao modelo *baseline*, indicando que sua configuração e treinamento foram satisfatórios.

Um ponto evidenciado é a baixa performance obtida não só pelo MobileNet, em classificar as classes Ruído e Outro já que estes não apresentam um comportamento padrão e não há exemplos suficientes para entender bem os diferentes fenômenos.

Um próximo passo desse trabalho seria considerar os dados contextuais para realizar a classificação do evento, já que podem trazer maior entendimento do que está ocorrendo com o usuário naquele momento, detectando posições do corpo, entendimento de variações no estado da pessoa visto que o comportamento do sinal ECG de uma pessoa deitada é diferente da mesma pessoa correndo mas não indica que está ocorrendo uma irregularidade no comportamento de seu coração. Nesse caso teria que treinar outro modelo para este propósito e considerar como realizar a comunicação entre os modelos finais a fim de haver essa interação entre variáveis contextuais e sinais eletrocardiográficos.



## REFERÊNCIAS

- ABAWAJY, J. H.; KELAREV, A. V.; CHOWDHURY, M. Multistage approach for clustering and classification of ecg data. **Computer methods and programs in biomedicine**, Elsevier, v. 112, n. 3, p. 720–730, 2013.
- ANSARI, Y. *et al.* Deep learning for ecg arrhythmia detection and classification: an overview of progress for period 2017–2023. **Frontiers in Physiology**, Frontiers, v. 14, p. 1246746, 2023.
- BISHOP, C. M. **Pattern recognition and machine learning**. [*S.l.: s.n.*]: Springer Science+ Business Media, 2006.
- BRAGA, A. d. P.; FERREIRA, A. C. P. de L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. [*S.l.: s.n.*]: LTC Editora Rio de Janeiro, Brazil, 2007.
- BRINK, H.; RICHARDS, J.; FETHEROLF, M. **Real-world machine learning**. [*S.l.: s.n.*]: Simon and Schuster, 2016.
- CARNEIRO, B. V. *et al.* Arritmias: fisiopatologia, quadro clínico e diagnóstico. **Revista de Medicina e Saúde de Brasília**, v. 1, n. 2, 2012.
- COCK, B. **C-3PO, PhD: Machine Learning in Astronomy**. 2015. Available at: <<https://astrobites.org/2015/04/15/c-3po-phd-machine-learning-in-astronomy/>>.
- CONSULTING, B. **O que esperar da AI para o futuro das organizações?** 2018. Available at: <<https://bridgeconsulting.com.br/insights/o-que-esperar-da-ai-para-o-futuro-das-organizacoes/>>.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of control, signals and systems**, Springer, v. 2, n. 4, p. 303–314, 1989.
- DENG, J. *et al.* Imagenet: A large-scale hierarchical image database. *In*: IEEE. **2009 IEEE conference on computer vision and pattern recognition**. [*S.l.: s.n.*], 2009. p. 248–255.
- DSA, D. S. A. **Deep Learning Book**. 2019. Available at: <<http://deeplearningbook.com.br/>>.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. [*S.l.: s.n.*]: John Wiley & Sons, 2012.
- DUKOR, S. O. **Neural Representation of AND, OR, NOT, XOR and XNOR Logic Gates (Perceptron Algorithm)**. 2018. Available at: <<https://medium.com/@stanleydukor/neural-representation-of-and-or-not-xor-and-xnor-logic-gates-perceptron-algorithm-b0275375fea1>>.
- EBRAHIMI, Z. *et al.* A review on deep learning methods for ecg arrhythmia classification. **Expert Systems with Applications: X**, Elsevier, v. 7, p. 100033, 2020.
- FACELI, K. *et al.* Inteligência artificial: Uma abordagem de aprendizado de máquina. 2011.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning. adaptive computation and machine learning. **Massachusetts, USA**, 2017.

GUPTA, P.; BHASKARPANDIT, S.; GUPTA, M. Similarity learning based few shot learning for ecg time series classification. *In: IEEE. 2021 Digital Image Computing: Techniques and Applications (DICTA)*. [S.l.: s.n.], 2021. p. 1–8.

H9J. **Cardiologia (adulto e infantil)**. 2020. Available at: <<https://www.h9j.com.br/pt/pacientes-e-visitantes/cardiologia>>.

HAYKIN, S. S.; VEEN, B. V. **Sinais e sistemas**. [S.l.: s.n.]: Bookman, 2001.

HE, K. *et al.* Deep residual learning for image recognition. *In: Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.

HE, K. *et al.* Identity mappings in deep residual networks. *In: SPRINGER. Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*. [S.l.: s.n.], 2016. p. 630–645.

HOWARD, A. G. Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017.

HUANG, J. *et al.* Ecg arrhythmia classification using stft-based spectrogram and convolutional neural network. **IEEE access**, IEEE, v. 7, p. 92871–92880, 2019.

KHOSLA, S. **CNN | Introduction to Pooling Layer**. 2023. Available at: <<https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>>.

KINGSLEY, M.; LEWIS, M.; MARSON, R. Comparison of polar 810 s and an ambulatory ecg system for rr interval measurement during progressive exercise. **International journal of sports medicine**, © Georg Thieme Verlag KG Stuttgart · New York, v. 26, n. 01, p. 39–44, 2005.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. 2012 alexnet. **Adv. Neural Inf. Process. Syst.**, p. 1–9, 2012.

KUMAR, D. *et al.* Deepaware: A hybrid deep learning and context-aware heuristics-based model for atrial fibrillation detection. **Computer Methods and Programs in Biomedicine**, Elsevier, v. 221, p. 106899, 2022.

KUMAR, D. *et al.* Cachet-cadb: A contextualized ambulatory electrocardiography arrhythmia dataset. **Frontiers in Cardiovascular Medicine**, Frontiers, v. 9, p. 893090, 2022.

KUMAR, M.; PACHORI, R. B.; ACHARYA, U. R. Characterization of coronary artery disease using flexible analytic wavelet transform applied on ecg signals. **Biomedical signal processing and control**, Elsevier, v. 31, p. 301–308, 2017.

KUTLU, Y.; KUNTALP, D. A multi-stage automatic arrhythmia recognition and classification system. **Computers in biology and medicine**, Elsevier, v. 41, n. 1, p. 37–45, 2011.

- LAVOISIER, L. e. I. **ELETROCARDIOGRAMA: O QUE É E COMO É FEITO O EXAME ECG**. 2021. Available at: <<https://lavoisier.com.br/saude/blog/eletrocardiograma>>.
- LIN, C.-W.; WANG, J.-S.; CHUNG, P.-C. Mining physiological conditions from heart rate variability analysis. **IEEE Computational Intelligence Magazine**, IEEE, v. 5, n. 1, p. 50–58, 2010.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, SciELO Brasil, v. 35, p. 85–94, 2021.
- LUGER, G. F. **Inteligência Artificial. Tradução de Daniel Vieira**. [S.l.: s.n.]: São Paulo: Pearson Education do Brasil, 2013.
- MITCHELL, T. M. Does machine learning really work? **AI magazine**, v. 18, n. 3, p. 11–11, 1997.
- MOURA, J. What is signal processing?[president’s message]. **IEEE Signal Processing Magazine**, IEEE, v. 26, n. 6, p. 6–6, 2009.
- NG, Y. *et al.* Few-shot transfer learning for personalized atrial fibrillation detection using patient-based siamese network with single-lead ecg records. **Artificial Intelligence in Medicine**, Elsevier, v. 144, p. 102644, 2023.
- NIH. **Arrhythmia**. *Acesso 2024*. Available at: <<https://www.nhlbi.nih.gov/health-topics/arrhythmia>>.
- NITTA, T. Solving the xor problem and the detection of symmetry using a single complex-valued neuron. **Neural Networks**, Elsevier, v. 16, n. 8, p. 1101–1105, 2003.
- PANDEY, S. K.; JANGHEL, R. R. Classification of electrocardiogram signal using an ensemble of deep learning models. **Data Technologies and Applications**, Emerald Publishing Limited, v. 55, n. 3, p. 446–460, 2021.
- RAJPUT, K. S. *et al.* On arrhythmia detection by deep learning and multidimensional representation. **arXiv preprint arXiv:1904.00138**, 2019.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- RUBIN, J. *et al.* Densely connected convolutional networks for detection of atrial fibrillation from short single-lead ecg recordings. **Journal of electrocardiology**, Elsevier, v. 51, n. 6, p. S18–S21, 2018.
- RUMELHART, D. E. *et al.* Learning representations by back-propagating errors. **Cognitive modeling**, v. 5, n. 3, p. 1, 1988.
- SANTOS, C. C. dos *et al.* Uso de transfer learning para o reconhecimento de gestos dinâmicos. *In: Congresso Brasileiro de Automática-CBA*. [S.l.: s.n.], 2019. v. 1, n. 1.
- SBC, S. B. d. C. **Cardiômetro - Série histórica dos óbitos e taxas por doenças cardiovasculares. Brasil, regiões e estados, 2000 a 2018**. *Acesso 2024*. Available at: <<http://www.cardiometro.com.br/grafico.asp>>.

SILVA, R. E. V. d. Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens. 2018.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SOBRAC, S. B. d. A. C. **DADOS SOBRE MORTE SÚBITA**. *Acesso 2024*. Available at: <<https://www.sobrac.org/campanha/arritmias-cardiacas-mortes-subita/>>.

TEICH, M. C. *et al.* Heart rate variability: measures and models. **Nonlinear Biomedical Signal Processing: Dynamic Analysis and Modeling**, Wiley Online Library, v. 2, p. 159–213, 2000.

VASCONCELOS, C. N.; CLUA, E. W. G. Deep learning-teoria e prática. **Jornadas de Atualização em Informática**, 2017.

VEEN, F. V. **The Neural Network Zoo**. 2016. Available at: <<http://www.asimovinstitute.org/neural-network-zoo/>>.

VOGADO, L. H. *et al.* Rede neural convolucional para o diagnóstico de leucemia. *In*: SBC. **Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)**. [S.l.: s.n.], 2019. p. 46–57.

XIA, Y. *et al.* Detecting atrial fibrillation by deep convolutional neural networks. **Computers in biology and medicine**, Elsevier, v. 93, p. 84–92, 2018.

YOSINSKI, J. *et al.* How transferable are features in deep neural networks? **Advances in neural information processing systems**, v. 27, 2014.

ZHANG, S.; ZHANG, C.; YANG, Q. Data preparation for data mining. **Applied artificial intelligence**, Taylor & Francis, v. 17, n. 5-6, p. 375–381, 2003.