



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

VICTOR HUGO CERCASIN POYER NOGUEIRA

ANÁLISE DE ELETROCARDIOGRAMA (ECG) COM  
REDES NEURASIS CONVOLUCIONAIS (CNN)

---

LONDRINA

2024

VICTOR HUGO CERCASIN POYER NOGUEIRA

**ANÁLISE DE ELETROCARDIOGRAMA (ECG) COM  
REDES NEURASIS CONVOLUCIONAIS (CNN)**

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Ciência da Computação da Universidade Estadual de Londrina para obtenção do título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Fábio Sakuray

Coorientador: Prof. Dr. Wesley Attrot

LONDRINA

2024

VICTOR HUGO CERCASIN POYER NOGUEIRA

**ANÁLISE DE ELETROCARDIOGRAMA (ECG) COM  
REDES NEURAIAS CONVOLUCIONAIS (CNN)**

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Ciência da Computação da Universidade Estadual de Londrina para obtenção do título de Bacharel em Ciência da Computação.

**BANCA EXAMINADORA**

---

Orientador: Prof. Dr. Fábio Sakuray  
Universidade Estadual de Londrina

---

Prof. Dr. Wesley Attrot  
Universidade Estadual de Londrina

---

Prof. Dr. Terceiro Membro da Banca  
Universidade/Instituição do Terceiro  
Membro da Banca – Sigla instituição

---

Prof. Ms. Quarto Membro da Banca  
Universidade/Instituição do Quarto  
Membro da Banca – Sigla instituição

Londrina, 25 de maio de 2024.

## AGRADECIMENTOS

CERCASIN, VICTOR HUGO. **Análise de Eletrocardiograma (ECG) com Redes Neurais Convolucionais (CNN)**. 2024. 37f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Universidade Estadual de Londrina, Londrina, 2024.

## RESUMO

As doenças cardiovasculares são as principais causadoras de mortes globais, tornando essencial o desenvolvimento de métodos diagnósticos precisos e eficientes. O eletrocardiograma (ECG) é uma ferramenta diagnóstica fundamental para identificar diversas patologias cardíacas. No entanto, a interpretação de ECGs é complexa e sujeita à disponibilidade e experiência de especialistas. Este trabalho explora o uso de Redes Neurais Convolucionais (CNNs) para automatizar e aprimorar a análise de ECGs, visando superar as limitações de interpretação humana e a escassez de médicos especializados, especialmente em áreas remotas. Diferentes arquiteturas de CNN foram avaliadas quanto à sua eficácia em identificar anormalidades cardíacas a partir de ECGs, utilizando uma ampla base de dados de sinais cardíacos. Os resultados demonstram que as CNNs, devido à sua capacidade de aprender características significativas dos dados sem a necessidade de intervenção manual ou extração prévia de características, apresentam um potencial significativo para o diagnóstico automatizado, com alta precisão e robustez. Este estudo apresenta a viabilidade das CNNs na análise de ECGs, com também destaca o potencial para sua aplicação em dispositivos portáteis de monitoramento cardíaco, contribuindo para uma abordagem mais acessível e eficiente no diagnóstico de doenças cardiovasculares.

**Palavras-chave:** ECG. CNN. Análise de Sinal. Redes Neurais. Inteligência Artificial. Doenças Cardíacas. Diagnóstico

CERCASIN, VICTOR HUGO. **Eletrocardiogram (EGC) analysis with Convolutional Neural Networks (CNN)**. 2024. 37p. Final Project (Bachelor of Science in Computer Science) – State University of Londrina, Londrina, 2024.

## ABSTRACT

Cardiovascular diseases are the leading cause of global mortality, making the development of precise and efficient diagnostic methods essential. Electrocardiogram (ECG) is a fundamental diagnostic tool for identifying various cardiac pathologies. However, ECG interpretation is complex and reliant on the availability and expertise of specialists. This work explores the use of Convolutional Neural Networks (CNNs) to automate and enhance ECG analysis, aiming to overcome human interpretation limitations and the shortage of specialized doctors, especially in remote areas. Different CNN architectures were evaluated for their effectiveness in identifying cardiac abnormalities from ECGs, using a comprehensive database of cardiac signals. The results demonstrate that CNNs, due to their ability to learn significant features from data without manual intervention or prior feature extraction, show significant potential for automated diagnosis, with high accuracy and robustness. This study not only reaffirms the feasibility of CNNs in ECG analysis but also highlights the potential for their application in portable cardiac monitoring devices, contributing to a more accessible and efficient approach to diagnosing cardiovascular diseases.

**Keywords:** ECG. CNN. Signal Analysis. Neural Networks. Artificial Intelligence. Cardiac Disease. Diagnosis

## LISTA DE ILUSTRAÇÕES

Figura 1 – Sinal de ECG de um batimento cardíaco normal [1] . . . . .	12
Figura 2 – Ciclo cardíaco normal com as ondas de ECG associadas [2] . . . . .	12
Figura 3 – Configuração típica de ECG com 10 eletrodos [3] . . . . .	13
Figura 4 – Estrutura de uma MLP[4] . . . . .	17
Figura 5 – Cálculo do valor de ativação [5] . . . . .	17
Figura 6 – Diagramas de funções de ativação: (a) Sigmoide. (b) <i>Tanh</i> . (c) <i>ReLU</i> . (d) <i>Leaky ReLU</i> . (e) <i>PReLU</i> . (f) <i>ELU</i> . (g) <i>Swish</i> . (h) <i>Mish</i> [5] . . . . .	19
Figura 7 – Funcionamento de uma convolução. . . . .	20
Figura 8 – Estrutura de uma CNN [6] . . . . .	20
Figura 9 – Imagens convolucionadas e seus respectivos <i>kernels</i> . (a) Filtro Identi- tidade (figura original), (b) Filtro de Nitidez, (c) Filtro de Desfoque Gaussiano, (d) Filtro de Realçamento de Borda Vertical, (e) Filtro de Realçamento de Borda Horizontal, (f) Filtro de Realçamento de Borda Lapaciana . . . . .	21
Figura 10 – Arquitetura do modelo proposto em [7] . . . . .	27
Figura 11 – Entrada do modelo CNN proposto em [8] . . . . .	28

## LISTA DE TABELAS

Tabela 1 – Modelo CNN do trabalho 1 . . . . .	24
Tabela 2 – Modelo CNN-LSTM do trabalho 1 . . . . .	24
Tabela 3 – Resultados do trabalho 1 . . . . .	25
Tabela 4 – Modelo CNN do trabalho 2 . . . . .	25
Tabela 5 – Resultados do trabalho 2 . . . . .	26
Tabela 6 – Resultados do trabalho 4 . . . . .	29

## LISTA DE ABREVIATURAS E SIGLAS

CNN	Redes Neurais Convolucionais, do inglês <i>Convolutional Neural Network</i>
ECG	Eletrocardiograma
KNN	K-vizinhos Mais Próximos, do inglês <i>K-nearest Neighbours</i>
LDA	análise de Discriminante Linear, do inglês <i>Linear Discriminant Analysis</i>
ANN	Rede Neural Artificial, do inglês <i>Artificial Neural Network</i>
MLP	Perceptron Multi-camadas, do inglês <i>Multi-layer Perceptron</i>
ReLu	Unidade Linear Retificada, do inglês <i>Rectified Linear Unit</i>

# SUMÁRIO

1	INTRODUÇÃO . . . . .	10
2	ELETROCARDIOGRAMA . . . . .	11
2.1	Pontos Fiduciais . . . . .	11
2.2	Canais do ECG . . . . .	13
2.3	Análise automática de ECG . . . . .	13
2.3.1	Pré-Processamento . . . . .	14
2.3.2	Extração de Características . . . . .	14
2.3.3	Classificação do Batimento Cardíaco . . . . .	14
3	REDE NEURAL CONVOLUCIONAL (CNN) . . . . .	16
3.1	Redes Neurais Perceptron Multicamadas . . . . .	16
3.1.1	Hiperparâmetros . . . . .	16
3.2	Convolução . . . . .	19
3.3	Estrutura de uma CNN . . . . .	20
3.3.1	Bloco de extração de características . . . . .	21
4	TRABALHOS RELACIONADOS . . . . .	23
4.1	Trabalho 1: <i>Multiclass Classification of Myocardial Infarction with Convolutional and Recurrent Neural Networks for Portable ECG Devices</i> . . . . .	23
4.2	Trabalho 2: <i>Classification of myocardial infarction with multi-lead ECG signals and deep CNN</i> . . . . .	25
4.3	Trabalho 3: <i>Interpretation of Electrocardiogram (ECG) Rhythm by Combined CNN and BiLSTM</i> . . . . .	26
4.4	Trabalho 4: <i>Interpretation of EKG with Image Recognition and Convolutional Neural Networks</i> . . . . .	27
5	DESAFIOS E LIMITAÇÕES . . . . .	30
6	CONCLUSÃO . . . . .	31
6.1	Próximas etapas deste trabalho . . . . .	31
	REFERÊNCIAS . . . . .	33

# 1 INTRODUÇÃO

Segundo a Organização Mundial da Saúde, as doenças cardiovasculares são a principal causa de mortes no mundo atualmente, matando aproximadamente 17,9 milhões de pessoas todo ano, representando um desafio significativo para os sistemas de saúde em todo o mundo [9].

Doenças cardiovasculares são um grupo de condições do coração e vasos sanguíneos, como doenças coronárias, doenças cerebrovasculares e doenças reumáticas. Uma das ferramentas fundamentais para diagnosticar as diversas patologias cardíacas é o eletrocardiograma (ECG) que funciona através da análise da atividade elétrica do coração. No entanto, a interpretação de ECGs é uma tarefa complexa que exige conhecimento especializado e é suscetível a variações, dependendo da experiência do analista. Uma ferramenta automatizada de detecção de anomalias em ECG pode amenizar problemas de falha humana [10], e no cenário brasileiro, a má distribuição de médicos entre interior e capitais amplifica a necessidade da automação de procedimentos médicos, incluindo a medicina diagnóstica [11].

O avanço das tecnologias de inteligência artificial ofereceu novas perspectivas para a análise automatizada de sinais médicos. Dentre estas tecnologias, as Redes Neurais Convolucionais (CNNs) destacam-se pelo seu desempenho excepcional no processamento de dados visuais [5] e, por extensão, na análise de padrões em dados unidimensionais como os de ECG. As CNNs têm a capacidade de aprender características essenciais dos dados automaticamente, superando a necessidade de extração manual de características e potencializando a precisão diagnóstica [12].

Assim, este trabalho visa explorar o potencial das CNNs para aprimorar a análise de ECGs, com o objetivo de desenvolver um sistema que não apenas melhore a precisão dos diagnósticos cardíacos, mas também torne o processo mais acessível e menos dependente de especialistas, especialmente em áreas remotas onde tais recursos são escassos. Através de uma revisão de literatura extensa e estudos de caso práticos, foram avaliados diferentes arquiteturas de CNN e foi comparada sua eficácia na identificação de anormalidades cardíacas a partir de dados de ECG.

Este estudo é organizado da seguinte forma: inicialmente, é apresentada uma visão geral das doenças cardiovasculares e da importância do ECG. Em seguida, são discutidos os princípios fundamentais da CNN e como esta pode ser aplicada ao contexto dos ECGs. A seguir são apresentados trabalhos relacionados ao uso de CNN na análise de ECG, uma breve discussão das limitações e os desafios da proposta e as conclusões obtidas, assim como uma linha do tempo relacionada às próximas etapas deste trabalho.

## 2 ELETROCARDIOGRAMA

O coração humano é um músculo cuja função é bombear o sangue através de todo o corpo. A cada batimento são bombeados aproximadamente 70 ml de sangue, e durante a vida, o coração de uma pessoa baterá aproximadamente 2,5 bilhões de vezes em 70 anos. Este órgão contém 4 cavidades, os átrios esquerdo e direito e os ventrículos, esquerdo e direito. O átrio e o ventrículo esquerdos têm como função receber o sangue venoso (desprovido de oxigênio) do corpo e bombeá-lo para os pulmões, onde é feita uma troca gasosa em que oxigênio do ar é absorvido pelos pulmões enquanto o gás carbônico e outros gases indesejáveis são difundidos para a atmosfera. Em seguida, esse sangue rico em oxigênio é deslocado aos átrio e ventrículo esquerdos, de onde é bombeado para todo o corpo [13].

O funcionamento desse órgão é regido por descargas elétricas sincronizadas, que podem ser detectadas. Um ECG é simplesmente uma gravação dessa atividade elétrica, sendo um exame não invasivo e poderoso. Este exame pode aferir desde medidas de frequência cardíaca, ritmo dos batimentos, diagnóstico de anomalias e até no reconhecimento de emoções e identificação biométrica [2].

No entanto, a análise automatizada de batimentos cardíacos é extremamente desafiadora por vários motivos. Por exemplo, exames em dois indivíduos com a mesma condição cardíaca podem apresentar morfologias bastante dissimilares, enquanto condições diferentes podem se apresentar de modo bastante semelhantes. [2].

### 2.1 Pontos Fiduciais

Durante o exame de ECG, a diferença de potencial elétrico entre dois pontos do corpo humano é aferida, e então é possível analisar a morfologia do sinal resultante. A Figura 1 representa um sinal gerado por um único batimento de um coração saudável. O batimento cardíaco pode ser dividido entre algumas ondas distintas. Ao pico destas ondas é dado o nome de ponto fiducial.

Estes pontos estão associados a etapas específicas do batimento, ilustradas na Figura 2, e brevemente explicadas seguir [14]:

- **Onda P:** Desencadeada da despolarização (ativação) dos átrios;
- **Complexo QRS:** Despolarização dos ventrículos;
- **Onda T:** Representa a repolarização (recarga) dos ventrículos.




Figura 1 – Sinal de ECG de um batimento cardíaco normal [1]




Figura 2 – Ciclo cardíaco normal com as ondas de ECG associadas [2]

Divergências significativas na posição relativa, altura e até eixo destes pontos fiduciais podem caracterizar anomalias cardíacas. A seguir são apresentadas algumas alterações de morfologia e suas possíveis causas [14]:

- Prolongamento do intervalo PR pode indicar bloqueio atrial do primeiro grau;
- Bloqueios de ramo direito ou esquerdo são associados a irregularidade no complexo

QRS, como alargamento e morfologia anormal;

- Uma variação na amplitude do complexo QRS pode indicar hipertrofia ventricular direita ou esquerda;
- Variações do intervalo RR indicam diversos tipos de arritmias cardíacas incluindo taquicardia, bradicardia e fibrilação atrial.

## 2.2 Canais do ECG

No exame de ECG, diversos sensores conhecidos como canais são fixados a pontos pré estabelecidos do corpo do paciente. Cada par de sensores gera um sinal que representa a diferença de potencial elétrico entre os pontos. A combinação desses sinais nos dá uma noção geral do funcionamento do coração em três dimensões [14]. Um posicionamento comum dos canais em um paciente pode ser visto na Figura 3.




Figura 3 – Configuração típica de ECG com 10 eletrodos [3]

## 2.3 Análise automática de ECG

Segundo S. Kaplan Berkaya *et al.* [15], o campo de análise de ECG é dividido entre as seguintes fases: pré-processamento, extração de características e classificação. A seguir serão detalhadas cada uma delas.

### 2.3.1 Pré-Processamento

Imperfeições no processo de coleta do ECG causam diversos tipos de distorção no sinal dos canais. Essas interferências fazem com que o sinal fique mais ruidoso, dificultando sua interpretação. São fontes comuns de distorção o ruído da rede elétrica, a respiração do paciente e até outros equipamentos médicos. Um passo inicial importante na limpeza do sinal são os filtros passa-banda, que consistem na decomposição do sinal em suas frequências fundamentais e a seleção de uma faixa estreita de frequências de modo a filtrar ruídos. As bandas de frequências mais utilizadas são 0,1 - 100Hz [16], [17] e 1 - 40Hz [18], [19]. Filtros de passa-baixa [20], passa-alta [21] e filtro rejeita-faixa [22] também podem ser empregados. A escolha de um filtro adequado é importante e deve variar com o tipo de análise que se deseja executar, pois apesar da sua utilidade na redução de ruído, alguns filtros podem atenuar o sinal [2].

A normalização de amplitude também é uma técnica de pré-processamento importante. Ela permite comparar diretamente batimentos de pacientes diferentes e evita falsos positivos e falsos negativos para doenças que avaliam a amplitude dos pontos fiduciais [23], [24].

### 2.3.2 Extração de Características

A extração de características é a etapa em que se condensa a grande massa de dados gerada no exame de ECG em apenas alguns pontos de interesse. Ela pode ser realizada de várias formas de acordo com o tipo de classificação desejada. Uma das formas é a extração de características estatísticas, como energia, média, desvio padrão, máximo, mínimo, curtose e assimetria [15].

Outro tipo de característica são os pontos fiduciais. Algumas técnicas utilizadas na extração desses pontos são o algoritmo de Pan & Tompkins [25], no qual uma série de filtragens é aplicada ao sinal, destacando os picos do complexo QRS e suavizando os demais sinais. Outros métodos utilizam a técnica de transformada *wavelet*, que extrai pontos fiduciais a partir de pequenas ondas que obedecem certas relações matemáticas [18], [26].

### 2.3.3 Classificação do Batimento Cardíaco

Após a extração de características, é possível classificar o batimento cardíaco. Algumas das técnicas de classificação são: a análise de discriminante linear (LDA), que busca maximizar a distância entre-classes enquanto minimiza a distância intra-classes [27], [28]. K-vizinhos mais próximos (KNN do inglês *K-nearest neighbors*) é um algoritmo simples que classifica um vetor desconhecido de acordo com a proximidade para um valor especificado de vizinhos conhecidos em um sistema de votação [29], [30]. Redes neurais artificiais

(ANNs do inglês *artificial neural networks*) são modelos matemáticos inspirados na estrutura biológica das redes neurais cerebrais, compostas por neurônios interconectados que se ativam mutuamente. Estas redes são capazes de resolver tanto problemas de classificação linear quanto não linear, utilizando uma variedade de estruturas de aprendizado e algoritmos. Por exemplo, as redes neurais recorrentes se caracterizam por possuírem neurônios que se retroalimentam [17]. Já as redes neurais de valor complexo utilizam números complexos nos valores de ativação [31], enriquecendo o processo de modelagem através das funções de ativação e ajuste de vieses.

### 3 REDE NEURAL CONVOLUCIONAL (CNN)

As Redes Neurais Convolucionais (CNNs do inglês *convolutional neural networks*) representam uma evolução dentro do campo de aprendizado profundo, diferenciando-se pela utilização de camadas convolucionais que permitem uma escalabilidade eficaz em relação ao tamanho dos dados de entrada [5]. Seu uso elimina a necessidade de extração manual de características, facilitando o processamento de grandes dimensões de dados [15]. Além disso, as CNNs estão se mostrando promissoras na detecção de anomalias cardíacas através da análise de ECGs, pois adaptam-se à entrada de dados unidimensionais, uma prática que vem ganhando espaço além do seu uso frequente em dados bidimensionais [1], [3], [32], [33], [20], [34], [26].

Para entender melhor o potencial das CNNs, é essencial conhecer conceitos fundamentais como as redes neurais perceptron multicamadas e o processo de convolução, que são pilares para o funcionamento dessas redes avançadas.

#### 3.1 Redes Neurais Perceptron Multicamadas

As redes neurais perceptron multicamadas (MLP do inglês *multilayer perceptron*) têm sido utilizadas com sucesso em diversas tarefas, como classificação e reconhecimento de padrões, sistemas de modelagem e identificação, processamento de sinais, sistemas de controle e previsões de mercado. Esse sucesso pode ser atribuído a características como sua estrutura paralela, capacidade de aprendizado, adaptabilidade e tolerância a falhas [35].

A arquitetura de uma MLP consiste em neurônios organizados em três tipos de camadas: entrada, saída e camadas ocultas. Cada neurônio armazena um valor conhecido como valor de ativação e é conectado a todos os neurônios das camadas adjacentes, formando uma rede densamente interligada. Os valores de entrada, conhecidos como características ou *features*, são inseridos nos neurônios da camada de entrada. Para determinar o valor de ativação de neurônios em camadas subsequentes, realiza-se uma soma ponderada dos valores de ativação dos neurônios antecedentes, em seguida este valor é processado por uma função de ativação [4]. A configuração espacial de uma MLP é ilustrada na Figura 4, e o cálculo do valor de ativação de um neurônio é detalhado na Figura 5.

##### 3.1.1 Hiperparâmetros

No processo de construção e treinamento supervisionado de uma rede neural, inicialmente define-se a arquitetura do modelo e os chamados hiperparâmetros. Hiperpa-




Figura 4 – Estrutura de uma MLP[4]




Figura 5 – Cálculo do valor de ativação [5]

râmetros são valores definidos antes do treinamento que determinam a estrutura e o comportamento do modelo [36]. São exemplos:

- **Quantidade de camadas ocultas:** Escolher o número de camadas ocultas em um MLP é crucial para seu desempenho e precisão, e o número ideal depende em grande parte da complexidade da tarefa. Uma única camada oculta pode modelar funções

relativamente simples, mas problemas mais complexos geralmente requerem mais camadas. Adicionar camadas ocultas ajuda a rede a aprender características em múltiplos níveis de abstração, o que melhora sua capacidade de generalizar a partir dos dados de treinamento. No entanto, muitas camadas podem tornar a rede propensa a *overfitting*<sup>1</sup>, especialmente se não houver dados de treinamento suficientes [38];

- **Quantidade de neurônios em cada camada:** É essencial que o número de neurônios seja adequadamente dimensionado para capturar a complexidade inerente ao problema, evitando-se uma quantidade excessiva que possa induzir ao *overfitting*, situação na qual o modelo pode memorizar os dados de entrada em vez de generalizar. Por outro lado, um número insuficiente de neurônios pode resultar em *underfitting*, onde o modelo não possui capacidade suficiente para representar adequadamente o problema [39];
- **Função de ativação:** A cada camada da rede deve-se definir uma função de ativação. Existem várias funções de ativação com casos de uso diferentes, mas a função principal das funções de ativação é permitir ao modelo realizar transformações não lineares nos dados de entrada, aumentando bastante seu potencial de modelagem [40]. Exemplos de funções de ativação amplamente utilizadas são::
  1. **ReLU:** *ReLU* ou Unidade Linear Retificada possui um bom desempenho computacional por ser composta de segmentos lineares, apresentando excelente potencial de modelagem [41];
  2. **Sigmoide:** Esta função de ativação realiza a compressão dos valores reais ao intervalo entre 0 e 1, sendo utilizada em problemas de classificação binária [42];
  3. **Leaky ReLU:** É uma derivação da função de ativação ReLu na qual números negativos são mapeados para números negativos pequenos. Essa característica ameniza o problema de morte de neurônios que pode atingir camadas ativadas por ReLu [43].

A Figura 6 apresenta uma representação gráfica destas e outras funções de ativação.

- **Função de perda:** A função de perda é um componente crítico durante o treinamento de modelos, utilizada para avaliar a precisão do modelo em relação aos dados de treinamento. Ela é calculada com base na discrepância entre as previsões geradas pela camada de saída do modelo e os valores esperados. O propósito principal do treinamento é, portanto, minimizar o valor da função de perda para todas as instâncias de dados [44].

---

<sup>1</sup> *Overfitting* ocorre quando uma rede neural aprende padrões específicos do conjunto de treinamento que não são generalizáveis para dados não vistos [37]




Figura 6 – Diagramas de funções de ativação: (a) Sigmoide. (b) *Tanh*. (c) *ReLU*. (d) *Leaky ReLU*. (e) *PReLU*. (f) *ELU*. (g) *Swish*. (h) *Mish* [5]

## 3.2 Convolação

No contexto de CNN, a convolução é uma técnica utilizada para extrair informações relevantes de um conjunto de dados através da aplicação de filtros. Esta operação, tipicamente linear, é frequentemente combinada com uma função de ativação não linear para permitir que a rede aprenda padrões complexos. Durante o processo de convolução, informações contidas em registros de dados adjacentes são combinadas. Com múltiplas convoluções subsequentes, ocorre a intercomunicação entre áreas distantes em uma série temporal ou outros tipos de dados regularmente espaçados, permitindo uma extração de característica globais [45], [46].

Para facilitar a compreensão do conceito de convolução, nesta sessão demonstraremos seu funcionamento no contexto da análise de imagens. No entanto, seu funcionamento é análogo em outros tipos de dados como séries temporais unidimensionais.

Na convolução, um filtro ou *kernel* é escolhido. Ele consiste de um conjunto de multiplicadores lineares organizados em uma grade. Sua dimensão e os valores dos multiplicadores são escolhidos de acordo com a função desejada [47]. Este filtro percorre a imagem atribuindo a cada pixel o resultado da soma ponderada entre seus valores adjacentes e os multiplicadores do *kernel*, resultando em um novo conjunto de dados que agora representa uma combinação linear entre valores adjacentes, como demonstrado na Figura 7 [5].

Essa técnica pode gerar transformações como realçamento de bordas, aumento de nitidez e desfoque, como demonstrado na Figura 9 [48].




Figura 7 – Funcionamento de uma convolução.




Figura 8 – Estrutura de uma CNN [6]

### 3.3 Estrutura de uma CNN

Em geral, a estrutura de uma CNN consiste em dois blocos básicos: o bloco de extração de características e o bloco de classificação [34]. O bloco de extração de características inclui as camadas convolucionais, e sua função é reduzir as dimensões espaciais e aumentar a densidade informacional dos dados, gerando novas características mais promissoras. O bloco de classificação consiste em uma seção de neurônios completamente




Figura 9 – Imagens convolucionadas e seus respectivos *kernels*. (a) Filtro Identidade (figura original), (b) Filtro de Nitidez, (c) Filtro de Desfoque Gaussiano, (d) Filtro de Realçamento de Borda Vertical, (e) Filtro de Realçamento de Borda Horizontal, (f) Filtro de Realçamento de Borda Lapaciana

conexos, e sua função é realizar a avaliação dos mapas de características extraídos no primeiro bloco, tendo como saída a classificação ou regressão desejada. Pode-se concluir que o bloco de classificação é uma rede MLP cujas características de entrada são alimentadas pelo bloco anterior, como ilustrado na Figura 8 [49].

### 3.3.1 Bloco de extração de características

Este bloco consiste em alguns componentes com funções específicas. São eles [50]:

- **Camada de convolução:** A convolução no contexto de CNN é um pouco diferente da convolução no contexto de tratamento de imagem. Nele, diversos filtros ou *kernels* são convolucionados nos *feature maps*<sup>2</sup> da camada anterior.

<sup>2</sup> *Feature maps* é o nome dado às saídas das camadas convolucionais.

- **Função de ativação:** Após a convolução, a função de ativação faz uma transformação não linear nos valores de cada unidade de dado das *feature maps*.
- **Camadas *pooling*:** A função das camadas *pooling* é realizar a diminuição espacial dos dados. Inicialmente, define-se o tamanho do filtro de *pooling* (comumente 2x2 para imagens), e então um algoritmo determina qual valor deve representar todos os valores contidos na área de do filtro. Exemplos de tipos de *pooling* são: *Max pooling*, que define o valor da área de *pooling* como o maior. *Average pooling*, que define o valor da área de *pooling* como a média entre os valores.

## 4 TRABALHOS RELACIONADOS

A seguir são apresentados alguns trabalhos publicados que relacionam análise de ECG e o uso de CNN. Os resultados obtidos são significativos, e demonstram um grande potencial nesta área.

### 4.1 Trabalho 1: *Multiclass Classification of Myocardial Infarction with Convolutional and Recurrent Neural Networks for Portable ECG Devices*

O trabalho foi realizado pelos autores Hin Wai Luita e King Lau Chow [33]. O objetivo deste estudo foi classificar exames de ECG em três categorias: infarto do miocárdio, outras anormalidades e ruído. Para isso, foram utilizados dois bancos de dados principais. O primeiro banco de dados foi o *Physikalisch-Technische Bundesanstalt (PTB) diagnostic ECG database* [51], que contém 549 registros de 290 pacientes, sendo 48 registros de infarto do miocárdio, 52 registros de indivíduos saudáveis e 90 registros com diversas outras doenças, como insuficiência cardíaca, bloqueio de ramo, disritmia e hipertrofia cardíaca. O segundo banco de dados utilizado foi o *AF classification from a short single lead ECG recording: Physionet/computing in cardiology challenge 2017 database (AF-Challenge)* [52], que contém 278 sinais de ruído.

O pré-processamento dos dados envolveu a determinação de parâmetros utilizando *grid search*. Primeiramente, foi realizado o *denoising* utilizando o algoritmo de *Savitzky Galay*. Em seguida, foi feita a remoção do *base wonder* e a segmentação dos batimentos no pico das ondas R. As bordas dos sinais foram preenchidas com zeros para garantir uma duração de 1707ms, assegurando consistência entre os batimentos. Por fim, o sinal foi normalizado.

Os autores propuseram dois modelos principais: um modelo puramente baseado em CNN e um modelo que incorpora uma camada recorrente, denominado CNN-LSTM. Além disso, foram testadas variações com *stacking decoding* e outras com características extraídas manualmente. As Tabelas 1 e 2 apresentam a arquitetura da CNN e da CNN-LSTM, respectivamente. Os resultados dos modelos e suas variações estão apresentados na Tabela 3.

Tabela 1 – Modelo CNN do trabalho 1

<b>Camada</b>	<b>Tipo</b>	<b>Formato de Saída</b>
0	Inputs	512
1–6	Convolutional block	$256 \times 32$
7–12	Convolutional block	$128 \times 32$
13–18	Convolutional block	$64 \times 32$
19–24	Convolutional block	$32 \times 32$
25	Flattened	1024
26	Fully connected	32
27	Batch normalisation	32
28	Dropout 50%	32
29	Fully connected	32
30	Batch normalisation	32
31	Dropout 50%	32
32	Fully connected	16
33	Batch normalisation	16
34	Dropout 50%	16
35	Outputs	4

Tabela 2 – Modelo CNN-LSTM do trabalho 1

<b>Camada</b>	<b>Tipo</b>	<b>Formato de Saída</b>
0	Inputs	$8 \times 512$
1–6	Time-distributed convolutional block	$8 \times 256 \times 32$
7–12	Time-distributed convolutional block	$8 \times 128 \times 32$
13–18	Time-distributed convolutional block	$8 \times 64 \times 32$
19–24	Time-distributed convolutional block	$8 \times 32 \times 32$
25	Time-distributed flattened	$8 \times 1024$
26	Time-distributed fully connected	$8 \times 32$
27	Time-distributed batch normalisation	$8 \times 32$
28	Time-distributed dropout 50%	$8 \times 32$
29	LSTM	32
30	Batch normalisation	32
31	Dropout 50%	32
32	Fully connected	16
33	Batch normalisation	16
34	Dropout 50%	16
35	Outputs	4

Tabela 3 – Resultados do trabalho 1

Classificador	Sensibilidade	Especificidade	PPV	F1
Hand-crafted features MLP	54,4%	93,3%	87,2%	66,3%
CNN	49,8%	92,0%	86,5%	59,7%
CNN-LSTM	68,1%	86,8%	81,2%	73,0%
CNN stacking decoding	64,4%	96,3%	93,9%	75,9%
CNN-LSTM stacking decoding	92,4%	97,7%	97,2%	94,6%
CNN-LSTM stacking decoding with hand-crafted features	79,9%	98,8%	98,3%	87,2%

## 4.2 Trabalho 2: *Classification of myocardial infarction with multi-lead ECG signals and deep CNN*

O trabalho foi realizado pelos autores Ulas Baran Baloglu, Muhammed Talo, Ozal Yildirim, Ru San Tan e U Rajendra Acharya [34]. O objetivo deste estudo foi realizar o diagnóstico de 10 tipos de infarto do miocárdio com alta precisão utilizando 12 derivações de ECG. Para isso, foi utilizado o banco de dados *Physikalisch-Technische Bundesanstalt (PTB) diagnostic ECG database* [51], que contém dados de 200 pacientes, sendo 52 considerados normais e 148 classificados como subtipos de infarto do miocárdio, com sinais registrados a uma frequência de 1000Hz.

O pré-processamento dos dados incluiu várias etapas. Primeiramente, foi realizado o *denoising*. Em seguida, foi feita a remoção do *base wander*. A segmentação dos batimentos foi realizada com a detecção do ponto R, seguida de cortes de 250 pontos antes e 400 pontos após o ponto R.

O modelo proposto pelos autores utiliza a mesma CNN para realizar a classificação das 12 derivações do ECG. A arquitetura do modelo está disponível na Tabela 4. Os resultados do modelo estão apresentados na Tabela 5.

Tabela 4 – Modelo CNN do trabalho 2

Número	Nome da Camada	Formato de Saída	Número de Parâmetros
1	Conv 1D	$647 \times 64$	384
2	Conv 1D	$645 \times 128$	24.704
3	MaxPooling1D	$322 \times 128$	0
4	Dropout	$322 \times 128$	0
5	Conv 1D	$310 \times 128$	213.120
6	Conv 1D	$304 \times 128$	229.632
7	MaxPooling1D	$152 \times 256$	0
8	Flatten	38.912	0
9	Dense	64	2.490.432
10	SoftMax	11	715

Tabela 5 – Resultados do trabalho 2

Classe	ACC (%)	PRE (%)	SEN (%)	SPE (%)	F1 (%)
Anterior	99,94	99,59	99,86	99,95	99,72
Anterior Lateral	99,85	99,37	99,47	99,90	99,42
Anterior Septal	99,88	99,76	99,52	99,95	99,64
Healthy	99,97	99,93	99,93	99,98	99,93
Inferior	99,97	99,93	99,93	99,98	99,93
Inferior Lateral	99,93	99,64	99,76	99,95	99,70
Inferior Posterior	100	100	100	100	100
Inferior Posterior Lateral	100	100	100	100	100
Lateral	100	100	100	100	100
Posterior	100	100	100	100	100
Posterior Lateral	99,98	100	99,09	100	99,54
<b>Acurácia Global (%)</b>			<b>99.78</b>		

### 4.3 Trabalho 3: *Interpretation of Electrocardiogram (ECG) Rhythm by Combined CNN and BiLSTM*

O trabalho foi realizado pelos autores Xue Xu, Sohyun Jeong e Jianqiang Li [7]. O objetivo inicial deste estudo foi treinar um modelo para a identificação de Fibrilação Atrial. Em seguida, os pesos pré-treinados foram utilizados para treinar o modelo para categorizar os batimentos em cinco categorias.

Para isso, foram utilizados dois bancos de dados. O primeiro banco de dados foi o *2017 PhysioNet/CinC Challenge* [52], que contém 8528 exames de 9 a 61 segundos classificados como normais, fibrilação atrial, outros e ruído. Este banco de dados foi utilizado para o treinamento preliminar do modelo. O segundo banco de dados foi o *MIT-BIH Arrhythmia Dataset* [53], que contém registros de 47 pacientes com batimentos classificados em cinco categorias: batimentos normais, batimentos ectópicos supraventriculares, batimentos ectópicos ventriculares, fusão de batimento ventricular e normal, e outros.

O pré-processamento dos dados envolveu várias etapas. Primeiramente, foi realizado o *down-sampling* para 125Hz, seguido de normalização. Em seguida, foi feita a detecção do pico R e a aferição do pico T utilizando o ponto médio do complexo R-R. Os batimentos foram segmentados no pico T aferido anteriormente e, por fim, foi aplicado *padding* com zeros.

O modelo proposto é complexo e inclui um bloco convolucional seguido de blocos recorrentes em uma arquitetura não linear, conforme ilustrado na Figura 11. Os resultados do modelo foram notáveis, com uma precisão de 96.34%, recall de 95.90%, F1-score de 95.92




Figura 10 – Arquitetura do modelo proposto em [7]

#### 4.4 Trabalho 4: *Interpretation of EKG with Image Recognition and Convolutional Neural Networks*

O trabalho [8] foi realizado pelos autores Subrat Das, Matthew Epland, Jiang Yu e Ranjit Suri [8]. O objetivo deste estudo foi a classificação de ECG entre sete classes clínicas: RBBB, AF, NORMAL, STD, I-AVB, STE e BVVV. Para isso, foram utilizadas convoluções 2D com imagens contendo os sinais de ECG.

O banco de dados utilizado foi o *2018 China Physiological Signal Challenge (CPSC)*[54],

que contém 6877 exames com durações entre 6 e 60 segundos, registrados em 12 canais.

O pré-processamento dos dados envolveu várias etapas. Primeiramente, foram removidas as entradas na classe "outros" e aquelas com múltiplas classes. Em seguida, os conjuntos de dados foram separados entre treinamento e teste, garantindo que o mesmo paciente não estivesse presente em ambos. Os exames foram segmentados em imagens contendo 2.5 segundos de cada canal, conforme ilustrado na Figura 11.

O modelo proposto utilizou uma variação do modelo pré-treinado *MobileNetV3*, que é um modelo pronto e customizável. Os resultados do modelo estão apresentados na Tabela 6.



Figura 11 – Entrada do modelo CNN proposto em [8]

	<b>Precision</b>	<b>Recall</b>	<b>F1-score</b>
Normal	0,710	0,679	0,694
AF	0,907	0,870	0,888
I-ABV	0,712	0,857	0,778
LBBB	0,711	0,853	0,775
RBBB	0,892	0,826	0,858
STD	0,728	0,731	0,729
STE	0,525	0,572	0,547

Tabela 6 – Resultados do trabalho 4

## 5 DESAFIOS E LIMITAÇÕES

Apesar de promissor, o uso de Redes Neurais Convolucionais (CNNs) na avaliação de exames de ECG enfrenta desafios significativos. Um dos principais é a necessidade de grandes volumes de dados; as CNNs requerem extensas bases de dados para tratar problemas complexos efetivamente [55]. Além disso, a coleta de dados sensíveis de saúde envolve complexidades legais e éticas consideráveis [56]. Outro desafio relevante é a consistência dos dados disponíveis. Muitos conjuntos de dados são desatualizados, limitados e inconsistentes, o que exige uma atenção meticulosa no tratamento dos dados para assegurar homogeneidade e evitar a introdução de vieses indesejados. Um exemplo desta limitação é a falta de variedade étnica e etária, sendo uma parcela desproporcional dos sujeitos avaliados idosos e de origem geográfica concentrada em poucos países [57]. Outras limitações advêm do fato de que redes neurais são consideradas "caixas pretas", pois seu funcionamento exato é obscuro [58]. Isto recorre em alguns desafios inesperados e ainda pouco compreendidos, por exemplo:

- **Confabilidade:** A alta sensibilidade dos procedimentos médicos requer que técnicas cujo funcionamento não é completamente entendido sejam utilizadas com cautela, sob constante supervisão humana.
- **Generalidade:** Estes modelos tendem a não performar bem em condições atípicas, como doenças raras ou que se apresentam de forma anormal. Outra possível fonte de inconsistência é o uso de equipamentos diferentes na coleta dos exames [59].

## 6 CONCLUSÃO

O estudo detalhado das particularidades dos exames de ECG, bem como das características, funcionamento e capacidades dos modelos de Redes Neurais Convolucionais (CNNs), demonstrou um promissor potencial para a aplicação dessas tecnologias na área da saúde. A análise automatizada de ECGs pode trazer significativos benefícios, especialmente na precisão diagnóstica e na acessibilidade do atendimento médico, particularmente em regiões onde há escassez de especialistas.

As CNNs, com sua habilidade de aprender características relevantes dos dados de forma autônoma, mostraram-se eficazes na identificação de anomalias cardíacas, apresentando altos índices de sensibilidade e especificidade em diversos estudos analisados. Este trabalho reforça a viabilidade do uso de CNNs para a análise de sinais cardíacos e aponta para a possibilidade de sua implementação em dispositivos portáteis de monitoramento, oferecendo uma abordagem mais acessível e eficiente para o diagnóstico de doenças cardiovasculares.

No entanto, é importante ressaltar que a adoção dessas tecnologias enfrenta desafios, como a necessidade de grandes volumes de dados para treinamento, questões de privacidade e segurança dos dados de saúde, e a complexidade legal e ética envolvida. Além disso, a variabilidade e a qualidade dos dados disponíveis são fatores que precisam ser cuidadosamente gerenciados para garantir a confiabilidade dos modelos.

Futuras pesquisas devem focar na melhoria contínua dos modelos, na ampliação das bases de dados com maior diversidade étnica e etária, e no desenvolvimento de soluções que integrem essas tecnologias de forma segura e eficiente nos sistemas de saúde. Assim, espera-se que as CNNs possam, em um futuro próximo, transformar a prática médica, proporcionando diagnósticos mais rápidos, precisos e acessíveis.

### 6.1 Próximas etapas deste trabalho

A seguir serão apresentadas as próximas etapas deste trabalho, que ainda está em desenvolvimento

1. Estudo sobre a construção do modelo de redes neurais para melhor compreender os componentes disponíveis, sua função e aplicabilidade, assim como estudo e avaliação de modelos existente já testados e bem avaliados;
2. Estudo das bases de dados de exames de ECG livremente disponíveis e escolha da(s) mais apropriada(s);

3. Estudo sobre exames de ECG, sua leitura e interpretação assim como identificação das anomalias cardíacas mais importantes;
4. Definição da arquitetura de entrada e saída, número de classes, e metodologias de avaliação de resultados
5. Determinação de métodos de pré-processamento dos dados;
6. Implementação dos modelos com as classes: normal, anormal;
7. Implementação dos modelos com as classes: normal, anormal, ruído;
8. Determinação de quais e quantas anomalias serão classificadas na etapa posterior;
9. Implementação dos modelos com as classes: normal, anomalias específicas, anormal, ruído;
10. Análise dos resultados
11. Escrita da versão final do TCC e preparação para a defesa;

	jun	jul	ago	set	out
Atividade 1	X				
Atividade 2	X	X			
Atividade 3	X	X			
Atividade 4		X			
Atividade 5		X			
Atividade 6			X		
Atividade 7			X		
Atividade 8			X	X	
Atividade 9				X	
Atividade 10				X	
Atividade 11					X

## REFERÊNCIAS

- [1] ISIN, A.; OZDALILI, S. Cardiac arrhythmia detection using deep learning. *Procedia Computer Science*, v. 120, p. 268–275, 2017. ISSN 1877-0509. 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, ICSCCW 2017, 22-23 August 2017, Budapest, Hungary. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187705091732450X>>.
- [2] BERKAYA, S. K. et al. A survey on ecg analysis. *Biomedical Signal Processing and Control*, Elsevier, v. 43, p. 216–235, 2018.
- [3] LUZ, E. J. da S. et al. Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, v. 127, p. 144–164, 2016. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260715003314>>.
- [4] PANCHAL, G. et al. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, v. 3, n. 2, p. 332–337, 2011.
- [5] LI, Z. et al. A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, v. 33, n. 12, p. 6999–7019, 2022.
- [6] SIMPLILEARN. *Convolutional Neural Network Tutorial*. s.d. Disponível em: <<https://www.simplilearn.com/tutorials/deep-learning-tutorial/convolutional-neural-network>>.
- [7] XU, X.; JEONG, S.; LI, J. Interpretation of electrocardiogram (ecg) rhythm by combined cnn and bilstm. *Ieee Access*, IEEE, v. 8, p. 125380–125388, 2020.
- [8] DAS, S. et al. Interpretation of ekg with image recognition and convolutional neural networks. *Current Problems in Cardiology*, Elsevier, p. 101744, 2023.
- [9] World Health Organization. *Cardiovascular diseases*. 2017. Disponível em: <<https://www.who.int/health-topics/cardiovascular-diseases>>.
- [10] CHAUHAN, S.; VIG, L. Anomaly detection in ecg time signals via deep long short-term memory networks. *2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, p. 1–7, 2015.
- [11] SCHEFFER, M. et al. Demografia médica no brasil-2018. In: *Demografia médica no Brasil-2018*. [S.l.: s.n.], 2018. p. 287–287.
- [12] SANGHA, V. et al. Automated multilabel diagnosis on electrocardiographic images and signals. *Nature Communications*, v. 13, 2021.
- [13] HOUGHTON, A. *Making sense of the ECG: a hands-on guide*. [S.l.]: CRC press, 2019.

- [14] PRICE, D. How to read an electrocardiogram (ecg). part 1: Basic principles of the ecg. the normal ecg. *South Sudan Medical Journal*, v. 3, n. 2, p. 26–31, 2010.
- [15] Kaplan Berkaya, S. et al. A survey on ecg analysis. *Biomedical Signal Processing and Control*, v. 43, p. 216–235, 2018. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809418300636>>.
- [16] ÜBEYLI, E. D. Adaptive neuro-fuzzy inference system for classification of ecg signals using lyapunov exponents. *Computer Methods and Programs in Biomedicine*, v. 93, n. 3, p. 313–321, 2009. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260708002599>>.
- [17] DUTTA, S.; CHATTERJEE, A.; MUNSHI, S. Identification of ecg beats from cross-spectrum information aided learning vector quantization. *Measurement*, v. 44, n. 10, p. 2020–2027, 2011. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224111002739>>.
- [18] TANTAWI, M. M. et al. A wavelet feature extraction method for electrocardiogram (ecg)-based biometric recognition. *Signal, Image and Video Processing*, Springer, v. 9, p. 1271–1280, 2015.
- [19] AGRAFIOTI, F.; HATZINAKOS, D. Ecg biometric analysis in cardiac irregularity conditions. *Signal, Image and Video Processing*, Springer, v. 3, n. 4, p. 329–343, 2009.
- [20] ORESKO, J. J. et al. A wearable smartphone-based platform for real-time cardiovascular disease detection via electrocardiogram processing. *IEEE Transactions on Information Technology in Biomedicine*, v. 14, n. 3, p. 734–740, 2010.
- [21] ALCARAZ, R.; HORNERO, F.; RIETA, J. J. Dynamic time warping applied to estimate atrial fibrillation temporal organization from the surface electrocardiogram. *Medical Engineering Physics*, v. 35, n. 9, p. 1341–1348, 2013. ISSN 1350-4533. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350453313000581>>.
- [22] CHUA, T. W.; TAN, W. W. Non-singleton genetic fuzzy logic system for arrhythmias classification. *Engineering Applications of Artificial Intelligence*, v. 24, n. 2, p. 251–259, 2011. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197610001892>>.
- [23] MANIKANDAN, M.; SOMAN, K. A novel method for detecting r-peaks in electrocardiogram (ecg) signal. *Biomedical Signal Processing and Control*, v. 7, n. 2, p. 118–128, 2012. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809411000292>>.
- [24] MANIKANDAN, M. S.; DANDAPAT, S. Wavelet-based electrocardiogram signal compression methods and their performances: A prospective review. *Biomedical Signal Processing and Control*, v. 14, p. 73–107, 2014. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809414000998>>.
- [25] PAN, J.; TOMPKINS, W. J. A real-time qrs detection algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32, n. 3, p. 230–236, 1985.

- [26] SHEN, T.; TOMPKINS, W.; HU, Y. One-lead ecg for identity verification. In: *Proceedings of the Second Joint 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society* [Engineering in Medicine and Biology. [S.l.: s.n.], 2002. v. 1, p. 62–63 vol.1.
- [27] MARTIS, R. J.; ACHARYA, U. R.; MIN, L. C. Ecg beat classification using pca, lda, ica and discrete wavelet transform. *Biomedical Signal Processing and Control*, v. 8, n. 5, p. 437–448, 2013. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809413000062>>.
- [28] YEH, Y.-C.; WANG, W.-J.; CHIOU, C. W. Cardiac arrhythmia diagnosis method using linear discriminant analysis on ecg signals. *Measurement*, v. 42, n. 5, p. 778–789, 2009. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224109000050>>.
- [29] KUTLU, Y.; KUNTALP, D. A multi-stage automatic arrhythmia recognition and classification system. *Computers in Biology and Medicine*, v. 41, n. 1, p. 37–45, 2011. ISSN 0010-4825. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0010482510001605>>.
- [30] KUTLU, Y.; KUNTALP, D. Feature extraction for ecg heartbeats using higher order statistics of wpd coefficients. *Computer Methods and Programs in Biomedicine*, v. 105, n. 3, p. 257–267, 2012. ISSN 0169-2607. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169260711002665>>.
- [31] ÖZBAY, Y. A new approach to detection of ecg arrhythmias: Complex discrete wavelet transform based complex valued artificial neural network. *Journal of Medical Systems*, Springer, v. 33, n. 6, p. 435–445, 2009.
- [32] PETMEZAS, G. et al. Automated atrial fibrillation detection using a hybrid cnn-lstm network on imbalanced ecg datasets. *Biomedical Signal Processing and Control*, v. 63, p. 102194, 2021. ISSN 1746-8094. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1746809420303323>>.
- [33] LUI, H. W.; CHOW, K. L. Multiclass classification of myocardial infarction with convolutional and recurrent neural networks for portable ecg devices. *Informatics in Medicine Unlocked*, v. 13, p. 26–33, 2018. ISSN 2352-9148. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352914818301333>>.
- [34] BALOGLU, U. B. et al. Classification of myocardial infarction with multi-lead ecg signals and deep cnn. *Pattern Recognition Letters*, v. 122, p. 23–30, 2019. ISSN 0167-8655. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016786551930056X>>.
- [35] SAZLI, M. H. A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, Ankara University, v. 50, n. 01, 2006.
- [36] CUI, H.; BAI, J. A new hyperparameters optimization method for convolutional neural networks. *Pattern Recognition Letters*, v. 125, p. 828–834, 2019. ISSN 0167-8655. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167865519300327>>.

- [37] 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.
- [38] WANAS, N. et al. On the optimal number of hidden nodes in a neural network. *Conference Proceedings. IEEE Canadian Conference on Electrical and Computer Engineering (Cat. No.98TH8341)*, v. 2, p. 918–921 vol.2, 1998.
- [39] ZHANG, Z.; MA, X.; YANG, Y. Bounds on the number of hidden neurons in three-layer binary neural networks. *Neural networks : the official journal of the International Neural Network Society*, v. 16 7, p. 995–1002, 2003.
- [40] SZANDAŁA, T. Review and comparison of commonly used activation functions for deep neural networks. In: \_\_\_\_\_. *Bio-inspired Neurocomputing*. Singapore: Springer Singapore, 2021. p. 203–224. ISBN 978-981-15-5495-7. Disponível em: <[https://doi.org/10.1007/978-981-15-5495-7\\_11](https://doi.org/10.1007/978-981-15-5495-7_11)>.
- [41] AGARAP, A. F. Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*, 2018.
- [42] NIERADZIK, L. et al. Effect of the output activation function on the probabilities and errors in medical image segmentation. *arXiv preprint arXiv:2109.00903*, 2021.
- [43] MASTROMICHALAKIS, S. Alrelu: A different approach on leaky relu activation function to improve neural networks performance. *arXiv preprint arXiv:2012.07564*, 2020.
- [44] CHO, K. et al. A performance comparison of loss functions. In: *2019 International Conference on Information and Communication Technology Convergence (ICTC)*. [S.l.: s.n.], 2019. p. 1146–1151.
- [45] PANG, Y. et al. Convolution in convolution for network in network. *IEEE Transactions on Neural Networks and Learning Systems*, v. 29, n. 5, p. 1587–1597, 2018.
- [46] GU, J. et al. Recent advances in convolutional neural networks. *Pattern Recognition*, v. 77, p. 354–377, 2018. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320317304120>>.
- [47] LUDWIG, J. Image convolution. *Portland State University*, 2013.
- [48] JUNG, J. H.; SHIN, Y.; KWON, Y. Extension of convolutional neural network with general image processing kernels. In: *TENCON 2018 - 2018 IEEE Region 10 Conference*. [S.l.: s.n.], 2018. p. 1436–1439.
- [49] YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, Springer, v. 9, p. 611–629, 2018.
- [50] SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [51] BOUSSELJOT, R.; KREISELER, D.; SCHNABEL, A. Nutzung der ekg-signal-datenbank cardiodat der ptb über das internet. *Biomedical Engineering / Biomedizinische Technik*, v. 40, n. s1, p. 317–318, 1995. Disponível em: <<https://doi.org/10.1515/bmte.1995.40.s1.317>>.

- [52] CLIFFORD, G. D. et al. Af classification from a short single lead ecg recording: The physionet/computing in cardiology challenge 2017. In: *2017 Computing in Cardiology (CinC)*. [S.l.: s.n.], 2017. p. 1–4.
- [53] MOODY, R. M. G. Mit-bih arrhythmia database. *Proc. PhysioNet*, 2005.
- [54] WANG, X. et al. Paroxysmal atrial fibrillation events detection from dynamic ecg recordings: The 4th china physiological signal challenge 2021. *Proc. PhysioNet*, p. 1–83, 2021.
- [55] ANTONIOU, A.; STORKEY, A.; EDWARDS, H. Data augmentation generative adversarial networks. *arXiv preprint arXiv:1711.04340*, 2017.
- [56] PRICE, W. N.; COHEN, I. G. Privacy in the age of medical big data. *Nature medicine*, Nature Publishing Group US New York, v. 25, n. 1, p. 37–43, 2019.
- [57] LI, J. et al. Cross-ethnicity/race generalization failure of behavioral prediction from resting-state functional connectivity. *Science Advances*, v. 8, n. 11, p. eabj1812, 2022. Disponível em: <<https://www.science.org/doi/abs/10.1126/sciadv.abj1812>>.
- [58] DUCH, W. Coloring black boxes: visualization of neural network decisions. In: *Proceedings of the International Joint Conference on Neural Networks, 2003*. [S.l.: s.n.], 2003. v. 3, p. 1735–1740 vol.3.
- [59] ABDELKARIM, M.; ELADAWI, R. Tcp-net++: Test case prioritization using end-to-end deep neural networks - deployment analysis and enhancements. *2023 IEEE International Conference On Artificial Intelligence Testing (AITest)*, p. 99–106, 2023.