

# Análise Eletrocardiograma (ECG) com Redes Neurais Convolucionais (CNN)

Victor Hugo Cercasin Poyer Nogueira<sup>1</sup>, Wesley Attrot<sup>1</sup>, Fábio Sakuray<sup>1</sup>

<sup>1</sup>Departamento de Computação – Universidade Estadual de Londrina (UEL)  
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

victorhugo.cercsain@uel.br, wesley@uel.br, sakuray@uel.br


**Abstract.** *Electrocardiogram (ECG) exams are essential in diagnosing numerous heart diseases and conditions such as myocardial infarction, fibrillation and cardiac arrhythmias. These exams may last up to 24 hours in everyday situations, or even permanently with the use of wearables, such as smartwatches. In the proposed work, we will investigate and assess the feasibility of using Convolutional Neural Networks (CNNs) in the analysis of such exams, thereby facilitating the work of physicians.*

**Resumo.** *Os exames de eletrocardiograma (ECGs) são essenciais no diagnóstico de inúmeras doenças e condições cardíacas, como infarto do miocárdio, fibrilação e arritmias cardíacas. Esses exames podem cotidianamente durar até 24 horas, ou até permanentemente no caso dos wearables, como relógios inteligentes. No trabalho proposto, investigaremos e avaliaremos a viabilidade do uso da técnica das Redes Neurais Convolucionais (CNNs) na análise de tais exames, facilitando o trabalho dos médicos.*

## 1. Introdução

O sinal obtido no exame de eletrocardiograma (ECG) representa a atividade elétrica do coração e pode ser utilizado para diversos fins, desde determinação de frequência cardíaca, avaliação do ritmo cardíaco e detecção de anomalias [10]. Um batimento cardíaco é composto por 3 ondas principais: onda P, desencadeada da despolarização (ativação) dos átrios, o complexo QRS, que representa a despolarização dos ventrículos, e a onda T, que representa a repolarização (recarga) dos ventrículos [22], como mostrado na figura 1. A localização dos picos dessas ondas são conhecidos como pontos fiduciais, e a amplitude desses pontos, bem como sua frequência e posição relativa possibilitam a classificação do batimento como normal ou anormal [8].

O complexo PQRT (batimento cardíaco) varia de pessoa para pessoa e ainda diferente indivíduos podem apresentar características distintas para a mesma doença[10], e além disso, duas doenças diferentes podem apresentar propriedades similares, tornando a identificação correta e generalista de pontos fiduciais e o diagnóstico de doenças cardíacas através do ECG, uma tarefa difícil [10]. Métodos que tentam extrair a posição dos pontos fiduciais graficamente também encontram problemas, pois algumas condições cardíacas podem causar inversão de picos, duplicação de picos ou até mesmo o desaparecimento completo deles. Também podem ocorrer problemas na captura do ECG, como choques mecânicos nos sensores e movimento exagerado do paciente, gerando sinais erráticos que não representam os batimentos do paciente.



**Figura 1. Batimento cardíaco saudável**  
Fonte: [9]

Com os avanços técnicos, teóricos e práticos na área de redes neurais artificiais (*Artificial Neural Networks* - ANNs), abre-se a oportunidade de utilizá-las para abordar o problema em questão. Em particular, a variação denominada rede neural convolucional (*Convolutional Neural Networks* - CNN) se mostra altamente adequada para situações em que a extração de características é particularmente desafiadora [13].

## **2. Fundamentação Teórico-Methodológica e Estado da Arte**

Segundo S. Kaplan Berkaya *et al.* [10], o campo de análise de ECG apresenta as seguintes fases: pré-processamento, extração de características e classificação. A seguir serão detalhas cada uma delas, e as CNNs.

### **2.1. Pré-Processamento**

Imperfeições inerentes do processo de coleta do ECG causam diversos tipos de interferência no sinal das sondas. Essas interferências fazem com que o sinal fique mais ruidoso, dificultando sua interpretação. São fontes comuns de interferência 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. Esse processo consiste na decomposição do sinal em suas frequências fundamentais e a seleção de uma faixa estreita de frequências de modo a filtrar ruídos. A banda de frequências mais utilizada é 0,1 - 100Hz [27], [6]. Outras bandas, como 1 - 40Hz, também são utilizadas [24], [2]. Filtros de passa-baixa [18], passa-alta [3] e filtro rejeita-faixa [5] também podem ser utilizados.

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.

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 [16], [15].

### **2.2. 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.

Pode-se aproximar a extração de características de várias formas dependendo do tipo de classificação desejada. Uma forma bastante utilizada é a extração de características estatísticas, como energia, média, desvio padrão, máximo, mínimo, curtose e assimetria [10].

Outro tipo de característica e o foco deste trabalho são os pontos fiduciais. Algumas técnicas utilizadas na extração desses pontos são o algoritmo de Pan Tompkins [20], no qual uma série de filtragens é aplicada ao sinal, destacando os picos do complexo QRS e suavizando os demais sinais. Outros métodos utiliza variações da técnica de transformada *wavelet*, que utiliza *wavelets*, pequenas ondas que obedecem certas relações matemática, para extração de pontos fiduciais [24], [23].

### 2.3. Classificação

Após a extração de características, é possível classificar o batimento cardíaco. São algumas das técnicas de classificação: a análise de discriminante linear (LDA), que busca maximizar a distância entre-classes enquanto minimiza a distância intra-classes [17], [25]. k-vizinhos mais próximos (KNN) é um algoritmo simples que classifica um vetor desconhecido de acordo com a proximidade para k-vizinhos conhecidos em um sistema de votação [11], [12]. Redes neurais artificiais (ANNs) também podem ser utilizadas na etapa de classificação. São modelos matemáticos inspirados na biologia das redes neurais, com neurônios interconectados que são ativados por neurônios vizinhos. ANNs podem resolver problemas de classificação linear ou não linear com diversas estruturas de aprendizado e algoritmos. Exemplos de estruturas de classificação são as redes neurais recorrentes, que possuem neurônios de auto alimentação [6], redes neurais de valor complexo, que utilizam números complexos nos valores de ativação [19], funções de ativação e vieses.

### 2.4. Redes Neurais Convolucionais (CNNs)

A CNN é uma das variações mais significativos de redes neurais no campo de *deep learning* [13]. Esse tipo de rede neural utiliza uma ou mais camadas convolucionais dentro de uma arquitetura profunda. Essas camadas tem como característica o uso do processo matemático de convolução para a extração de características da entrada. O principal diferencial dessa técnica é que, ao contrário de outras técnicas de redes neurais, não é necessário realizar a extração de características dos dados de entrada. Dessa forma, uma maior dimensão de dados pode ser inserida nos neurônios de entrada, e por isso, ela tem sido utilizada largamente na classificação de imagens [10]. Essa característica torna o uso das CNNs na identificação de anomalias cardíacas na análise de ECGs bastante promissor, pois dispensa a etapa problemática de extração de características. Embora essa técnica seja mais utilizada em dados bidimensionais como imagens, o uso em dados unidimensionais como análise de sinais está crescendo. Shubhi Harbola e Volker Coors [7] propuseram um modelo de entrada unidimensional para a predição de direção e velocidade do vento com resultados variando entre 85,4 a 99,7% de precisão. Osama Abdeljaber *et al.* [1] apresenta uma CNN compacta para a detecção de falha em rolamentos, com precisão acima de 99%. As CNNs também estão sendo largamente utilizada na área de análise de ECG, com resultados promissores. Zhang, Dian Zhou, e Xuan Zen [26] utilizam uma CNN para realizar identificação biométrica de humanos, com precisão média de 93,5%. Georgios Petmezas *et al.* [21] propuseram modelos para a predição de fibrilação atrial,

com precisão de 98,70% e entre 55,36% a 98,48%, respectivamente. Hin Wai Lui e King Lau Chow [14] e Ulas Baran Baloglu *et al.* [4] utilizaram as CNNs para a detecção de infartos do miocárdio, com 97,2% e 99,6% de precisão.

### 3. Objetivos

O objetivo do presente trabalho é avaliar o desempenho das redes neurais convolucionais (CNNs) na detecção automática de anomalias cardíacas no exame de ECG. Serão testadas diversas variações de CNN (arquiteturas) e avaliados pelos marcadores de desempenho apropriados, como acurácia, precisão e *F1 score*.

### 4. Procedimentos metodológicos/Métodos e técnicas

Neste estudo, utilizaremos uma rede neural convolucional (CNN) para realizar a classificação de batimentos cardíacos. Para tal, a linguagem python e a biblioteca PyTorch (entre outras) serão utilizadas para importação e pré-tratamento dos dados, além da construção, treinamento e avaliação do modelo CNN. Inicialmente, o *Google Colab* será utilizado como plataforma de desenvolvimento devido ao acesso gratuito a recursos computacionais em nuvem e uso generalizado na indústria para desenvolvimento de redes neurais. Pretende-se avaliar o comportamento das CNNs de forma abrangente para aferir suas limitações e performance. Para tal, as CNNs serão testadas nos seguintes cenários:

1. **Batimento normal e anormal** : classificação entre batimento normal e anormal;
2. **Batimento normal, anormal e ruído**. Espera-se que a adição da classe ruído melhore a precisão do modelo, pois alguns batimentos apresentam níveis de distorção grande demais para a avaliação precisa;
3. **Batimento normal, anomalia A , ..., anomalia n, anormal, ruído**. Como a classe "anormal" compreende diversas condições cardíacas, é possível subclassificá-la. Neste cenário serão classificadas tipos distintos de anomalia, bem como batimentos normais e anomalias não especificadas. Espera-se determinar a severidade da perda de performance ao aumentar o número de classes devido ao aumento de complexidade.

Os conjuntos de dados a serem utilizados no treinamento e teste do modelo ainda não foram determinados, mas entre os conjuntos mais comumente utilizados estão o *The Massachusetts Institute of Technology-Beth Israel Hospital (MIT-BIH) Arrhythmia database*, conhecida como MIT-BIH e *Physionet PTB Diagnostic ECG database*.

### 5. Cronograma de Execução

1. Escrita do projeto de TCC para o dia 04/03;
2. Estudo e escolha da melhor plataforma e biblioteca(s) para desenvolvimento.;
3. Métodos anteriores de análise automática de ECGs, seu escopo e resultados;
4. Estudo das bases de dados de exames de ECG livremente disponíveis e escolha da(s) mais apropriada(s);
5. Estudo sobre exames de ECG, sua leitura e interpretação assim como identificação das anomalias cardíacas mais importantes;
6. Base teórica para a compreensão do funcionamento de redes neurais, suas variações e capacidades, em especial as redes neurais convolucionais (CNNs);

7. 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;
8. Estudo sobre a localização, download, importação e manipulação de dados na plataforma de desenvolvimento escolhida;
9. Escrita da Versão Preliminar do TCC para o dia 20/05/24;
10. Reprodução de resultados de estudos em áreas adjacentes;
11. Determinação de métodos de pré-tratamento dos dados;
12. Arquitetura de entrada e saída, número de classes, metodologias de avaliação de resultados
13. Implementação dos modelos com as classes: normal, anormal;
14. Implementação dos modelos com as classes: normal, anormal, ruído;
15. Determinação de quais e quantas anomalias serão classificadas na etapa posterior;
16. Implementação dos modelos com as classes: normal, anomalias específicas, anormal, ruído;
17. Escrita da versão final do TCC ;

	fev	mar	abr	mai	jun	jul	ago	set	out	nov
Atividade 1	X									
Atividade 2	X									
Atividade 3	X	X								
Atividade 4	X	X								
Atividade 5	X	X	X							
Atividade 6	X	X	X							
Atividade 7		X	X							
Atividade 8			X							
Atividade 9			X	X						
Atividade 10				X	X					
Atividade 11					X					
Atividade 12						X				
Atividade 13						X				
Atividade 14						X				
Atividade 15							X			
Atividade 16							X	X		
Atividade 17								X	X	X

## 6. Contribuições e/ou Resultados esperados

Este estudo busca analisar o processo de desenvolvimento de CNNs para classificação de batimentos cardíacos em exame de ECG, avaliando sua viabilidade e limitações. Para isto é preciso também construir modelos com performance similar ou superior aos de outros trabalhos, assim como realizar testes de diversos modelos e técnicas, para que se verifique as abordagens mais promissoras.

## 7. Espaço para assinaturas

Londrina, vinte e oito de Fevereiro de 2024.

**Referências**

- [1] Osama Abdeljaber, Sadok Sassi, Onur Avci, Serkan Kiranyaz, Abdelrahman Aly Ibrahim, and Moncef Gabbouj. Fault detection and severity identification of ball bearings by online condition monitoring. *IEEE Transactions on Industrial Electronics*, 66(10):8136–8147, 2019.
- [2] Foteini Agrafioti and Dimitrios Hatzinakos. Ecg biometric analysis in cardiac irregularity conditions. *Signal, Image and Video Processing*, 3(4):329–343, 2009.
- [3] Raúl Alcaraz, Fernando Hornero, and José Joaquín Rieta. Dynamic time warping applied to estimate atrial fibrillation temporal organization from the surface electrocardiogram. *Medical Engineering Physics*, 35(9):1341–1348, 2013.
- [4] Ulas Baran Baloglu, Muhammed Talo, Ozal Yildirim, Ru San Tan, and U Rajendra Acharya. Classification of myocardial infarction with multi-lead ecg signals and deep cnn. *Pattern Recognition Letters*, 122:23–30, 2019.
- [5] Teck Wee Chua and Woei Wan Tan. Non-singleton genetic fuzzy logic system for arrhythmias classification. *Engineering Applications of Artificial Intelligence*, 24(2):251–259, 2011.
- [6] Saibal Dutta, Amitava Chatterjee, and Sugata Munshi. Identification of ecg beats from cross-spectrum information aided learning vector quantization. *Measurement*, 44(10):2020–2027, 2011.
- [7] Shubhi Harbola and Volker Coors. One dimensional convolutional neural network architectures for wind prediction. *Energy Conversion and Management*, 195:70–75, 2019.
- [8] Andrew Houghton. *Making sense of the ECG: a hands-on guide*. CRC press, 2019.
- [9] Ali Isin and Selen Ozdalili. Cardiac arrhythmia detection using deep learning. *Procedia Computer Science*, 120:268–275, 2017. 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, ICSCCW 2017, 22-23 August 2017, Budapest, Hungary.
- [10] Selcan Kaplan Berkaya, Alper Kursat Uysal, Efnan Sora Gunal, Semih Ergin, Serkan Gunal, and M. Bilginer Gulmezoglu. A survey on ecg analysis. *Biomedical Signal Processing and Control*, 43:216–235, 2018.
- [11] Yakup Kutlu and Damla Kuntalp. A multi-stage automatic arrhythmia recognition and classification system. *Computers in Biology and Medicine*, 41(1):37–45, 2011.
- [12] Yakup Kutlu and Damla Kuntalp. Feature extraction for ecg heartbeats using higher order statistics of wpd coefficients. *Computer Methods and Programs in Biomedicine*, 105(3):257–267, 2012.
- [13] Zewen Li, Fan Liu, Wenjie Yang, Shouheng Peng, and Jun Zhou. A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12):6999–7019, 2022.

- [14] Hin Wai Lui and King Lau Chow. Multiclass classification of myocardial infarction with convolutional and recurrent neural networks for portable ecg devices. *Informatics in Medicine Unlocked*, 13:26–33, 2018.
- [15] M. Sabarimalai Manikandan and S. Dandapat. Wavelet-based electrocardiogram signal compression methods and their performances: A prospective review. *Biomedical Signal Processing and Control*, 14:73–107, 2014.
- [16] M.Sabarimalai Manikandan and K.P. Soman. A novel method for detecting r-peaks in electrocardiogram (ecg) signal. *Biomedical Signal Processing and Control*, 7(2):118–128, 2012.
- [17] Roshan Joy Martis, U. Rajendra Acharya, and Lim Choo Min. Ecg beat classification using pca, lda, ica and discrete wavelet transform. *Biomedical Signal Processing and Control*, 8(5):437–448, 2013.
- [18] Joseph J. Oresko, Zhanpeng Jin, Jun Cheng, Shimeng Huang, Yuwen Sun, Heather Duschl, and Allen C. Cheng. A wearable smartphone-based platform for real-time cardiovascular disease detection via electrocardiogram processing. *IEEE Transactions on Information Technology in Biomedicine*, 14(3):734–740, 2010.
- [19] Yüksel Özbay. A new approach to detection of ecg arrhythmias: Complex discrete wavelet transform based complex valued artificial neural network. *Journal of Medical Systems*, 33(6):435–445, 2009.
- [20] Jiapu Pan and Willis J. Tompkins. A real-time qrs detection algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32(3):230–236, 1985.
- [21] Georgios Petmezas, Kostas Haris, Leandros Stefanopoulos, Vassilis Kilintzis, Andreas Tzavelis, John A Rogers, Aggelos K Katsaggelos, and Nicos Maglaveras. Automated atrial fibrillation detection using a hybrid cnn-lstm network on imbalanced ecg datasets. *Biomedical Signal Processing and Control*, 63:102194, 2021.
- [22] Dallas Price. How to read an electrocardiogram (ecg). part 1: Basic principles of the ecg. the normal ecg. *South Sudan Medical Journal*, 3:26–31, 2010.
- [23] T.W. Shen, W.J. Tompkins, and Y.H. Hu. 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, volume 1, pages 62–63 vol.1, 2002.
- [24] Manal M Tantawi, Kenneth Revett, Abdel-Badeeh Salem, and Mohamed F Tolba. A wavelet feature extraction method for electrocardiogram (ecg)-based biometric recognition. *Signal, Image and Video Processing*, 9:1271–1280, 2015.
- [25] Yun-Chi Yeh, Wen-June Wang, and Che Wun Chiou. Cardiac arrhythmia diagnosis method using linear discriminant analysis on ecg signals. *Measurement*, 42(5):778–789, 2009.
- [26] Qingxue Zhang, Dian Zhou, and Xuan Zeng. Heartid: A multiresolution convolutional neural network for ecg-based biometric human identification in smart health applications. *IEEE Access*, 5:11805–11816, 2017.

- [27] Elif Derya Übeyli. Adaptive neuro-fuzzy inference system for classification of ecg signals using lyapunov exponents. *Computer Methods and Programs in Biomedicine*, 93(3):313–321, 2009.