



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

XXIX SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS **SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2025**

Modelo computacional para imagens bioelétricas cardíacas usando várias técnicas de extração de características usando CNN

Giovanna Venas Oliveira¹; Gilney Figueira Zebende²

¹ Bolsista PIBIC/FAPESB, Graduando em Biologia, Departamento de Biologia da Universidade Estadual de Feira de Santana, e-mail: giovannavenasuefs@gmail.com

² Gilney Figueira Zebende. Departamento de Física, e-mail: gfigzebende@uefs.br

PALAVRAS-CHAVE: ECGs, CNN, Imagens bioelétricas cardíacas

INTRODUÇÃO

O coração é essencial para a homeostase, distribuindo nutrientes e oxigênio pelo sistema circulatório, e sua função de bombeamento é controlada pela atividade bioelétrica autônoma do miocárdio. Durante cada ciclo cardíaco, potenciais elétricos se propagam pelo tórax e, quando registrados na superfície, dão origem a eletrocardiogramas (ECGs) [1]. Os ECGs não apenas refletem a dinâmica elétrica do coração, mas também fornecem informações diagnósticas cruciais para a identificação de arritmias, infartos, insuficiências, bloqueios e alterações isquêmicas [2].

A análise avançada de sinais, utilizando técnicas como a Transformada de Hilbert-Huang (HHT), a Transformada de Fourier (FFT), os Coeficientes Centrais de Frequência de Mel (MFCCs) e a Transformada Wavelet Discreta (DWT), permite uma compreensão detalhada dos fenômenos eletrofisiológicos, contribuindo para o desenvolvimento de tecnologias médicas inovadoras e tratamentos personalizados [19]. Nesse contexto, a extração de características visa reduzir a dimensionalidade e comprimir os dados, retraindo informações essenciais.

Facilita seu uso em modelos de aprendizado de máquina e inteligência artificial para aplicações como classificação e diagnóstico automatizado [5]. Assim, apesar da dependência histórica da expertise clínica para a interpretação de ECG, a crescente adoção de sistemas computadorizados busca mitigar as limitações humanas, aumentando a precisão da identificação precoce de anomalias cardíacas [6], [7] e [15].

A seleção do método de extração de características está diretamente ligada a aplicações específicas e às limitações dos recursos disponíveis. Este estudo propõe uma avaliação comparativa de diferentes técnicas de extração de características de ECG, incluindo HHT, FFT, MFCCs e DWT, considerando sua aplicabilidade em interface com modelos de Redes Neurais Convolucionais (CNN). Para tanto, um conjunto de dados composto por 197 sinais de ECG serviu de base. Destes, 55 eram de arritmias cardíacas (RRA), 55 de infarto do miocárdio (IM), 57 com ritmo sinusal normal (RSN) e 30 de insuficiência cardíaca congestiva (ICC). Além disso, a equipe utilizou 167 sinais de ECG para o

conjunto de treinamento do modelo CNN e selecionou 30 sinais (8 ARR, 7 MI, 10 NSR e 5 CHF) para o conjunto de teste.

A análise comparativa das técnicas de transformação para identificação de eventos transientes em sinais de ECG revelou características distintas e complementares. Nesse sentido, a escolha da técnica mais adequada para análise depende das características específicas do sinal, dos objetivos da análise e dos recursos computacionais disponíveis. Neste trabalho apresentam-se e se discutem os resultados obtidos, comparando-os com achados de estudos semelhantes e avaliando-os utilizando a matriz de confusão gerada durante o treinamento e teste do modelo CNN, o que permite uma análise mais aprofundada da abordagem do modelo computacional proposto.

MATERIAL E MÉTODOS OU METODOLOGIA (ou equivalente)

A Figura 1 ilustra o sistema proposto para identificação de disfunções cardíacas com base em sinais de ECG, aplicando redes CNN. Está estruturado em a fase de pré-processamento dos sinais crus de ECGs, depois temos a etapa de aplicação das técnicas de extração de parâmetros (HHT, FFT, DWT e MFCCs), logo a seguir, a fase de registro e geração do conjunto de dados de treinamento e testes. Na última fase teremos aplicação da rede CNN para treinamento e validação, para a classificação das disfunções cardíacas.




Fig. 1: O diagrama representa o processo de extração de características do ECG.

Rede Neural Convolutacional (CNN) e Conjunto de Dados

Após a construção dos conjuntos de dados obtidos a partir das características e métodos de extração, os dados são submetidos à CNN genérica para processamento e classificação dos sinais de ECG. A CNN implementada é estruturada em várias etapas, começando com a instalação de bibliotecas essenciais, incluindo EMD-signal, pyht, pywavelets e librosa, no ambiente Colab, que executa código em Python.

O conjunto de dados consiste em 197 sinais de ECG obtidos do repositório PhysioNet e categorizados em quatro classes: 55 ARR, 55 MI, 57 NSR e 30 sinais de ECG de CHF. O conjunto de dados foi dividido em um conjunto de treinamento composto por 167 sinais e um conjunto de teste com 30 sinais, distribuídos da seguinte forma: 8 ARR, 7 MI, 10 NSR e 5 CHF. Esse padrão foi mantido para cada método de extração de características, formando assim uma amostragem estratificada para manter a distribuição das classes. Portanto, cada sinal passa por decomposição HHT, FFT, MFCCs e DWT, sendo armazenado juntamente com seus rótulos, que servirão como entrada para a rede neural convolutacional. A arquitetura CNN é projetada com múltiplas camadas convolucionais e de agrupamento, seguidas por camadas totalmente conectadas e uma camada de saída softmax.

Na figura 2 é possível identificar formas de onda típicas de diferentes problemas cardíacos. O sinal ARR mostra as chamadas arritmias, o tipo CHF ou “orelha de coelho” mostra o segmento QRS com maior duração ou espessura em comparação ao ritmo NSR que mostra um sinal de ECG com frequência cardíaca normal. O sinal de ECG tipo MI mostra elevação do segmento ST.




Figura 2. Exemplos de sinais de ECG associados a diferentes estados de saúde cardíaca ou categorias de batimentos cardíacos: (a) ARR, (b) CHF, (c) IM, (d) NSR.

RESULTADOS E/OU DISCUSSÃO (ou Análise e discussão dos resultados)

Aqui apresentamos os resultados do modelo CNN treinado com as características extraídas, avaliando a eficácia de cada técnica na diferenciação das quatro condições cardíacas. Matrizes de confusão e métricas de desempenho são fornecidas para ilustrar as capacidades de classificação do modelo, facilitando uma avaliação comparativa dos métodos de extração de características empregados. Na Figura 3 mostramos um sinal ECG diagnosticado com IM, processado usando a Transformada de Fourier. As FFT permitem a identificação de componentes de frequência associados a diferentes condições cardíacas.




Figura 3. Exemplo de sinal ECG com os primeiros 1.000 pontos, diagnosticado com IM, processado pela Transformada de Fourier.

Por fim, o método da DWT oferece localização precisa nos domínios do tempo e da frequência, segmentando automaticamente as ondas do ECG e permitindo a análise detalhada de cada componente. Por meio de sua decomposição multiescala, destaca a energia do complexo QRS em bandas específicas, facilitando a identificação de anormalidades. A Tabela II apresenta o relatório de classificação para o conjunto de testes considerando as diferentes técnicas de extração de características (HHT, FFT, MFCC e DWT).

Tabela II: Classificação do conjunto de testes para os métodos de extração de características.

Metric	HHT	FFT	MFCC	DWT
Arrhythmia				
Precision	0.83	0.47	1.00	0.88
Recall	0.71	1.00	1.00	1.00
F1-score	0.77	0.64	1.00	0.93
Instances	7	7	7	7
Myocardial Infarction				
Precision	1.00	1.00	1.00	1.00
Recall	1.00	1.00	1.00	1.00
F1-score	1.00	1.00	1.00	1.00
Instances	5	5	5	5
Heart Failure				
Precision	0.78	0.00	0.00	1.00
Recall	0.88	0.00	0.00	0.88
F1-score	0.82	0.00	0.00	0.93
Instances	8	8	8	8
Normal				
Precision	1.00	1.00	0.56	1.00
Recall	1.00	1.00	1.00	1.00
F1-score	1.00	1.00	0.71	1.00
Instances	10	10	10	10
Overall Metric				
Accuracy	0.90	0.73	0.73	0.97




Figura 4. Matrizes de confusão para classificação de ECG para métodos de extração de características.

Os valores de precisão, recall e pontuação F1 são relatados para as quatro classes de sinais cardíacos (ARR, IM, CHF e NSR), juntamente com o número de instâncias em cada classe. A última linha mostra a precisão geral do modelo para cada técnica, destacando DWT (0,97) como a mais eficaz, seguida por HHT (0,90), enquanto FFT e MFCC apresentaram desempenho semelhante (0,73). A Figura 4 fornece uma representação visual das matrizes de confusão para cada método de extração de características.

CONSIDERAÇÕES FINAIS

Este estudo comparou técnicas de extração de características aplicadas a sinais de ECGs (HHT, FFT, MFCCs e DWT), destacando suas vantagens e limitações. A HHT provou ser eficaz para a detecção de anomalias e o prognóstico eficiente de distúrbios cardíacos, alcançando 90% de precisão no modelo CNN. A técnica DWT se destacou como a mais robusta, com 97% de precisão para identificar e prever anormalidades cardíacas.

REFERÊNCIAS

[1] Malmivuo, J. and Plonsey, R. (1995). Bioelectromagnetism: Principles and applications of bioelectric and biomagnetic fields. Oxford University Press, USA.

[2] Vaduganathan, M., Mensah, G. A., Turco, J. V., Fuster, V., and Roth, G. A. (2022). The global burden of cardiovascular diseases and risk: a compass for future health.

[3] “Estatística Cardiovascular – Brasil 2023,” Artigo Especial, Arquivos Brasileiros de Cardiologia, vol. 121, no. 2, fev. 2024, doi:10.36660/abc.20240079.