



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

Classificação de doenças cardíacas usando ECGs e aprendizado profundo de máquina

Alisson Lopes Rocha de Jesus¹; Juan A. Leyva-Cruz²

1. Bolsista PVC/CNPq, Graduando em Física, Departamento de Física da Universidade Estadual de Feira de Santana, e-mail: alirocha20111@gmail.com
2. Orientador, Departamento de Física, Universidade Estadual de Feira de Santana, e-mail: juan@uefs.br

PALAVRAS-CHAVE: CNN, ECG; aprendizagem profunda de máquina, coração.

INTRODUÇÃO

As doenças cardiovasculares (DCVs) são a principal causa de mortalidade em todo o mundo. Das 20,5 milhões de mortes relacionadas a DCVs em 2021, aproximadamente 80% ocorreram em países de baixa e média renda. Atualmente, a eletrocardiografia ainda é a melhor técnica para detectar anormalidades e inferir o estado de saúde do miocárdio. Apesar dos avanços científicos e tecnológicos na área da saúde, as DCVs são aproximadamente 27% de todas as mortes no Brasil [2, 3]. A eletrocardiografia é um exame que mede a atividade elétrica do coração e fornece informações relevantes sobre a saúde cardíaca, por meio do eletrocardiograma (ECG). Essas informações são fundamentais para o diagnóstico de diversas doenças. Num monitoramento longo a avaliação manual dos dados dos ECGs é um processo extremamente demorado. Os avanços tecnológicos no campo da eletrocardiografia e a escassez de profissionais cardiologistas motivaram o interesse na classificação automatizada de sinais de ECGs. Recentemente, as abordagens de Inteligência Artificial (IA) [4], em especial os métodos baseados em Redes Neurais de aprendizado profundo de máquina [5-7], têm atraído muita atenção, para a classificação de ECGs, e assim, a identificação dos estados de saúde do coração. Estes modelos computacionais apresentam a capacidade de distinção efetiva entre batimentos normais, arritmias e padrões de anormalidade da condução ventricular. Dessa forma, busca-se a otimização da velocidade e da precisão do diagnóstico, resultando em aprimoramento dos resultados para os pacientes. O método aqui apresentado é fundamentado em um modelo de Rede Neural Convolucional (CNN) que foi treinado e avaliado no conjunto de dados disponibilizados gratuitamente na internet [8]. Neste sentido, o objetivo principal deste trabalho é classificar quatro tipos diferentes de problemas cardíacos utilizando sinais de eletrocardiogramas humanos, utilizando transformadas *wavelet* contínuas (CWT) e a rede neural convolucional profunda RestNet, na plataforma Matlab.

MATERIAL E MÉTODOS

Banco de dados de ECGs

O uso de bancos de dados de ECGs gratuitos e de código aberto (Extraídos do site PhysioNet (<https://archive.fisionet.org/fisiobank/database>), bem anotados e validados, produz resultados comparáveis aos sinais do mundo real. Neste trabalho foram utilizadas quatro bases de dados diferentes. Os tipos de problemas cardíacos incluem pessoas com arritmia cardíaca (ARR), pessoas com insuficiência cardíaca congestiva (CHF) e pessoas com ritmo sinusal normal (NSR). Mais especificamente, foram utilizados 96 ECGs com IRA, 30 com ICC e 36 com RSN. A frequência de amostragem inicial foi de 400 Hz, mas os dados foram reduzidos para uma taxa comum de 128 Hz. O comprimento dos dados foi truncado para um tamanho comum de 65.536 amostras. O quarto banco de dados utilizado foi o banco de dados de ECG diagnóstico de PTB, que contém 549 ECGs em repouso usando 12 derivações cardíacas. Esses ECGs foram adquiridos com taxa de amostragem de 1000 Hz e resolução de 16 bits. Especificamente, foram utilizados 55 sinais de ECG com diagnóstico de infarto do miocárdio (IM) e 21 NSR.

2.2 Procedimento de aplicação de Rede Neural Convolucional

No diagrama da Figura 1 podemos observar que a metodologia de aplicação do método de aprendizagem profunda utilizando CNN é composta por cinco fases principais.




Figura 1. Diagrama de blocos da aplicação da CNN na classificação de ECGs

A Fase I representa o carregamento e inspeção dos sinais de ECG dos bancos de dados mencionados. A segunda fase é o pré-processamento do ECG, onde temos duas situações que tiveram que ser contornadas. A primeira está relacionada às variações positivas e negativas das linhas de base, presentes nos sinais brutos e ruidosos de todas as bases de dados. Além disso, foi necessária a filtragem das frequências de ruído, para as quais foram aplicados filtros passa-baixa de 120 Hz, passa-alta de 0,3 Hz e Notch de 50 Hz. Vale ressaltar que as frequências acima já foram otimizadas para sinais de ECG de acordo com a literatura.

Na fase III, o primeiro passo foi a aplicação de um subprocesso de subamostragem para 128 Hz, de todos os sinais de ECG da quarta base de dados, e homogeneizamos o número de amostras para 16.458 amostras para todos os sinais. Reunindo todos os bancos de dados citados acima, foi criada uma estrutura chamada ECGfive.mat, com o campo Dados de tamanho (197x16458), que representa os dados em mV dos ECGs. O campo Labels é uma matriz de Labels de tamanho de caracteres (197x1) que identifica os tipos de ECGs, que foram 55 ARR, 55 MI, 57 NSR e 30 CHF. Em seguida, foi realizado o processo de extração de características dos biossinais, para o qual foram obtidos os escalogramas de todos os sinais de ECG de todas as categorias utilizadas neste estudo. Na Fase IV, os dados de ECG foram preparados para treinamento e validação da rede neural convolucional RestNet utilizada neste trabalho. As redes de aprendizagem profunda podem ter muitas camadas, até mesmo centenas delas, e aprendem diretamente com os dados inseridos, como é o caso do RestNet. Na Fase V mostramos o desempenho da rede classificando corretamente as diferentes classes de ECGs, principalmente através da matriz de confusão, entre outros.

RESULTADOS E DISCUSSÕES

A rede CNN RestNet é uma rede pré-treinada e pode ser utilizada para realizar tarefas semelhantes às que normalmente realiza, isso é chamado de aprendizagem por transferência. Se a nova tarefa for semelhante à classificação de imagens, o uso da rede treinada poderá fornecer mais precisão. A rede neural RestNet pode aprender com os dados de entrada (imagens de escalogramas), para que possa ser treinada para reconhecer padrões, classificar dados e prever eventos futuros. A partir

da matriz de dados ECGfive.mat definida na seção anterior, na Figura 2, podemos ver um representante de um sinal de ECG típico após a aplicação da Fase II, para um sinal de ECG de infarto do miocárdio, MI..




Figura 2. Exemplos de um sinal de ECG típico após a aplicação da Fase II, para um sinal de ECG de infarto do miocárdio, MI.

Os diferentes sinais de ECGs incluem o sinal de ARR que mostra a variabilidade da frequência cardíaca as chamadas arritmias cardíacas, 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. Na preparação dos dados para treinamento, foram criadas representações frequência-tempo dos sinais de ECG. Essas representações são chamadas de escalogramas. Um escalograma é o valor absoluto dos coeficientes CWT de um sinal. Para a criação dos escalogramas foi pré-calculado um banco de filtros CWT. Pré-computar o banco de filtros CWT é o método preferido ao obter o CWT de muitos sinais usando os mesmos parâmetros.

Após a geração das imagens do escalograma, sinais de entrada da CNN, elas foram divididas aleatoriamente em dois grupos, um para treinamento e outro para validação. Mais precisamente, 80% das imagens para treinamento e o restante para validação. Ou seja, o número de imagens de treinamento foi 158 e 39 para validação. Após isso foi gerada a rede RestNet com 346 camadas de neurônios. As entradas foram de acordo com as características do CNN RestNet, que requer imagens RGB de tamanho 224 por 224 por 3. A seguir, as opções de treinamento e validação dos dados de entrada são customizadas aplicando a Rede Neural citada anteriormente. Dentre os parâmetros a serem escolhidos, destaca-se a taxa de aprendizagem, que foi escolhida aleatoriamente com valor de 10^{-4} . Após a etapa anterior, passamos para a parte fundamental do funcionamento da rede, que é o treinamento e validação da rede neural convolucional. Os principais resultados são apresentados nos gráficos da figura 3.




Figura 3. Precisão dos processos de treinamento e validação da rede neural RestNet.

Na figura 3 mostramos na parte superior o gráfico do progresso do treinamento representando a acurácia do treinamento e validação, que é a acurácia da classificação em cada classe com rótulos (Labels) conhecidos. Na parte inferior, mostramos a função de perda de treinamento, que é a perda de entropia cruzada em cada época. Quando o treino progride com sucesso, este valor normalmente diminui para zero. Neste estudo, o tempo de processamento da rede foi de 17 minutos com 40 segundos, 20 épocas, 140 iterações, 7 por época e taxa de aprendizado de 10^{-4} , conforme afirmado anteriormente. Pelo gráfico podemos observar que a acurácia da rede RestNet na classificação dos ECGs nas diferentes classes de problemas cardíacos aqui estudados foi de 74,35%. Para se ter uma ideia melhor do desempenho da CNN na classificação desses problemas cardíacos, foi calculada uma matriz de confusão onde podemos examinar a precisão do processo de validação, este tipo de matriz é uma tabela que permite a visualização do desempenho de um algoritmo de classificação. Os valores que estão na diagonal representam a quantidade de sinais de uma determinada classe que foram classificados corretamente. Podemos observar que as classes de ECGs ou problemas cardíacos que foram classificadas com maior precisão foram NSR com 77,8%, ECGs IM com 76,9%; e RAR com 72,7%, respectivamente.

CONSIDERAÇÕES FINAIS

Neste estudo, 197 sinais de ECG foram usados de forma inédita para classificar problemas cardíacos usando a rede CNN RestNet. Os sinais de ECG foram extraídos de quatro bancos de dados diferentes, o banco de dados de arritmia do MIT-BIH; Ritmo sinusal MIT-BIH; o banco de dados de insuficiência cardíaca congestiva e o banco de dados de ECG diagnóstico de PTB. A rede RestNet tinha 144 camadas de neurônios e foi configurada com uma taxa de aprendizado de 10^{-4} . Para dados de entrada foram utilizados escalogramas de ECG de todas as classes. Os resultados obtidos mostraram uma acurácia da rede RestNet na classificação dos ECG nas diferentes classes de problemas cardíacos aqui estudados de 74,35%. A partir das análises da matriz de confusão, podemos observar que as classes de ECGs ou problemas cardíacos que foram classificados com maior precisão foram NSR com 77,8%, ECGs IM com 76,9%; e RAR com 72,7%, respectivamente.

REFERÊNCIAS

- [1]. Lindstrom M, DeCleene N, Dorsey H, Fuster V, Johnson CO, LeGrand KE, et al. Global Burden of Cardiovascular Diseases and Risks Collaboration, 1990–2021. *J Am Coll Cardiol.* 2022; 80: 2372–2425. <https://doi.org/10.1016/j.jacc.2022.11.001>.
- [2]. OLIVEIRA, Gláucia Maria Moraes de et al. Estatística Cardiovascular – Brasil 2021. *Arq. Bras. Cardiol.*, v. 118, n. 1, p. 115-373, jan. 2022.
- [3]. COSTA, Letícia Rodrigues; PASSOS, Eduardo Vasconcelos; SILVESTRE, Odilson Marcos. O Redescobrimento do Brasil Cardiovascular: Como Prevenimos e Tratamos a Doença Cardiovascular em Nosso País. *Arquivos Brasileiros de Cardiologia*, v. 116, p. 117-118, 2021.
- [4]. GIFFONI, Rodrigo Tobias; TORRES, Rosália Moraes. Breve história da eletrocardiografia. *Revista Médica de Minas Gerais*, v. 20, n. 2, p. 263-270, 2010.
- [5] R. Avanzato, F. Beritelli, Automatic ecg diagnosis using convolutional neural network, *Electron* 9 (2020) 1–14, <https://doi.org/10.3390/electronics9060951>.
- [6] C.Y. Chen, Y.T. Lin, S.J. Lee, W.C. Tsai, T.C. Huang, Y.H. Liu, M.C. Cheng, C.Y. Dai, Automated ECG classification based on 1D deep learning network, *Methods* 202 (2022) 127–135, <https://doi.org/10.1016/j.ymeth.2021.04.021>.
- [7] K. Palczy, S. Smigiel, ECG Signal Classification Using Deep Learning Techniques Based on the PTB-XL Dataset, 2021, pp. 1–20. <https://doi.org/10.3390/e23091121>.
- [8] G.B. Moody, R.G. Mark, The impact of the MIT-BIH arrhythmia database, *IEEE Eng. Med. Biol. Mag.* 20 (2001) 45–50, <https://doi.org/10.1109/51.932724>.