



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

XXVIII SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2024

CLASSIFICAÇÃO DE ECGS DE INFARTO AGUDO DO MIOCÁRDIO USANDO REDES NEURAIS CONVOLUCIONAIS E O MÉTODO DE CORRELAÇÃO CRUZADA SEM TENDÊNCIAS (rhoDCCA)

Giovanna Venas Oliveira¹; Juan A. Leyva-Cruz²

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

PALAVRAS-CHAVE: ECG; infarto do Miocárdio; Redes Neurais Convolucionais (CNN).

INTRODUÇÃO

A Eletrocardiografia é a técnica de diagnóstico médico standard, que se usa para estudar os fenômenos bioelétricos que ocorrem no coração, através da medida do potencial elétrico na superfície do tórax. Podemos afirmar que os fluxos de íons através das membranas celulares das células do coração, chamadas de miócitos, formam as bases física dos fenômenos bioelétricos cardíacos [1]. Na literatura, são relatados diversos algoritmos, com diferentes metodologias, para realizar diagnósticos automáticos em tempo real do estado de saúde do coração, dentre os quais se destacam aqueles baseados na teoria de Redes Neurais, nas Transformadas de Hilbert ou de Fourier, nos Modelos de Markov, nos Algoritmos Genéticos, na Matemática Morfológica, nas Transformadas Wavelet continua ou discretas, dentre outros [2-5]. Segundo Marcin Maciejewski et al., [6] um procedimento utilizado tanto em pesquisas quanto na cardiologia clínica é o conhecido algoritmo de Pan-Tompkins [7].

Entretanto, nos últimos anos, os pesquisadores introduziram vários novos métodos para processamento digital e classificação dos sinais de ECGs. Alguns destes métodos de classificação são as redes neurais de função de base radial [8], as baseadas em Multi-Layer Perceptron (MLP), os métodos de Máquinas de Suporte a Vetores (MSV) [9-10], Aprendizados de Máquinas Profundos (AMP) [11-13]. Bem como, os algoritmos genéticos para a otimização de características em conjunto com as redes neurais na classificação de sinais de ECGs [14]. Neste contexto, as Redes Neurais Artificiais (RNAs) têm ganhado grande destaque no que diz respeito à aplicação da Inteligência Artificial (IA) na medicina. Dentre os tipos de ANNs, as Redes Neurais Convolucionais (CNN), têm apresentado os melhores resultados em termos de classificação de imagens, amplamente utilizadas em aplicações predição e diagnósticos assistivos [15] e [16]. O objetivo principal deste trabalho foi o de criar uma ferramenta computacional para Classificação de ECGs de infarto agudo do miocárdio usando redes neurais convolucionais e o método de correlação cruzada sem tendências (rhoDCCA) [17]. Além deste método, para implementar a CNN usamos sinais de eletrocardiogramas humanos, principalmente as representativas do infarto agudo do Miocárdio, as transformadas Wavelet contínuas (CWT) e a rede neural convolucional profunda GoogLeNet, na plataforma Matlab.

MATERIAL E MÉTODOS

2.1 Banco de dados de ECGs

Neste trabalho foram usados os biosinais de ECGs obtidos de forma gratuita de quatro bancos de dados de ECG gratuitos e de código aberto. Três adquiridos no site Physio-Net <https://archive.fisionet.org/fisiobank/database/>, estes são o banco de dados de ESGs com ritmos de batimento normal (NSR), o de arritmia (ARR) e o banco de dados de insuficiência cardíaca

congestiva (CHF) do BIDMC do MIT-BIH [17-19]. Em particular foram utilizados 96 ECGs com ARR, 30 com CHF e 36 com NSR. O quarto banco de dados utilizado foi o banco de dados de ECG diagnóstico de PTB [20], 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 (MI) e 21 NSR.

Ao integrar todos os bancos de dados citados acima, foi criada uma estrutura chamada ECGfive.mat, com os campos Dados de tamanho (197x16458), que representa os dados em mV dos ECGs. O campo Rótulos é uma matriz de rótulos de tamanho de caracteres (197x1) que identifica os tipos de ECGs, que foram 55 ARR, 55 MI, 57 NSR e 30 CHF. Os sinais de ECGs são pré-processados, onde se lê aplicam várias operações de processamento digital de sinais, dentre das quais se destacam, a filtragem e subamostragem dos ECGs. Esta filtragem permitiu corrigir as linhas de base, presentes nos sinais brutos e ruidosos de todas as bases de dados. Além disso, foi necessária a filtragem do ruído dos sinais crúes de ECGs, para as quais foram aplicados filtros passa-baixa de 120 Hz, passa-alta de 0,3 Hz e Notch de 50 Hz.

2.2 Procedimento de aplicação de Rede Neural Convolucional modificado com o método de correlação cruzada sem tendências (rhoDCCA).

O código computacional escrito em MATLAB para executar o modelo de CNN para a classificação de ECGs que incorpora coeficientes de correlação cruzada DCCA (Detrended Cross-Correlation Analysis) como recursos adicionais, inclui as seguintes etapas principais:

1. **Carregamento e pré-processamento dos dados:** os sinais de ECGs pré-processados são carregados, e separadas em pastas por categorias. Em seguida foram obtidas as imagens escalogramas de todos os sinais de ECGs e de todas as categorias utilizadas neste estudo. Isso foi feito por meio de transformadas de Wavelets discretas. Ou seja, os coeficientes destas transformadas dos ECGs foram convertidos em imagens de frequências e de tempo, indexadas num mapa de cores RGB, de tamanho [224 224 3] e armazenadas automaticamente em pastas separadas por classes.
2. **Divisão dos Dados:** nesta etapa foram separadas as imagens e seus correspondentes atributos, em dois sets de dados para trabalhar na rede neural, um set para treino e outro grupo para teste ou validação. Este processo foi feito de forma randômica com uma probabilidade de 0.7.
3. **Carregar Arquitetura CNN:** aqui chamamos a arquitetura da rede neural, CNN básica que é definida usando camadas convolucionais, normalização de lote, ativação ReLU, etc. Aqui foi usada a CNN GoogLeNet na qual se aprofundou a rede com camadas convolucionais adicionais.
4. **Implementação do rhoDCCA:** nesta etapa foi implementada a função *rhodcca* para calcular os coeficientes de correlação cruzada DCCA entre as duas séries temporais de ECGs entre as categorias.
5. **Extração de recursos:** aqui foi escrita a função *extractDCCAFeatures* que aplica a função *rhoDCCA* a cada par de amostras de ECGs, criando uma matriz de recursos.
6. **CNN modificada:** a CNN original é modificada para incluir os recursos rhoDCCA como um canal adicional na entrada.
7. **Configurando os Parâmetros da CNNs:** aqui especificamos os parâmetros da rede neural convolucional, tais como o cronograma de taxa de aprendizado, a taxa de aprendizado inicial, o número de épocas, o tamanho do lote, a frequência de validação, e incluímos o set de dados de validação e suas etiquetas o rótulos.

8. **Treinamento e avaliação:** a rede modificada é treinada e avaliada no conjunto de teste ou validação.
9. **Visualização da performance da rede Convolucional:** *nesta última etapa calculamos e visualizamos a precisão da classificação dos ECGs pela CNN.*

RESULTADOS E DISCUSSÕES

A rede CNN GoogLeNet é uma rede pré-treinada e pode ser utilizada para realizar tarefas semelhantes às que normalmente realiza para a classificação de imagens, 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 GoogLeNet 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 uma amostra representativa dos ECGs para cada categoria ou condição cardíaca, prontos para serem utilizados na CNN.

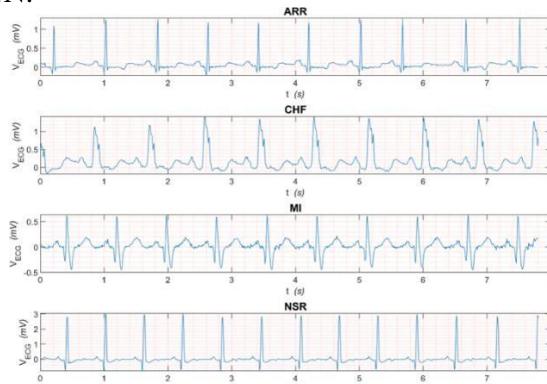


Figura 2. Exemplos de sinais de ECG associados a diferentes estados de saúde cardíaca ou categorias de batimentos cardíacos: (a) IRA, (b) ICC, (c) IM, (d) NSR.

Na figura 2 é possível identificar formas de onda típicas de diferentes problemas cardíacos. O sinal ARR mostra a variabilidade da frequência cardíaca 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.

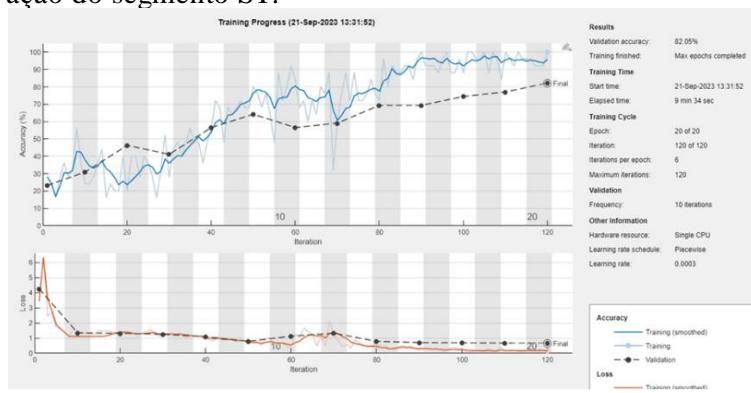


Figura 3. Precisão dos processos de treinamento e validação da rede neural GoogLeNet modificada.

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 9 minutos com 34 segundos, 20 épocas, 120 iterações, 7 por época e taxa de aprendizado de 3×10^{-4} , conforme afirmado anteriormente. Pelo gráfico podemos observar que a acurácia da rede

GoogLeNet na classificação dos ECGs nas diferentes classes de problemas cardíacos aqui estudados foi de 82,05%. Para se ter uma ideia melhor do desempenho da CNN na classificação desses problemas cardíacos, foi calculada uma matriz de confusão, conforme mostra a figura 4, abaixo.

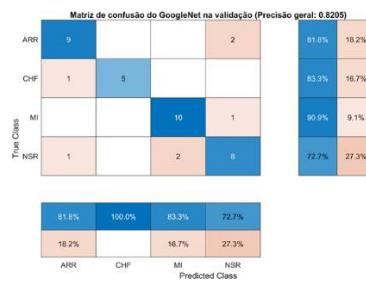


Figura 4. Matriz de confusão mostrando o desempenho da classificação da CNN por categorias de ECGs.

Na matriz de confusão da Figura 4 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 CHF inferida com 100 %, depois segue os ECGs infarto agudo do miocárdio com 83.3 %; es arritmias ARR com 81,8 %, respectivamente.

CONSIDERAÇÕES FINAIS

O eletrocardiograma (ECG) é um método eficiente para o diagnóstico de doenças cardíacas e tem sido amplamente utilizado na prática clínica. Problemas cardíacos são a principal causa de morte no mundo. Além disso, encontrar novos métodos para detectar e diagnosticar anomalias cardíacas é uma das principais demandas da comunidade científica nessa área. Neste estudo, 197 sinais de ECG foram usados de forma inédita para classificar condições cardíacas usando a rede neural convolucional GoogLeNet modificada. Desses ECGs, 55 eram de arritmias cardíacas (ARR), 55 de infarto do miocárdio (IM), 57 de ECG com ritmo normal (NSR) e 30 de insuficiência cardíaca (CHF). Esses sinais foram reamostrados a uma taxa de amostragem de 128 Hz. Os conjuntos de dados de ECG foram extraídos de quatro diferentes bases de dados: a base de dados MIT-BIH de arritmia, MIT-BIH de ritmo sinusal, a base de dados de insuficiência cardíaca congestiva e a base de dados de ECGs diagnósticos PTB. A rede GoogLeNet tinha 144 camadas de neurônios e foi configurada com uma taxa de aprendizado de 3*10-4. Para os dados de entrada, foram utilizados escalogramas de ECG de todas as classes. A CNN foi treinada com 158 imagens de treinamento e 39 foram usadas para validação. Essas imagens de escalogramas foram escolhidas aleatoriamente. Os resultados obtidos com a aplicação da CNN mostram uma acurácia da aplicação usando a rede GoogLeNet, na classificação de ECGs nas diferentes classes de problemas cardíacos estudadas de 82,05 %. O estudo experimental de inteligência artificial proposto é viável para classificar satisfatoriamente problemas cardíacos..

REFERÊNCIAS

- [1] J. Malmivuo and R. Plonsey, *Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields*. Oxford University Press, USA, 1995.
- [2] V. Krasteva, I. Jekova, R. Leber, R. Schmid, and R. Abächerli, "Real-time arrhythmia detection with supplementary ecg quality and pulse wave monitoring for the reduction of false alarms in icus," *Physiological measurement*, vol. 37, no. 8, p. 1273, 2016.
- [3] B. Vandendriessche, M. Abas, T. E. Dick, K. A. Loparo, and F. J. Jacono, "A framework for patient state tracking by classifying multiscalar physiologic waveform features," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 12, pp. 2890–2900, 2017.