

Detecção automática de arritmias cardíacas utilizando redes neurais convolucionais

Luan Guio Cotini, Renato Candido, Magno T. M. Silva

Resumo— Este trabalho compara duas arquiteturas de redes neurais convolucionais (*convolutional neural networks* – CNNs) para a detecção automática de arritmias cardíacas. Com base no sinal de eletrocardiograma (ECG), consideraram-se duas abordagens: uma unidimensional (CNN-1D), operando sobre o sinal cru e uma bidimensional (CNN-2D), alimentada por espectrogramas do sinal de ECG. Para mitigar o desbalanceamento das classes, utilizam-se pesos na função custo e a sobreamostragem aleatória. Os resultados indicam que a CNN-2D supera o desempenho da CNN-1D, diminuindo falsos alarmes e elevando o F1-score.

Palavras-Chave— Aprendizado de máquina, redes neurais convolucionais, eletrocardiograma, espectrograma.

Abstract— This work compares two convolutional neural network (CNN) architectures for the automatic detection of cardiac arrhythmias. Based on the electrocardiogram (ECG) signal, two approaches were considered: a one-dimensional model (1D-CNN) operating on the raw signal and a two-dimensional model (2D-CNN) fed with spectrograms derived from the ECG signal. To mitigate class imbalance, class weights in the cost function and random oversampling were employed. The results indicate that the 2D-CNN outperforms the 1D-CNN, reducing false alarms and improving the F1-score.

Keywords— Machine learning, convolutional neural networks, electrocardiogram, spectrogram.

I. INTRODUÇÃO

O diagnóstico de cardiopatias depende de uma análise precisa da atividade elétrica do coração [1]. O sinal de eletrocardiograma (ECG) contém informações clínicas que permitem que essa tarefa seja realizada por especialistas qualificados, o que pode ser demorado e é inviável quando se necessita de resultados imediatos. Diante disso, soluções baseadas em técnicas de aprendizado de máquina para detecção e classificação automática de arritmias cardíacas têm sido amplamente propostas na literatura [1]–[14].

A *Association for the Advancement of Medical Instrumentation* (AAMI) [15] recomenda que os sinais de ECG de pacientes utilizados no treinamento dos classificadores não sejam reutilizados no teste (divisão inter-paciente). Entre os trabalhos que seguem essa divisão mais realista entre pacientes de treinamento e teste, destacam-se [2]–[5], [8]. Apesar dessa recomendação, revisões recentes da literatura mostram que aproximadamente 86,7% dos trabalhos contemporâneos ainda adotam o paradigma de avaliação intra-paciente [14]. Esse

cenário evidencia um desafio importante, já que diversos estudos relatam quedas significativas nas métricas de desempenho quando os modelos são avaliados em pacientes que não foram observados no treinamento (ver [14] e suas referências).

Em aprendizado de máquina, as redes neurais convolucionais (*convolutional neural networks* – CNNs) constituem uma das principais arquiteturas para o processamento e análise de imagens. Essas redes utilizam camadas convolucionais capazes de extrair automaticamente características relevantes, o que tem levado a um bom desempenho em diferentes aplicações [16], [17]. As CNNs têm sido utilizadas para classificação de arritmias cardíacas, considerando arquiteturas unidimensionais (1D) [6], [7] ou bidimensionais (2D) [13], [20], [21]. No caso da CNN-2D, é comum usar como entrada a representação tempo-frequência obtida com a transformada de Fourier de curto prazo (*short time Fourier transform* - STFT), que transforma o sinal de ECG em uma matriz de números complexos, usada para gerar espectrogramas [21]. A maioria dos trabalhos que utiliza a STFT para gerar os espectrogramas descarta a fase e considera apenas o módulo, como é o caso de [21].

Neste trabalho, é apresentada uma comparação entre uma arquitetura baseada em CNN-1D com uma baseada em CNN-2D para detecção de arritmias cardíacas utilizando sinais de ECG do banco de dados MIT - *Boston's Beth Israel Hospital Arrhythmia Database* (MITDB) [18], [19]. O artigo está organizado da seguinte forma. Na Seção II, descrevem-se o banco de dados e as arquiteturas de CNN utilizadas. As Seções III e IV contêm, respectivamente, os resultados de simulações e as principais conclusões do trabalho.

II. BANCO DE DADOS E ARQUITETURAS DAS CNNs

Para a avaliação e validação das arquiteturas propostas, utilizou-se o banco de dados MITDB [18], [19], que é amplamente reconhecido na literatura como padrão de referência para sistemas automatizados de classificação de batimentos cardíacos. O MITDB é composto por 48 registros de eletrocardiograma ambulatorial biderivacional, com duração aproximada de 30 minutos cada, coletados de 47 indivíduos. Os sinais foram digitalizados a uma taxa de amostragem de 360 Hz por canal com resolução de 11 bits. A maior parte dos registros foram feitos utilizando-se as derivações bipolar II modificada (*lead A*) e a precordial V1 (*lead B*). De acordo com as recomendações da AAMI, os batimentos cardíacos devem ser categorizados em cinco classes: batimentos do nó sinoatrial (N), supraventriculares ectópicos (S), ventriculares ectópicos (V), fusão de batimentos normais e ventriculares ectópicos (F) e desconhecidos ou de marca-passo (Q). Neste trabalho, porém, devido à ausência de resultados promissores

para a classe Q e à menor quantidade de dados da classe F, optou-se por considerar apenas as classes N, S e V. Para tanto, os batimentos pertencentes à classe N foram mapeados como representativos da classe *Normal*, enquanto os batimentos originados das classes S e V foram mapeados como *Arritmia*.

Uma característica do banco de dados MITDB é o seu forte desbalanceamento entre as classes, o que torna necessária a utilização de técnicas que mitiguem esse efeito durante o aprendizado dos modelos. Para lidar com o desbalanceamento dos dados, foram utilizadas duas abordagens distintas durante a etapa de treinamento: (i) pesos na função custo e (ii) sobreamostragem aleatória, descritas a seguir.

Em vez de tratar todos os erros de classificação de forma idêntica, na abordagem (i) atribui-se na função custo um peso inversamente proporcional à frequência de cada classe no conjunto de treinamento. Dessa forma, a penalização imposta devido a um erro de classificação na classe minoritária (arritmia) torna-se significativamente maior do que aquela associada à classe majoritária (normal).

Na abordagem (ii), a sobreamostragem aleatória foca em modificar o conjunto de treinamento, replicando os exemplos da classe minoritária até certo volume. Neste trabalho, os dados de arritmia foram replicados até atingir a mesma quantidade de dados da classe majoritária. Como resultado, o conjunto de treinamento foi expandido de 65.240 para 116.572 batimentos, conforme detalhado na Tabela I.

TABELA I: Distribuição das classes de batimentos no conjunto de treinamento antes e após a sobreamostragem.

Classe	Original	Sobreamostrado
Normal	58.286 (89%)	58.286 (50%)
Arritmia	6.954 (11%)	58.286 (50%)
Total	65.240	116.572

Para compor as entradas utilizadas nos modelos, foram utilizadas 1080 amostras da primeira derivação do sinal de ECG em torno do pico R, o que corresponde aproximadamente à informação de três batimentos cardíacos consecutivos, tendo a rede como objetivo classificar o batimento central. Os dados foram normalizados de forma a apresentarem média zero e variância unitária e divididos na proporção 80% para treinamento e 20% para teste. As simulações e implementações foram realizadas utilizando a biblioteca PyTorch¹ do Python.

Como abordagem inicial, implementou-se uma CNN unidimensional (CNN-1D) que opera sobre o sinal cru no domínio do tempo. O modelo, esquematizado na Figura 1, é composto por três blocos convolucionais com filtros 5×1 , função de ativação *ReLU*, *padding* $p = 2$ e *stride* $s = 1$ sequenciais, intercalados com camadas de *max-pooling* (subamostragem). Na sequência considerou-se um classificador perceptron multicamada (*multilayer perceptron* – MLP), composto por uma camada oculta com 128 neurônios e função de ativação *ReLU* e uma camada de saída com 1 neurônio e função de ativação sigmoideal. Consideraram-se também *dropout* com probabilidade $p = 0,5$, inicialização de He e entropia cruzada como função custo. O modelo foi treinado com o otimizador Adam com taxa de aprendizado $\eta = 0,001$, $\beta_1 = 0,9$ e $\beta_2 = 0,999$ [17].

Em uma segunda abordagem, para explorar as características no domínio tempo-frequência, os sinais foram transfor-




Fig. 1: Arquitetura da CNN-1D.

mados em espectrogramas por meio da STFT. Para tanto, utilizou-se uma janela de Hamming com $L = 64$ amostras e sobreposição de 50%. Sabendo que a STFT geralmente envolve valores complexos e considerando que se deseja uma rede neural que trabalhe no domínio real, foram testadas três formas diferentes de entrada: (i) apenas o módulo da STFT, (ii) o módulo acrescido do seno da fase e (iii) o módulo acrescido do seno e do cosseno da fase. Dessa forma, a entrada resultante do modelo possui dimensões $11 \times 35 \times k$ sendo $k = 1, 2, 3$ para cada uma das propostas. A rede utilizada foi uma CNN bidimensional (CNN-2D), composta por blocos convolucionais com filtros 3×3 , $p = 1$ e $s = 1$, seguida por uma camada de *max-pooling*, conforme ilustrado na Figura 2. A MLP e as demais características do modelo são iguais às da CNN-1D.




Fig. 2: Arquitetura da CNN-2D.

III. RESULTADOS E DISCUSSÃO

Para a avaliação quantitativa do desempenho dos modelos propostos para detecção de arritmia cardíaca, foram adotadas três métricas: precisão definida como $P = VP/(VP + FP)$, sensibilidade calculada como $S = VP/(VP + FN)$ e $F1-score = 2P \times S/(P + S)$, em que VP , FP e FN denotam os números de verdadeiros positivos, falsos positivos e falsos negativos, respectivamente. A precisão quantifica a capacidade do classificador em mitigar a ocorrência de falsos alarmes, enquanto a sensibilidade reflete a eficácia do sistema em detectar os batimentos patológicos presentes. O $F1-score$, por sua vez, estabelece a média harmônica entre ambas as métricas descritas, fornecendo um índice global de robustez para cenários com forte desbalanceamento de classes.

Os experimentos iniciais foram dedicados à avaliação da arquitetura CNN-1D, operando sobre o sinal de ECG cru. Os resultados obtidos sob as duas estratégias de mitigação do

¹<https://pytorch.org/>

desbalanceamento de dados estão consolidados na Tabela II. Observa-se nesta tabela que a abordagem baseada em sobreamostragem aleatória superou a penalização por pesos na função custo no valor do F1-score.

TABELA II: Métricas de desempenho com a CNN-1D.

Estratégia	<i>P</i>	<i>S</i>	F1-score
Pesos na função custo	0,50	0,93	0,65
Sobreamostragem	0,67	0,92	0,77

Em uma segunda etapa, as análises foram estendidas para a CNN-2D. Como a sobreamostragem aleatória superou a técnica de pesos na função custo com a CNN-1D, considerou-se apenas esse método com a CNN-2D. Os resultados obtidos considerando as três estratégias de entrada estão na Tabela III. O modelo restrito ao módulo da STFT apresentou desempenho inferior, atingindo um F1-score de apenas 0,69, penalizado pela baixa precisão (0,58) decorrente de um elevado índice de falsos alarmes. A introdução do seno da fase da STFT promoveu uma melhora substancial na discriminação morfológica, elevando a sensibilidade para 0,91 e o F1-score para 0,73. O melhor cenário de classificação, contudo, foi atingido com a configuração do módulo acrescido do seno e cosseno da fase da STFT, a qual estabilizou o F1-score em 0,76, impulsionado pelo patamar mais elevado de precisão (0,66).

TABELA III: Métricas de desempenho com a CNN-2D.

Estratégia de entrada	<i>P</i>	<i>S</i>	F1-score
(i) Módulo da STFT	0,58	0,85	0,69
(ii) Módulo e seno da fase da STFT	0,61	0,91	0,73
(iii) Módulo, sen e cos da fase da STFT	0,66	0,89	0,76

Esse comportamento evidencia que o fornecimento completo das informações de fase é decisivo para o modelo. A fase parece atuar no sincronismo das transições harmônicas do complexo QRS, permitindo que a CNN-2D atenuar os falsos positivos e se aproxime do desempenho da CNN-1D. As curvas de aprendizado no treinamento e validação ao longo das épocas para a CNN-1D que utiliza a sobreamostragem aleatória e para a CNN-2D que considera o módulo, seno e cosseno da STFT estão mostradas na Fig. 3. Os resultados da Tabela III para a abordagem (iii) foram obtidos com os pesos da época 14 e os da Tabela II considerando a sobreamostragem, com os pesos da época 13. Em ambos os casos, levou-se em conta a convergência do treinamento e o resultado da validação.




Fig. 3: Entropia cruzada no treinamento e validação.

IV. CONCLUSÕES

Este trabalho apresentou uma análise comparativa entre abordagens baseadas em CNN-1D e CNN-2D para classi-

ficação binária de batimentos cardíacos utilizando o banco de dados MITDB. Os resultados demonstraram que, diante do desbalanceamento do banco de dados, a técnica de sobreamostragem foi mais eficaz do que a penalização por pesos na função custo. Além disso, observou-se que a CNN-2D multicanal alimentada com magnitude e fase da STFT apresenta um desempenho semelhante ao da CNN-1D. A inclusão explícita da informação de fase permitiu capturar o sincronismo harmônico do complexo QRS, resultando no F1-Score de 0,76. Como continuidade deste trabalho, pretende-se estender a avaliação para o cenário de classificação multi-classe, seguindo as recomendações da AAMI.

REFERÊNCIAS

- [1] S. K. Berkaya *et al.*, "A survey on ECG analysis," *Biomedical Signal Processing and Control*, vol. 43, pp. 216–235, 2018.
- [2] P. de Chazal, M. O'Dwyer, and R. B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features," *IEEE Trans. Biomed. Eng.*, vol. 51, pp. 1196–1206, 2004.
- [3] T. Mar *et al.*, "Optimization of ECG classification by means of feature selection," *IEEE Trans. Biomed. Eng.*, vol. 58, pp. 2168–2177, 2011.
- [4] C. Lin and C. Yang, "Heartbeat classification using normalized RR intervals and morphological features," *Math. Probl. Eng.*, 2014.
- [5] G. Garcia *et al.*, "Improving automatic cardiac arrhythmia classification: Joining temporal-VCG, complex networks and SVM classifier," in *Proc. Int. Joint Conf. Neural Netw. (IJCNN)*, pp. 3896–3900, 2016.
- [6] U. R. Acharya *et al.*, "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network," *Information Sciences*, vol. 405, pp. 81–90, 2017.
- [7] U. R. Acharya *et al.*, "Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network," *Knowledge-Based Systems*, vol. 132, pp. 62–71, 2017.
- [8] G. Garcia *et al.*, "Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO," *Scientific Reports*, vol. 7, pp. 1–11, 2017.
- [9] R. Banerjee, A. Ghose, and S. Khandelwal, "A novel recurrent neural network architecture for classification of atrial fibrillation using single-lead ECG," in *Proc. European Signal Process. Conf. (EUSIPCO)*, 2019.
- [10] A. Y. Hannun *et al.*, "Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network," *Nature Medicine*, vol. 25, pp. 65–69, 2019.
- [11] N. Nagata, R. Candido, and M. T. M. Silva, "Combinações de redes neurais e discriminantes lineares para classificação de arritmias cardíacas," in *Anais do SBrt*, Fortaleza, CE, 2021.
- [12] O. R. A. Almanifi *et al.*, "Heartbeat murmurs detection in phonocardiogram recordings via transfer learning," *Alexandria Engineering Journal*, vol. 61, pp. 10995–11002, 2022.
- [13] F. R. Mashrur, A. Dutta Roy, and D. K. Saha, "Automatic identification of arrhythmia from ECG using AlexNet convolutional neural network," in *Proc. Int. Conf. Electr. Inf. Commun. Technol. (EICT)*, Khulna, Bangladesh, pp. 1–5, 2019.
- [14] Q. Xiao *et al.*, "Deep learning-based ECG arrhythmia classification: A systematic review," *Applied Sciences*, vol. 13, pp. 1–25, 2023.
- [15] Association for the Advancement of Medical Instrumentation (AAMI), *ANSI/AAMI EC57:1998/(R)2008 - Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms*. Arlington, VA, USA: American National Standards Institute, 2008.
- [16] Y. LeCun and Y. Bengio, "Convolutional networks for images, speech, and time series," in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, ed., Cambridge, MA: MIT Press, 2nd ed., 2003.
- [17] C. M. Bishop, *Deep Learn.: Found. Concepts*. Springer, 2024.
- [18] A. L. Goldberger *et al.*, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, pp. e215–e220, 2000.
- [19] G. B. Moody and R. G. Mark, "The impact of the MIT-BIH arrhythmia database," *IEEE Eng. Med. Biol. Mag.*, vol. 20, pp. 45–50, 2001.
- [20] H. Mewada, "2D-wavelet encoded deep CNN for image-based ECG classification," *Multimedia Tools and Applications*, vol. 82, no. 14, pp. 20553–20569, 2023.
- [21] A. Ullah, S. M. Anwar, M. Bilal, and R. M. Mehmood, "Classification of arrhythmia by using deep learning with 2-D ECG spectral image representation," *Remote Sensing*, vol. 12, no. 11, p. 1685, 2020.