

Redes Neurais Convolucionais para identificação de arritmias cardíacas

Convolution Neural Networks to identify cardiac arrhythmias

RESUMO

Ana Livia Franco
af franco@alunos.utfpr.edu.br
Universidade Tecnológica Federal
do Paraná, Cornélio Procopio,
Paraná, Brasil

Priscila Tiemi Maeda Saito
psaito@utfpr.edu.br
Universidade Tecnológica Federal
do Paraná, Cornélio Procopio,
Paraná, Brasil

As doenças cardiovasculares são as principais causas da mortalidade humana, dentre elas destaca-se a arritmia cardíaca. O diagnóstico de arritmia é dado especialmente pelo Eletrocardiograma (ECG). Para tanto, especialistas devem analisar visualmente os sinais biomédicos gerados a partir das gravações de ECG, o que faz com que o diagnóstico se torne um processo longo e exaustivo. Sendo assim, o presente trabalho propõe a classificação automática de arritmias cardíacas, a partir de sinais de ECG, bem como de imagens obtidas do pré-processamento desses sinais, por meio de Redes Neurais Convolucionais (CNNs) unidimensionais e bidimensionais. Como resultado, a arquitetura de CNN proposta atingiu 82,86% de acurácia média no cenário bidimensional e 98,55% no cenário unidimensional. Portanto, os resultados experimentais indicam que a arquitetura desenvolvida é uma alternativa viável para a realização de predições e auxílio na obtenção de diagnósticos médicos.

PALAVRAS-CHAVE: Aprendizado de Máquina. Classificação Automática. Inteligência Artificial. Rede Neural. Visão Computacional.

ABSTRACT

Cardiovascular diseases are the main causes of human mortality, among them, cardiac arrhythmia stands out. The diagnosis of arrhythmia is made especially using the electrocardiogram (ECG). For this, specialists must perform a visual analysis of the biomedical signals generated in the ECG recordings, which makes the diagnosis a long and exhaustive process. Thus, the present work proposes the automatic classification of cardiac arrhythmias, based on ECG signals, as well as images obtained from the pre-processing of these signals, through one-dimensional and two-dimensional Convolutional Neural Networks (CNNs). As a result, the proposed CNN architecture reached an average accuracy of 82,86% in the two-dimensional scenario and 98.55% in the one-dimensional scenario. Thus, the experimental results indicate that the developed architecture is a viable alternative for making predictions and helping to obtain medical diagnoses.

KEYWORDS: Machine Learning. Automatic classification. Artificial Intelligence. Neural Network. Computer Vision.

Recebido: 19 ago. 2020.

Aprovado: 01 out. 2020.

Direito autorial: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



INTRODUÇÃO

Segundo relatório da Organização Mundial da Saúde (OMS), as doenças cardiovasculares (DVCs) são as principais causas da mortalidade humana atualmente (WHO, 2017). A arritmia cardíaca pertence ao grupo de doenças cardiovasculares, sendo caracterizada pela falta de ritmo dos batimentos cardíacos. O diagnóstico de arritmia é dado sobretudo pelo Eletrocardiograma (ECG), uma ferramenta médica responsável por registrar as atividades elétricas cardíacas de um indivíduo.

Normalmente, os sinais biomédicos gerados a partir das gravações de ECG são complexos e não estacionários. Sendo assim, o diagnóstico de arritmia cardíaca torna-se um processo longo e exaustivo, uma vez que os especialistas devem analisar as formas de onda batida a batida. Por conseguinte, a classificação automatizada dos ritmos cardíacos de sinais de ECG pode se tornar uma importante aliada para a geração de laudos médicos (PADMA et al., 2018).

Nos últimos anos, o avanço das técnicas em Aprendizado de Máquina foi notável, recebendo a atenção da academia e da indústria, visto seu progresso considerável em muitos domínios. À vista disso, diversos trabalhos presentes na literatura apresentam a classificação automática de arritmias cardíacas utilizando métodos baseados em Aprendizado de Máquina.

Além disso, abordagens envolvendo Aprendizado Profundo, especialmente as Redes Neurais Convolucionais (Convolutional Neural Networks - CNNs), têm sido amplamente utilizadas na solução de problemas de visão computacional. Segundo o estudo realizado por Kiranyaz et al. (2019), tal popularidade se deu devido à capacidade das CNNs em lidar com padrões e objetos complexos, bem como em processar grandes conjuntos de dados com maior eficiência computacional.

Diante disso, entre as abordagens unidimensionais (1D), ou seja, abordagens que utilizam como entrada os sinais de ECG, está o trabalho realizado por Kachuee, Fazeli e Sarrafzadeh (2018) que propõe uma CNN 1D, a qual utiliza como entrada cinco superclasses de arritmia cardíaca, recomendadas pelo padrão ANSI/AAMI/ISO EC57. De outro modo, o estudo realizado por Wu et al. (2018) tem como finalidade verificar o desempenho de CNNs 1D em comparação às CNNs bidimensionais (2D) na detecção de arritmias cardíacas. Nesse contexto, foi constatado pelos autores que o melhor desempenho foi alcançado pela CNN 2D, a qual obteve resultados superiores em todas as métricas aplicadas.

Isso posto, o presente trabalho busca auxiliar o processo de diagnóstico com o desenvolvimento de uma abordagem capaz de classificar arritmias cardíacas, a partir de sinais de ECG, bem como de imagens oriundas desses sinais, por meio de CNNs 1D e 2D, respectivamente. Para tal, foram utilizadas as cinco superclasses recomendadas pelo padrão ANSI/AAMI/ISO EC57, uma vez que verificou-se a ausência de estudos que as utilizam em cenários 2D.

MATERIAIS E MÉTODOS

O presente trabalho propõe o desenvolvimento de uma abordagem envolvendo uma CNN 2D para a classificação de arritmias cardíacas. Nesse contexto, a aquisição de sinais biomédicos de ECG se deu a partir da base dados

de arritmia MIT-BIH (MOODY, 2010). Além disso, visto que o modelo de CNN proposto utiliza imagens bidimensionais como entrada, os registros de ECG foram pré-processados a fim de gerar imagens de ECG. Em sequência, as imagens obtidas foram divididas em conjuntos de treinamento e teste.

A partir disso, a CNN 2D foi implementada e treinada de modo a classificar cinco superclasses de arritmia cardíaca. Posteriormente, validou-se o desempenho da proposta comparando-o com o de demais arquiteturas disponíveis na literatura. Os resultados alcançados também foram equiparados com o desempenho de uma CNN 1D, cuja entrada é dada por sinais de ECG oriundos da base de dados ECG Heartbeat Classification (FAZELI, 2018), composta pelas mesmas cinco superclasses utilizadas no cenário bidimensional.

BASE DE DADOS

As gravações de ECG utilizadas para a aquisição de imagens bidimensionais foram extraídas da base de dados de arritmia cardíaca MIT-BIH, a qual é composta por 48 gravações de ECG e aproximadamente 110000 batimentos cardíacos rotulados em 20 classes distintas de arritmia cardíaca (MOODY, 2010).

Com a finalidade de comparar o desempenho de diferentes técnicas computacionais para a classificação de arritmias cardíacas, a AAMI desenvolveu o padrão ANSI/AAMI/ISO EC57 para a realização de experimentos e divulgação de resultados. A partir disso, é recomendada a utilização de 16 classes rotuladas pela base de dados MIT-BIH, sendo essas agrupadas em 5 superclasses, conforme apresentado na Tabela 1.

Tabela 1 – Superclasses recomendadas pelo padrão ANSI/AAMI/ISO EC57.

Superclasse	Descrição	Classes agrupadas
N	Batimento normal	N, L, R, e, j
S	Batimento ectópico supraventricular	A, a, J, S
V	Batimento ectópico ventricular	V, E
F	Batimento de fusão	F
Q	Batimento desconhecido	\, f, Q

Fonte: Autoria própria.


Além disso, para a realização de experimentos com CNNs 1D, foi utilizada a base de dados ECG Heartbeat Classification (FAZELI, 2018). Resultado do trabalho proposto por Kachuee, Fazeli e Sarrafzadeh (2018), a mesma foi obtida através do pré-processamento da base de dados de arritmia MIT-BIH (MOODY, 2010), sendo composta por 109446 amostras e cinco superclasses de arritmia cardíaca referentes ao padrão ANSI/AAMI/ISO EC57.

PRÉ-PROCESSAMENTO DOS DADOS

Com o propósito de satisfazer os requisitos de entrada de uma CNN 2D, os sinais de ECG oriundos da base de dados de arritmia cardíaca MIT-BIH foram transformados em imagens. Para tanto, cada batida cardíaca foi plotada a partir da centralização do pico de onda R, assim como recomendado por Wu et al. (2018).

Além disso, as imagens foram plotadas em escala de cinza com resolução de 256x256 pixels, como demonstrado pela Figura 1.

Figura 1 – Exemplo das imagens obtidas.



Fonte: Autoria própria.

Visto que durante a revisão bibliográfica verificou-se a ausência de estudos que utilizam as superclasses recomendadas pela AAMI em abordagens 2D, essas foram utilizadas no presente trabalho para a aquisição das imagens. Desse modo, foram obtidas ao todo 109446 imagens referentes às cinco superclasses recomendadas pelo padrão ANSI/AAMI/ISO EC57.

CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS

A fim de atingir os objetivos do presente trabalho, foi construída uma arquitetura de CNN 2D composta por seis camadas convolucionais e três camadas totalmente conectadas. A arquitetura proposta também é composta por uma camada de Flatten, conforme ilustrada pela Figura 2, a qual é responsável por nivelar a saída das camadas convolucionais.

Figura 2 – Arquitetura do modelo proposto.



Fonte: Autoria própria.

Além disso, foi utilizada a função de ativação Rectified Linear Unit (ReLU), responsável por retornar um valor máximo entre zero e o valor de entrada. Na última camada totalmente conectada utilizou-se a função de ativação Softmax, caracterizada por receber como entrada um vetor e normaliza-lo em uma distribuição de probabilidade proporcional às exponenciais dos valores de entrada.

Também utilizou-se camadas de Dropout entre as camadas totalmente conectadas, uma técnica de regularização responsável por diminuir a capacidade de memorização e aumentar a competência de generalização de uma rede. Assim, a cada iteração, é aleatoriamente removida determinada porcentagem de neurônios de uma camada. Em sequência, na próxima iteração os neurônios removidos são reinseridos.

O otimizador utilizado foi o Adam, um método de descida de gradiente estocástico baseado na estimativa adaptativa de momentos de primeira e segunda

ordem. Nesse sentido, foram realizados experimentos variando o Learning Rate do otimizador, afim de detectar o melhor valor para o cenário.

Além disso, das imagens resultantes do pré-processamento, 80% foram atribuídas ao conjunto de treinamento e 20% ao conjunto de teste. A partir de tais conjuntos, a rede proposta foi treinada ao longo de 50 épocas e testada a fim de realizar as previsões. Nesse sentido, foram realizadas cinco execuções para cada experimento com o intuito de obter a média dos resultados alcançados.

Em sequência, foi construída uma CNN 1D, cuja arquitetura é uma representação unidimensional do modelo proposto. A mesma foi treinada e testada a partir de sinais de ECG divididos em conjuntos de treinamento e teste na mesma proporção que o conjunto de imagens 2D proposto pelo presente trabalho.

RESULTADOS E DISCUSSÃO

A partir das imagens de ECG, foram realizados experimentos com o modelo proposto e arquiteturas disponíveis na literatura, tais como AlexNet, EfficientNet, InceptionV3, ResNet50, VGG16 e VGG19. Após a aquisição dos resultados, verificou-se que o modelo proposto e as arquiteturas EfficientNet, InceptionV3, ResNet50 e VGG16 apresentaram os melhores desempenhos. Visto isso, a Tabela 2 apresenta os resultados alcançados por essas arquiteturas, considerando as métricas de acurácia e precisão, bem como a avaliação dada pela estatística de Youden.

Tabela 2 – Melhores resultados alcançados.

<i>Learning Rate</i>	Arquitetura	Acurácia (%)	Precisão (%)	Estatística de Youden
0,001	Proposta	82,86 ± 0,16	82,86 ± 0,16	0,7858
0,005	EfficientNet	82,79 ± 0,00	82,79 ± 0,00	0,7849
0,005	VGG16	82,79 ± 0,00	82,79 ± 0,00	0,7849
0,01	VGG16	82,79 ± 0,00	82,79 ± 0,00	0,7332
0,05	EfficientNet	82,79 ± 0,00	82,79 ± 0,00	0,7849
0,05	InceptionV3	82,79 ± 0,01	82,79 ± 0,01	0,7849
0,05	Resnet50	82,79 ± 0,00	82,79 ± 0,00	0,7849

Fonte: Autoria própria.

O modelo proposto alcançou acurácia média de 82,86% e também se destacou segundo a estatística de Youden, o que comprova que a classificação ocorreu de forma satisfatória. Além disso, a fim de verificar o desempenho da proposta na classificação por classes, foi gerada a matriz de confusão, ilustrada pela Figura 3.

Figura 3 – Matriz de confusão do modelo bidimensional proposto.

Rótulo	Previsões				
	N	S	V	F	Q
N	14495	8	0	3615	0
S	0	462	92	0	2
V	0	119	1187	1	141
F	22	7	1	132	0
Q	2	50	0	237	1319

Fonte: Autoria própria.

Por fim, o modelo proposto foi adaptado para uma CNN 1D. Também foram realizados experimentos variando o valor do Learning Rate e assim verificou-se que o melhor resultado foi obtido com um valor de 0,001, alcançando uma acurácia média de 98,55%. Além disso, a abordagem 1D atingiu um índice de 0,9824 pela estatística de Youden, o que denota a existência de poucos falsos positivos e falsos negativos. Sua eficiência na classificação também é comprovada pela matriz de confusão, apresentada pela Figura 4.

Figura 3 – Matriz de confusão do modelo unidimensional proposto.

Rótulo	Previsões				
	N	S	V	F	Q
N	18044	46	20	6	2
S	98	450	5	3	0
V	49	5	1361	30	3
F	17	0	5	140	0
Q	20	0	0	2	1586

Fonte: Autoria própria.

Isto posto, verificou-se que a arquitetura proposta apresentou resultados significativos em ambos os cenários, comprovando a eficiência das CNNs para a classificação de arritmias cardíacas. Contudo, a abordagem 1D superou a 2D no quesito acurácia em 15,68%, indicando ser a implementação mais adequada do modelo proposto para a realização das predições.

CONCLUSÃO

Visto a importância do monitoramento regular do ritmo cardíaco para pacientes com arritmias cardíacas, tornou-se pertinente o desenvolvimento de técnicas que implementem a detecção e a classificação automática das mesmas. Nesse sentido, o presente trabalho propôs a classificação de cinco superclasses de arritmias cardíacas por meio de CNNs 1D e 2D.

Para o cenário 2D, imagens de ECG foram geradas e utilizadas para treinar uma CNN 2D que alcançou índice de 0,7858 na estatística de Youden, o que indica que a classificação ocorreu de forma satisfatória. Por outro lado, na abordagem 1D, sinais de ECG foram utilizados como entrada para uma CNN 1D, com arquitetura similar à CNN 2D proposta. O cenário 1D ultrapassou o desempenho atingido pelo 2D, obtendo 98,55% de acurácia média e índice de 0,9824 pela estatística de Youden.

Sendo assim, os resultados do presente trabalho indicam que a utilização de CNNs para a classificação de arritmias cardíacas é adequada, especialmente para o cenário 1D. Além disso, a arquitetura de CNN proposta apresentou melhor desempenho em relação ao de algumas arquiteturas disponíveis na literatura, podendo ser utilizada para auxílio a diagnósticos médicos.

AGRADECIMENTOS

Agradeço a Universidade Tecnológica Federal do Paraná pelo ambiente de aprendizagem, ao CNPq (processo 431668/2016-7) e a NVIDIA pela disponibilização da placa de vídeo GeForce GTX 1080 Ti, utilizada para a realização dos experimentos.

REFERÊNCIAS

FAZELI, S. ECG Heartbeat Categorization Dataset. Kaggle, mai. 2018. Disponível em: <https://www.kaggle.com/shayanfazeli/heartbeat>. Acesso em: 26 out. 2019.

KACHUEE, M.; FAZELI, S.; SARRAFZADEH, M. ECG Heartbeat Classification: A Deep Transferable Representation. In: 2018 IEEE International Conference on Healthcare Informatics (ICHI). IEEE, jun. 2018. DOI: 10.1109/ichi.2018.00092.

KIRANYAZ, S. et al. 1D Convolutional Neural Networks and Applications: A Survey. 2019. ArXiv: 1905.03554.

MOODY, G. B. MIT-BIH Arrhythmia Database Directory (Introduction). 2010. Disponível em: <https://physionet.org/physiobank/database/html/mitdbdir/intro.htm>. Acesso em: 26 out. 2019.

PADMA, S. et al. Carotid Arterial Pulse Waveform Measurements Using Fiber Bragg Grating Pulse Probe. IEEE Journal of Biomedical and Health Informatics, Institute of Electrical e Electronics Engineers (IEEE), v. 22, n. 5, p 1415-1420, set. 2018. DOI: 10.1190/jbhi.2017.2765701.

WHO. Cardiovascular Diseases (CVDs). World Health Organization, mai. 2017. Disponível em: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)). Acesso em: 25 out. 2019.

WU, Y. et al. A Comparison of 1-D and 2-D Deep Convolutional Neural Networks in ECG Classification. 2018.