

3.13.99 – Engenharia Biomédica.

CLASSIFICAÇÃO DE ARRITMIAS CARDÍACAS COM REDES NEURAIS PERCEPTRON MULTICAMADANatália Nagata¹, Renato Candido², Magno T. M. Silva³

1. Estudante de Engenharia Elétrica, da Escola Politécnica da Universidade de São Paulo (EPUSP)
2. Pesquisador Associado da EPUSP - Departamento de Engenharia de Sistemas Eletrônicos/Coorientador
3. Professor da EPUSP - Departamento de Engenharia de Sistemas Eletrônicos/Orientador

Resumo

O desenvolvimento de sistemas de diagnóstico automatizado a partir do sinal de eletrocardiograma (ECG) é um assunto de interesse desde a década de 1980. Recentemente, com o surgimento de novas técnicas de aprendizado de máquina, a pesquisa em automatização do diagnóstico de arritmias cardíacas atraiu novamente a atenção da comunidade científica. Neste trabalho, utilizam-se redes neurais do tipo perceptron multicamada (*multilayer perceptron* - MLP) para classificação automática de arritmias, considerando a abordagem mais realista de separação dos dados dos pacientes durante as fases de treinamento e teste. Os objetivos da pesquisa são: (i) encontrar as melhores estruturas de redes MLP para o problema em termos de métricas de classificação, (ii) estudar o efeito da entrada e da extração de características no desempenho da rede e (iii) realizar uma análise comparativa dos resultados obtidos com os da literatura.

Palavras-chave: Sinal de ECG; diagnóstico automático; cardiologia.

Apoio financeiro: FAPESP (2019/26911-6 e 2017/20378-9)

Trabalho selecionado para a JNIC: Pró-Reitoria de Pesquisa da USP

Introdução

Segundo a Organização Mundial da Saúde (OMS), as doenças cardiovasculares são a principal causa de morte no mundo e as arritmias cardíacas são algumas das doenças cardiovasculares mais comuns [1]. As arritmias correspondem a qualquer distúrbio na taxa, na regularidade e nos locais de origem ou condução dos impulsos elétricos cardíacos [2]. O diagnóstico das arritmias é feito pela análise do sinal de eletrocardiograma (ECG), que registra a atividade elétrica do coração pelos potenciais superficiais do corpo ao longo do tempo.

A análise manual do ECG demanda muito tempo do especialista e é dificultada pelas características morfológicas variáveis do sinal. Algumas arritmias aparecem raramente e pode ser necessário gravar até uma semana de atividade do ECG, o que impossibilita a obtenção de resultados imediatos [3]. Assim, muitos métodos computadorizados para detecção automática têm sido propostos na literatura [2, 4]. Devido às altas taxas de erro desses métodos e ao crescimento da área de aprendizado de máquina [5], a pesquisa em automatização do diagnóstico de arritmias cardíacas ressurgiu [3, 6-9].

Recentemente, soluções baseadas em redes neurais, como redes perceptron multicamada (MLP) [3], convolucionais [6, 7] e recorrentes [8, 9] têm sido propostas na literatura. Em vários desses trabalhos, os autores utilizam dados dos mesmos pacientes tanto no conjunto de teste, quanto no de treinamento. Essa abordagem não é clinicamente realista, já que na prática o sistema treinado será utilizado em pacientes cujos dados não foram usados no treinamento. Neste artigo, propõe-se o uso de redes neurais do tipo MLP para detecção e classificação de arritmias cardíacas, usando a separação dos pacientes nas fases de treinamento e teste do banco de dados *MIT-BIH Arrhythmia Database* (MITDB) [10, 11]. Os objetivos do trabalho são: (i) propor melhores estruturas de redes MLP como classificadores em termos de métricas de desempenho, (ii) identificar a influência das características usadas como entrada e (iii) realizar uma comparação com a literatura.

Metodologia

O MITDB é composto por 48 gravações ambulatoriais de duas derivações de 30 minutos de pacientes do *Boston's Beth Israel Hospital*, com anotações manuais de cada batimento feitas por cardiologistas. Como o sinal de ECG é característico de cada indivíduo e de sua condição física, para não prejudicar a generalização dos métodos de automatização de diagnóstico, a *Association for the Advancement of Medical Instrumentation* (AAMI) [12] recomenda a divisão das gravações de modo que batimentos de um mesmo paciente não sejam simultaneamente usados nos conjuntos de treinamento e de teste. Apesar disso, poucos pesquisadores seguem as recomendações da AAMI, originando resultados favorecidos e não realistas, o que dificulta a verificação dos méritos relativos aos diferentes algoritmos. Neste trabalho, seguiu-se a divisão por pacientes proposta por De Chazal et al. [13]. Além disso, os dados foram classificados entre as cinco classes sugeridas pela AAMI: 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). A implementação do classificador foi dividida em quatro etapas conforme esquematizado na Figura 1.

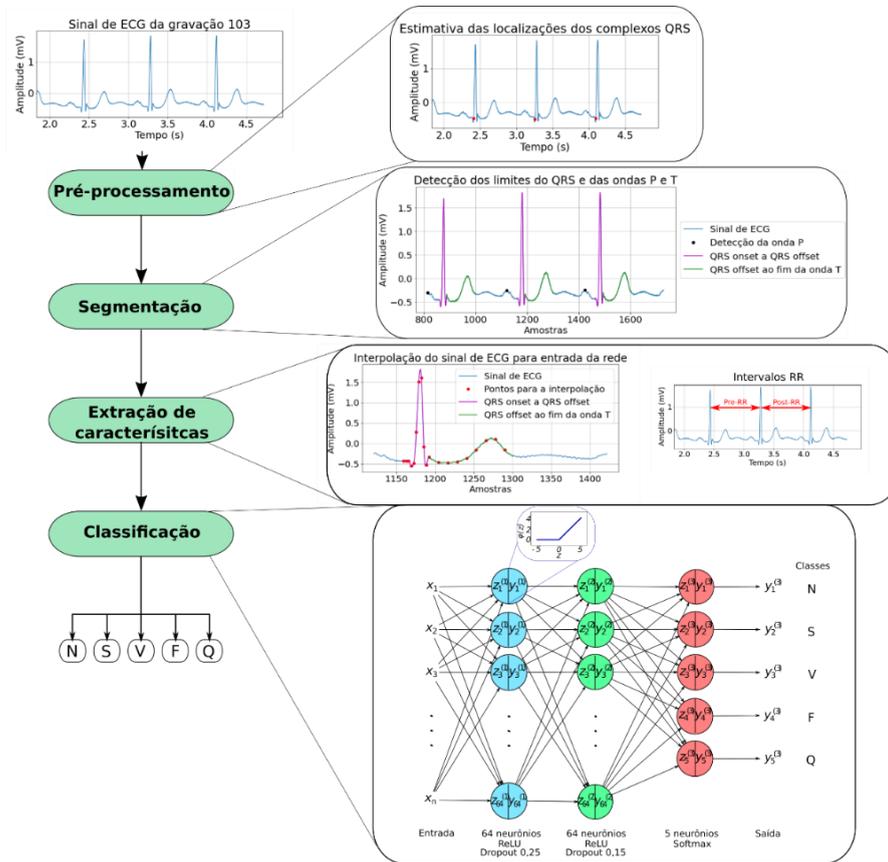


Figura 1 – Diagrama das quatro etapas de técnicas computadorizadas para análise de ECG.

A etapa de pré-processamento reduz os ruídos e artefatos provenientes de várias origens, como a rede elétrica. A segmentação delimita o complexo QRS e as ondas P e T. Para isso, usou-se o método proposto em [14], baseado em Transformada de Wavelet e implementado em MATLAB pelo pacote ecg-kit [15]. Já a etapa de extração de características determina a menor quantidade de características do sinal de ECG que permite taxas de classificação aceitáveis. Um exemplo de extração foi proposto por [13], em que são tomadas 10 amostras do complexo QRS, 9 amostras entre o fim do QRS e o fim da Onda T, informações dos intervalos RR, da duração do QRS e da Onda T e a presença da Onda P. Além dessas características, considera-se aqui o uso de um ou três batimentos do sinal original como entrada.

Na etapa de classificação, considerou-se uma MLP de duas camadas ocultas, ambas com 64 neurônios, funções de ativação ReLU, e *dropout* de 0,15 e 0,25 respectivamente. Na camada de saída, foram utilizados 5 neurônios com função Softmax. Para trabalhar com as classes desbalanceadas, usou-se a função custo de entropia cruzada categórica com pesos calculados na proporção inversa do número de dados de cada classe. Considerou-se ainda o algoritmo de otimização Adam com $\beta_1 = 0,9$ e $\beta_2 = 0,99$, e o algoritmo de retropropagação (*backpropagation*) com passo de aprendizado $\eta = 0,001$, 1000 épocas para o treinamento e *mini-batches* de tamanho $k = 2048$. Todas as etapas, com exceção da extração de características, foram implementadas em Python e as redes foram implementadas usando as bibliotecas Tensorflow e Keras [16].

Resultados e Discussão

As configurações usadas nas entradas foram de um ou três batimentos do sinal original da primeira derivação (A1, A2) e da segunda derivação (B1, B2), de três batimentos das duas derivações (AB), de três batimentos da primeira derivação junto às informações dos intervalos RR (A3) e de características extraídas como em [13] a partir das duas derivações (C). Calcularam-se as métricas de Acurácia geral (Acc),

$$Acc = \frac{VP + VN}{VP + VN + FP + FN},$$

e de Sensibilidade (Se) e Precisão (P) para cada classe,

$$Se = \frac{VP}{VP + FN} \text{ e } P = \frac{VP}{VP + FP},$$

em que VP, VN, FP e FN são, respectivamente, as quantidades de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Seguindo a recomendação da AAMI [12, 13], os falsos positivos devido à classe Q foram desconsiderados para a classe S e os falsos positivos devido às classes F e Q foram desconsiderados para a classe V.

Os resultados e o número de parâmetros para cada configuração estão apresentados na Tabela 1, junto aos resultados de [13], considerado como estado da arte. O número de parâmetros da solução de [13] não foi especificado e, portanto, não foi considerado na tabela. Devido à ausência do padrão Q, tanto na literatura quanto no presente trabalho, essa classificação não foi considerada na tabela.

Tabela 1 – Acurácia da rede (Acc), Sensibilidade (Se) e Precisão (P) de cada classe considerando diferentes entradas. Os maiores valores de cada métrica estão em negrito.

i	Acc	N		S		V		F		Número de Parâmetros
		Se (%)	P (%)							
A1	68,10	73,02	83,48	23,81	25,32	88,94	71,99	2,93	1,37	25029
A2	76,67	82,74	86,90	51,55	63,08	79,89	70,99	14,36	7,62	65989
B1	53,20	55,11	90,69	5,38	8,99	82,01	32,12	23,67	12,13	25029
B2	55,85	62,34	86,82	4,93	7,88	72,81	32,74	0,27	0,24	65989
AB	72,40	75,86	84,77	46,85	59,14	87,76	68,21	3,46	1,40	127429
A3	75,43	81,07	86,16	26,99	51,22	91,25	78,35	36,44	12,38	66437
C	71,15	74,25	92,41	35,94	33,91	80,73	72,11	75,27	17,13	7429
[13]	85,9	86,9	99,2	75,9	38,5	77,7	81,9	89,4	8,6	–

Para a primeira derivação, as métricas da configuração A2 são significativamente maiores do que as da A1, com um aumento da Acurácia, da Sensibilidade e da Precisão das classes N, S e F. Observou-se que os batimentos anterior e posterior ao batimento atual auxiliam a classificação, fornecendo melhores resultados para essa derivação. Já na segunda derivação, ambas as configurações B1 e B2 apresentam métricas baixas para classe S, Acurácias menores do que a primeira derivação, e resultados semelhantes entre si, com exceção da classe F, que foi melhor classificada na B1.

O uso de três batimentos das duas derivações (AB) não apresenta um ganho significativo em relação ao uso de A2, com um aumento apenas na Sensibilidade de V. Além disso, requer aproximadamente o dobro de parâmetros, sendo mais custoso. Em A3, o acréscimo da informação dos intervalos RR à configuração A2 auxiliou as classes V e F, mas prejudicou S. Por fim, a extração de características na configuração C permitiu aumentar a Sensibilidade de F, levando aos maiores valores de métricas dessa classe, e à maior Precisão de N, apesar de utilizar uma quantidade de parâmetros menor.

Na literatura, o desempenho da classe S é, em geral, muito baixo. Luz et al. implementaram em [17] os métodos propostos em [18-22] seguindo as recomendações da AAMI, o que levou a valores de no máximo 27,0% para Sensibilidade e de no máximo 48,3% para Precisão. Os resultados de [17] são inferiores aos da rede proposta com A2 na maioria das métricas. Considerando-se também os artigos [23-26], que otimizam classificadores para N, S e V, em um problema de apenas 3 classes, a rede proposta com A2 atinge uma Precisão da classe S melhor do que o maior dos valores da literatura, que é 53%, mas apresenta as métricas da classe N menores. Ainda assim, foi possível atingir os valores relatados pela literatura para as classes S e V, mesmo sem uma otimização para o problema de 3 classes.

Conclusões

Diversos trabalhos que utilizam redes neurais para classificação de arritmias cardíacas não separam os dados dos pacientes de modo realista e atingem desempenhos muito bons, com métricas acima de 95% de acerto. Como sugerido por [17], para permitir identificar os méritos dos diferentes métodos de diagnóstico automático propostos na literatura, é importante o estabelecimento de padrões de separação dos pacientes em treinamento e teste como os da AAMI. Além disso, observou-se que a eliminação de dados pode prejudicar a generalização da rede, descartando exemplos que poderiam contribuir no treinamento. Esse fato também foi constatado por [13] e evitado por uma função custo com pesos, que lida com o desbalanceamento dos dados e obtém resultados melhores do que subamostrar extensivamente algumas classes ou sobreamostrar dados.

Diversas simulações com a rede proposta mostraram que, para a primeira derivação, uma MLP com entrada de três batimentos atinge resultados melhores para a maior parte das métricas do que uma entrada com apenas um batimento. Isso se deve à informação do batimento anterior e posterior ao analisado, e, conseqüentemente, à informação do intervalo RR que entra na rede, o que pode ser justificado pela irregularidade desses intervalos em classes de arritmia, como a S, e pela sua regularidade na classe N.

A comparação dos resultados mostra que a rede proposta com A2 alcança os valores usuais apresentados na literatura para as classes N, S e V, e atinge uma Precisão de S maior do que [13,18-26], apesar de obter Acurácia e métricas de N menores. Similarmente, a rede proposta com C possibilita desempenhos melhores na classe F, com valor de Precisão maior do que os demais, e utiliza uma quantidade bem menor de parâmetros. Percebeu-se que as entradas de [13], também utilizadas por outros artigos, beneficiam as métricas da classe F na MLP proposta. Concluiu-se, principalmente, que a extração de características é uma etapa essencial na MLP, uma vez que permite alcançar bons resultados utilizando uma menor quantidade de parâmetros.

Referências bibliográficas

- [1] **World Health Organization:** The top 10 causes of death, 8 de dez. 2020. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>>. Acesso em: 9 de jan. de 2021.
- [2] BERKAYA, S. K. et al. A survey on ECG analysis. **Biomedical Signal Processing and Control**, v. 43, p. 216-235, 2018.
- [3] DEWANGAN, N. K.; SHUKLA, S. P. ECG arrhythmia classification using discrete wavelet transform and artificial neural

- network. In: **2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)**. IEEE, 2016. p. 1892-1896.
- [4] MARINHO, L. B. et al. A novel electrocardiogram feature extraction approach for cardiac arrhythmia classification. **Future Generation Computer Systems**, v. 97, p. 564-577, 2019.
- [5] GOODFELLOW, I. et al. **Deep learning**. Cambridge: MIT press, 2016.
- [6] HANNUN, A. Y. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. **Nature medicine**, v. 25, n. 1, p. 65-69, 2019.
- [7] ACHARYA, U. R. et al. A deep convolutional neural network model to classify heartbeats. **Computers in biology and medicine**, v. 89, p. 389-396, 2017.
- [8] WANG, G. et al. A global and updatable ECG beat classification system based on recurrent neural networks and active learning. **Information Sciences**, v. 501, p. 523-542, 2019.
- [9] BANERJEE, R.; GHOSE, A.; KHANDELWAL, S. A Novel Recurrent Neural Network Architecture for Classification of Atrial Fibrillation Using Single-lead ECG. In: **2019 27th European Signal Processing Conference (EUSIPCO)**. IEEE, 2019. p. 1-5.
- [10] GOLDBERGER, A. L. et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. **Circulation**, v. 101, n. 23, p. e215–e220, 2000.
- [11] MOODY, G. B.; MARK, R. G. The impact of the MIT-BIH arrhythmia database. **IEEE Engineering in Medicine and Biology Magazine**, v. 20, n. 3, p. 45-50, 2001.
- [12] AAMI, ANSI; EC57, A. A. M. I. (R) 2008-Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms. **American National Standards Institute**, Arlington, VA, USA, 2008.
- [13] DE CHAZAL, P.; O'DWYER, M.; REILLY, R. B. Automatic classification of heartbeats using ECG morphology and heartbeat interval features. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 7, p. 1196-1206, 2004.
- [14] MARTÍNEZ, J. P. et al. A wavelet-based ECG delineator: evaluation on standard databases. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 4, p. 570-581, 2004.
- [15] DEMSKI, A. J.; SORIA, M. L. ecg-kit: a Matlab Toolbox for Cardiovascular Signal Processing. **Journal of Open Research Software**, v. 4, n. 1, 2016.
- [16] ABADI, Martín et al. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Disponível em: <<https://www.tensorflow.org>>. Acesso em: 17 de jan. de 2020.
- [17] LUZ, E.; MENOTTI, D. How the choice of samples for building arrhythmia classifiers impact their performances. In: **2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. IEEE, 2011. p. 4988-4991.
- [18] YE, C.; COIMBRA, M. T.; KUMAR, B. V. K. V. Arrhythmia detection and classification using morphological and dynamic features of ECG signals. In: **2010 Annual International Conference of the IEEE Engineering in Medicine and Biology**. IEEE, 2010. p. 1918-1921.
- [19] YU, S.-N.; CHOU, K.-T. Integration of independent component analysis and neural networks for ECG beat classification. **Expert Systems with Applications**, v. 34, n. 4, p. 2841-2846, 2008.
- [20] YU, S.-N.; CHEN, Y.-H. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. **Pattern Recognition Letters**, v. 28, n. 10, p. 1142-1150, 2007.
- [21] GÜLER, I.; ÜBEYLI, E. D. ECG beat classifier designed by combined neural network model. **Pattern recognition**, v. 38, n. 2, p. 199-208, 2005.
- [22] SONG, M.-H. et al. Support vector machine based arrhythmia classification using reduced features. **International Journal of Control, Automation, and Systems**, v. 3, n. 4, p. 571-579, 2005.
- [23] LLAMEDO, M.; MARTÍNEZ, J. P. Heartbeat classification using feature selection driven by database generalization criteria. **IEEE Transactions on Biomedical Engineering**, v. 58, n. 3, p. 616-625, 2010.
- [24] LIN, C.-C.; YANG, C.-M. Heartbeat classification using normalized RR intervals and morphological features. **Mathematical Problems in Engineering**, v. 2014, 2014.
- [25] GARCIA, G. et al. Improving automatic cardiac arrhythmia classification: Joining temporal-VCG, complex networks and SVM classifier. In: **2016 International Joint Conference on Neural Networks (IJCNN)**. IEEE, 2016. p. 3896-3900.
- [26] GARCIA, G. et al. Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO. **Scientific Reports**, v. 7, n. 1, p. 1-11, 2017.