

Análise de ECG e detecção de arritmias

FREIRE, M. A.¹, KRUMMENAUER, C.², MACHADO, J.³

¹ Instituto Federal Sul-Rio-Grandense (IFSUL) – Charqueadas – RS – Brasil – ch-gabdir@ifsul.edu.br

RESUMO

Este meta-artigo descreve um trabalho que tem como intuito realizar a identificação de sinais cardíacos diferenciando entre arritmias do tipo Q, F, S, V, N e sinais normais, além da descrição dos avanços e resultados, também é mostrada a metodologia utilizada para esta construção. Após alcançar os resultados mostrados no artigo que é utilizado como base, teremos o objetivo de incluir este classificador em uma nuvem do servidor AWS.

Palavras-chave: Detecção Arritmias, ECG, LSTM, Python.

1 INTRODUÇÃO

O aumento da proporção de brasileiros com 65 anos ou mais vai dos cerca de 10% atualmente, para 21,9% em 2050, segundo projeções do Instituto de Pesquisa Econômica Aplicada (IPEA) (BONIFÁCIO; GUIMARÃES, 2021) e esse rápido envelhecimento da nossa população irá aumentar a carga sobre o sistema de saúde, visto que pessoas idosas estão mais suscetíveis a problemas de saúde que a fatia mais jovem da sociedade.

Além disso, mesmo após a pandemia da COVID-19, há a preocupação com os efeitos decorrentes da covid longa, onde sintomas respiratórios, cardíacos e neurológicos podem se estender por períodos maiores que 6 meses após a eliminação do vírus (BAIG, 2021; PERGOLIZZI et al., 2021; RUSHFORTH et al., 2021; YONG, 2021). Arritmias podem ser um dos sintomas das cardiopatias causadas pela COVID longa (YONG, 2021) e segundo o instituto norte-americano National Heart, Lung, and Blood Institute, uma das principais formas de identificar arritmias é através do exame de eletrocardiograma (ECG) (NHLBI, 2021).

Dentro deste contexto, o desenvolvimento de sistemas de ECG inteligentes, que possuam a capacidade de identificar arritmias de forma automática traria mais uma ferramenta para o corpo médico. Além disso, é possível desenvolver esses sistemas com conexão à internet, também conhecidos como ECG-IoT (Internet of Things), que além de realizarem a aquisição do sinal de ECG, podem enviar para um servidor, através de um sistema em nuvem, para posterior processamento.

Considerando que processadores em nuvem possuem uma capacidade computacional maior que sistemas embarcados, é possível executar algoritmos inteligentes para detecção de arritmias, que são foco de pesquisas atuais (ALFARAS; SORIANO; ORTÍN, 2019; DE MELO RIBEIRO et al., 2022; HU; CHEN; ZHOU, 2022). Portanto, esse trabalho tem o objetivo de desenvolver um sistema inteligente de classificação de arritmias e implementá-lo dentro do sistema de nuvem da Amazon (AWS). Para isso será implementado o classificador desenvolvido por BODA, MAHADEVAPPA e KUMAR DUTTA (2023), onde uma Rede Neural Recorrente (RNR) classifica características temporais e em tempo frequência, através de coeficientes *wavelets*.

2 METODOLOGIA (MATERIAL E MÉTODOS)

Slide 6-10

Para este trabalho, utilizamos Python, bibliotecas voltadas a manuseio de dados (Numpy, Pandas, Matplotlib e Pylab), criação e treinamento de redes LSTM (Tensorflow, Keras). O dataset utilizado foi o *PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals* que é disponibilizado pelo MIT nomeado de “MIT-BIH Arrhythmia Database” com o objetivo central para o desenvolvimento do artigo *The impact of the MIT-BIH arrhythmia database*. Após realizarmos o download, foi feita a filtragem dos sinais disponibilizados para retirar os ruídos de baixas e altas frequências, porém os pontos referentes aos sinais também precisaram ser alterados, pois identificavam os pontos do sinal sem filtro, por se tratar de um valor de deslocamento fixo, foi necessário apenas realizar um incremento em todos os pontos informados.

Depois de ter o sinal filtrado e com a identificação de todas as batidas, foi iniciada a construção do dataset, foi preciso realizar a inserção de 4 características temporais que se relacionavam as distâncias entre picos e 4 morfológicas que se relacionavam aos coeficientes de *wavelets*. Cada linha do dataset possuía as seguintes informações: sinal da batida normalizado, 4 coeficientes temporais e 4 coeficientes morfológicos.

Após a finalização da divisão das batidas e características, foi realizada a divisão entre datasets, sendo eles DS1, DS21 e DS22. O DS1 se trata do dataset de treino geral, contendo dados dos indivíduos identificados com o número inicial 1, já o DS21 também é um dataset de treino porém específico e se trata dos primeiros 5

minutos do sinal dos indivíduos com número inicial 2, ou seja, cada indivíduo possui um dataset, e o DS22 se trata dos 25 minutos restantes do sinal dos indivíduos com número inicial 2. Desta forma cada indivíduo possui um dataset diferente para treino, um dataset dedicado para características daquele indivíduo.

Tendo todos os dataset divididos, foi iniciada a construção da rede LSTM, a entrada foi adequada as dimensões do dataset e a saída é baseada em um vetor de 5 posições e cada posição pode ser 0 ou 1, sendo assim identificando o tipo de batida que foi identificada. Também foi realizado o *shuffle* do dataset e os *call-backs* alimentavam vetores de *loss* e *acuracidade*. Após a construção a rede ficou com o layout mostrado na Figura 1 - Layout rede LSTM.

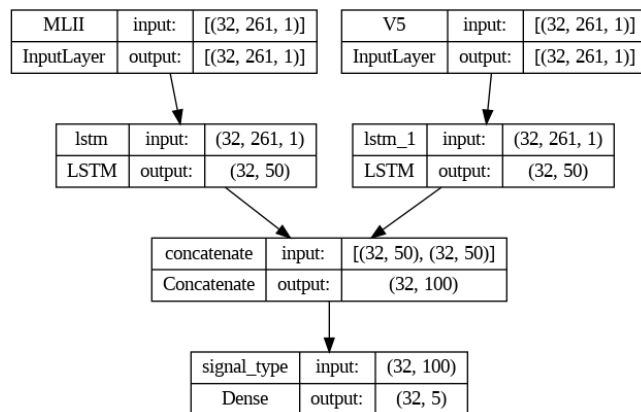


Figura 1 - Layout rede LSTM

Com o dataset e a base de treinamento construídos, iniciamos os treinamentos com 1000 épocas, armazenando todos os dados de todas as épocas.

3 RESULTADOS E DISCUSSÃO

Os resultados obtidos por épocas são possíveis de serem visualizados na Figura 2 - Resultado por época.

Os resultados armazenados estão por épocas pois está sendo aferido qual a quantidade ideal de épocas a serem utilizadas. Após visualizar os dados obtidos, foi visto que podemos prosseguir com o treinamento por mais épocas, já que não ocorreu o *overfit*, sendo assim este se trata dos próximos passos deste projeto. A realização dos treinamentos até 2000 épocas e visualização dos resultados obtidos por cada modelo.

Dados referentes a época 100					Dados referentes a época 600				
N	S	V	F	Q	N	S	V	F	Q
N 40450	689	456	203	20	N 40568	480	529	226	15
S 1082	1052	142	39	7	S 1047	1138	119	14	4
V 427	35	4189	115	23	V 315	26	4298	129	21
F 53	11	89	447	0	F 40	8	66	485	1
Q 3	2	0	0	0	Q 2	1	2	0	0

Dados referentes a época 200					Dados referentes a época 700				
N	S	V	F	Q	N	S	V	F	Q
N 40326	770	460	251	11	N 40755	566	380	100	17
S 1007	1129	158	21	7	S 1066	1167	64	11	14
V 347	41	4272	111	18	V 391	26	4310	45	17
F 49	14	89	448	0	F 43	8	81	468	0
Q 3	2	0	0	0	Q 4	1	0	0	0

Dados referentes a época 300					Dados referentes a época 800				
N	S	V	F	Q	N	S	V	F	Q
N 40563	516	444	279	16	N 40516	549	526	212	15
S 1041	1089	162	24	6	S 1136	1111	52	16	7
V 487	39	4119	129	15	V 304	33	4381	54	17
F 55	17	70	458	0	F 44	10	91	455	0
Q 2	2	1	0	0	Q 2	1	1	0	1

Dados referentes a época 400					Dados referentes a época 900				
N	S	V	F	Q	N	S	V	F	Q
N 40779	533	329	161	16	N 40860	483	326	134	15
S 975	1150	168	24	5	S 1042	1196	64	13	7
V 501	30	4165	76	17	V 367	32	4328	45	17
F 52	14	76	458	0	F 45	10	87	458	0
Q 3	2	0	0	0	Q 3	1	0	0	1

Dados referentes a época 500					Dados referentes a época 1000				
N	S	V	F	Q	N	S	V	F	Q
N 40721	516	411	155	15	N 40876	503	304	113	22
S 1082	1117	103	15	5	S 1051	1190	63	12	6
V 370	20	4289	85	16	V 431	36	4268	41	13
F 40	11	71	478	0	F 50	6	85	459	0
Q 3	2	0	0	0	Q 3	0	1	0	1

Figura 2 - Resultado por época

4 CONCLUSÃO

Os resultados mostram que o classificador está muito próximo do que foi obtido por BODA, MAHADEVAPPA e KUMAR DUTTA (2023), com exceção da arritmia tipo S. Como ainda não se observou *overfitting* da rede, mesmo considerando 1000 épocas, o próximo passo será treinar todos os modelos para valores maiores que 1000 épocas e avaliar novamente os resultados.

Em paralelo já estão sendo realizados estudos para integração do sistema com a nuvem AWS, onde o primeiro problema a ser explorado é o *parsing* dos dados que chegam na nuvem e os dados que são processados pelo algoritmo de classificação.

REFERÊNCIAS

ALFARAS, Miquel; SORIANO, Miguel C.; ORTÍN, Silvia. A Fast Machine Learning Model for ECG-Based Heartbeat Classification and Arrhythmia Detection. *Frontiers in Physics*, [s. l.], v. 0, p. 103, 2019.

BAIG, Abdul Mannan. Chronic long-COVID syndrome: A protracted COVID-19 illness with neurological dysfunctions. *CNS Neuroscience & Therapeutics*, [s. l.], v. 27, n. 12, p. 1433–1436, 2021.

BODA, Somaraju, MAHADEVAPPA, Mahadevappa, KUMAR DUTTA, Pranab. An automated patient-specific ECG beat classification using LSTM-based recurrent

neural networks. *Biomedical Signal Processing and Control*, vol. 84, p. 104756, 2023.

BONIFÁCIO, Gabriela; GUIMARÃES, Raquel. *Projeções populacionais por idade e sexo para o Brasil até 2100* Texto para Discussão - IPEA. Rio de Janeiro: [s. n.], 2021.

DE MELO RIBEIRO, Henrique et al. ECG-based real-time arrhythmia monitoring using quantized deep neural networks: A feasibility study. *Computers in Biology and Medicine*, [s. l.], v. 143, p. 105249, 2022.

GOLDBERGER, A., et al. "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation [Online]*. 101 (23), pp. e215–e220." (2000).

HU, Rui; CHEN, Jie; ZHOU, Li. A transformer-based deep neural network for arrhythmia detection using continuous ECG signals. *Computers in Biology and Medicine*, [s. l.], v. 144, p. 105325, 2022.

MOODY, George B.; MARK, Roger G. The impact of the MIT-BIH arrhythmia database. *IEEE engineering in medicine and biology magazine*, v. 20, n. 3, p. 45-50, 2001.

NHLBI. Arrhythmia | NHLBI, NIH. [S. l.], 2021. Disponível em: <https://www.nhlbi.nih.gov/health-topics/arrhythmia>. Acesso em: 12 nov. 2023.

PERGOLIZZI, Joseph V. et al. It's not over till it's over: A narrative review of long covid. *Signa Vitae*, [s. l.], v. 17, n. 3, p. 21–30, 2021.

RUSHFORTH, Alex et al. Long Covid – The illness narratives. *Social Science & Medicine*, [s. l.], v. 286, p. 114326, 2021.

YONG, Shin Jie. Long COVID or post-COVID-19 syndrome: putative pathophysiology, risk factors, and treatments. *Infectious Diseases*, [s. l.], v. 53, n. 10, p. 737–754, 2021.