



VIII Encontro de Iniciação Científica e Tecnológica

VIII EnICT

ISSN: 2526-6772

IFSP – Câmpus Araraquara

19 e 20 de outubro de 2023



Projeto e Avaliação de Sistema Preditor de Surtos Epiléticos Usando Transformada Wavelet e Correlação em Eletroencefalograma

Luis Otávio L. Amorim¹, Miguel Angelo de A. de Sousa², Sara D. dos Santos³, Ricardo Pires⁴

¹ Instituto Federal de São Paulo, Câmpus São Paulo, luisotaviolamorim@gmail.com

² Dr., Instituto Federal de São Paulo, Câmpus São Paulo, angelo@ifsp.edu.br

³ Dr., Instituto Federal de São Paulo, Câmpus São Paulo, sarad@ifsp.edu.br

⁴ Dr., Instituto Federal de São Paulo, Câmpus São Paulo, ricardo_pires@ifsp.edu.br

Área de conhecimento (Tabela CNPq): 3.13.01.01-0 Processamento de Sinais Biológicos.

RESUMO: A epilepsia é um dos distúrbios neurológicos mais comuns do mundo. Sua análise e diagnóstico é feita baseada no exame de eletroencefalograma (EEG). Seus tratamentos, baseados em medicamentos contínuos ou cirurgia, não têm uma boa eficácia para muitos pacientes. Desta forma, um sistema que detectasse um surto iminente seria muito interessante para que o paciente pudesse, ao ser advertido, colocar-se em uma situação de maior segurança. Neste contexto, diversas abordagens publicadas foram tentadas. Dentre elas, uma que se destaca utiliza um algoritmo de aprendizagem de máquina chamado *long short-term memory* (LSTM) e diversas características do EEG. Por mais que haja problemas na metodologia desta abordagem, foram obtidos resultados interessantes ao utilizá-la com algumas das características utilizadas naquele trabalho. Neste trabalho busca-se verificar se essas características trazem bons resultados se utilizadas em conjunto.

PALAVRAS-CHAVE: Processamento digital de sinais; Aprendizagem de Máquina; LSTM; Epilepsia.

INTRODUÇÃO

A epilepsia é um dos distúrbios neurológicos mais comuns, afetando 65 milhões de pessoas no mundo (EPILEPSY FOUNDATION, 2021; WORLD HEALTH ORGANIZATION, 2019). Ela é diagnosticada após uma pessoa ter tido ao menos dois surtos sem nenhuma outra causa médica conhecida.

Os surtos sofridos pelos pacientes ocorrem devido a distúrbios na atividade elétrica do cérebro. Esses distúrbios podem estar relacionados a lesões no cérebro ou mesmo a causas genéticas. Porém, na maioria dos casos, a causa é desconhecida (SHAFER; SIRVEN, 2020). Surtos podem ser desde pequenos lapsos de atenção até convulsões prolongadas e variam, em frequência, desde menos de um por ano até vários por dia (WORLD HEALTH ORGANIZATION, 2019).

A atividade cerebral é medida na forma do chamado eletroencefalograma (EEG), usando-se eletrodos posicionados na superfície do crânio. O EEG manifesta-se, dessa forma, como ondas ao longo do tempo, uma para cada eletrodo (também chamados de canais), representando as sinapses das comunicações entre as células cerebrais. Esse exame é utilizado nos principais testes para diagnóstico de epilepsia, além de outros distúrbios neurológicos (MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH,

2020).

Nesse contexto, os períodos de atividade cerebral são definidos como: ictal, correspondendo ao período de um surto; pré-ictal, que precede imediatamente um surto; pós-ictal, imediatamente a seguir de um surto e interictal, período distante de surtos (MULA; MONACO, 2011).

Os tratamentos para a epilepsia são baseados em medicamentos ou cirurgia. Eles são ineficazes para a maioria dos pacientes (GADHOUMI; LINA; GOTMAN, 2012). Dessa forma há grande interesse no desenvolvimento de sistemas para a previsão de surtos epiléticos para serem utilizados no dia a dia dos pacientes. Se um sistema desse tipo advertir um paciente sobre a possível chegada de um surto com uma boa antecedência e boa acurácia, esse paciente poderá se colocar em situação de segurança, como parar de dirigir um carro. Além disso, para os pacientes para os quais os medicamentos são eficazes, estes poderiam ser administrados apenas após a advertência feita pelo sistema, minimizando, assim, efeitos colaterais.

FUNDAMENTAÇÃO TEÓRICA

Na literatura, encontram-se trabalhos cujo objetivo é o desenvolvimento de sistemas de previsão de surtos epiléticos. Normalmente, eles buscam identificar se, num dado momento, o sinal EEG do paciente está no período interictal ou no período pré-ictal (GADHOUMI; LINA; GOTMAN, 2012; SONG; ZHANG, 2016; PARVEZ; PAUL, 2015; LIANG et al., 2016; ELGOHARY; ELDAWLATLY; KHALIL, 2016; TRUONG et al., 2018; BANDARABADI et al., 2015; TSIOURIS et al., 2018; SINGH; MALHOTRA, 2022). O usuário de um tal sistema, então, seria advertido quando ocorresse a entrada de seu sinal EEG no período pré-ictal.

Tsiouris et al. (2018) realizaram um trabalho muito promissor, com esse propósito, utilizando uma rede neural do tipo *Long Short Term Memory* (LSTM) (HOCHREITER; SCHMIDHUBER, 1997). Por mais que os resultados apresentados por esse grupo fossem promissores, a forma pela qual a separação dos conjuntos de dados de treino e de teste daquele sistema foi realizada não é a mais apropriada, já que vetores próximos a um mesmo surto foram utilizados nos dois conjuntos. Assim, pode-se dizer que a LSTM utilizou no treino algumas informações que deveriam estar presentes apenas no conjunto de teste. Isso foi verificado em trabalhos anteriores do grupo de pesquisa dos autores do presente trabalho. Verificou-se, também, que, dentre as características de EEG que o trabalho de Tsiouris et al. (2018) utilizou, as que trouxeram melhores resultados foram as relacionadas à correlação e a transformada Wavelet dos sinais.

A LSTM é uma rede neural recorrente concebida para lidar com sequências de dados (vetores) (HOCHREITER; SCHMIDHUBER, 1997; GERS; SCHMIDHUBER; CUMMINS, 2000). Em uma fase de treino, são apresentadas à LSTM várias sequências, informando-se a qual classe cada uma delas corresponde. Neste trabalho, as classes são: interictal e pré-ictal. Numa fase de teste de desempenho, novas sequências são apresentadas e a LSTM deverá classificá-las em função do que foi aprendido na fase de treino.

A transformada wavelet é uma transformada a qual, quando aplicada a uma função do tempo, identifica nesta função a ocorrência de um determinado padrão (forma de onda), em vários instantes e em várias escalas (ou níveis de detalhe) (MALLAT, 1989). O padrão a ser buscado na função pode ser escolhido pelo usuário, dentre várias possibilidades, cada uma destas sendo uma função que satisfaça a certos requisitos, dentre os quais o de poder formar uma base ortogonal de um espaço vetorial de funções. Na sua versão discreta, o resultado da aplicação da transformada wavelet é um conjunto de coeficientes, os quais revelam o quanto o padrão procurado está presente na função do tempo dada, em vários instantes e em várias escalas.

O coeficiente de correlação é uma métrica que busca aferir quão similar duas distribuições de variáveis são. Um coeficiente de correlação muito utilizado é o de Pearson (BENESTY et. al., 2010), definido pela Equação 1. Ele calcula a similaridade dos sinais ao verificar se a tendência (de subida ou descida) é semelhante nos dois. Neste trabalho, foi utilizada a correlação de Pearson indexada à defasagem, ou seja, é escolhido um valor k e calcula-se $2k + 1$ correlações, fazendo a defasagem temporal de um dos dois sinais de $-k$ até k . O valor da correlação é o máximo dentre esses valores calculados.

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (1)$$

onde,

x_i - i-ésima amostra da primeira variável

y_i - i-ésima amostra da segunda variável

\bar{x} - média da primeira variável

\bar{y} - média da segunda variável

r - correlação entre as duas variáveis

METODOLOGIA

Neste trabalho, decidiu-se usar metodologia semelhante à de Tsiouris et al (2018), mas separando-se de forma apropriada as sequências de treino das sequências de teste. Desta forma, ao invés de utilizar todas as crises para treino e teste, selecionamos as crises iniciais para a etapa de treino e apenas a última crise para a etapa de teste como recomendado por Amorim et. al (2022).

Os dados utilizados foram obtidos na base de dados aberta CHB MIT Scalp EEG Database, disponível no site PhysioNet (PHYSIONET, 2010), inicialmente descrito por Shoeb (2009). Esses exames foram obtidos no formato European Data Format (EDF) e sofreram diversas etapas de pré-processamento antes de serem utilizados pela LSTM.

A primeira etapa foi a de conversão desses arquivos, utilizando o software livre EDFBrowser para transformar os arquivos do formato EDF para o formato *Comma separated values* (CSV). Em seguida, utilizando programas já em mãos do grupo de pesquisa, criados em outros trabalhos, foram extraídas as janelas interictais e pré-ictais dos exames e dessas janelas foram extraídas as características objetivas de correlação, as correlações entre os sinais e o tempo de decorrelação de cada um dos sinais, e de Transformada de Wavelet, com ondas db4, usando-se, neste caso, os valores das médias dos módulos dos coeficientes wavelet em cada nível de detalhe.

Por fim, com tais vetores de características montados, foram montadas sequências contendo 15, 30, 45 ou 60 desses vetores de forma ordenada temporalmente. A parte final do pré-processamento foi a de junção, criando sequências contendo características tanto de correlação quanto de Transformada de Wavelet, isso foi feito simplesmente ao concatenar os vetores, desta forma, havendo 153 características de correlação e 1280 características de transformada Wavelet, o vetor conjunto possui 1433 características. Assim, ao final do pré-processamento, foram obtidas 12 sequências combinando o número de vetores por sequências com os tipos de vetores presentes.

Com as sequências de dados de entrada da rede neural preparados, iniciou-se a etapa final do processamento: o treino da LSTM. Para cada um dos conjuntos de dados, realizou-se o treino de duas LSTMs diferentes. A diferença entre elas é basicamente como a saída é tratada. No primeiro modelo, a saída é um único valor, sendo 0 para interictal e 1 para pré-ictal. Já no segundo, há duas saídas, uma específica para indicar se a classe é interictal e a segunda para indicar se é pré-ictal. A este modelo, devido ao tipo de codificação utilizado, dá-se o nome de *one-hot*.

Ambas as LSTMs possuem uma arquitetura contendo, como entrada, uma camada LSTM com 8 células, uma camada de 8 neurônios simples e a camada de saída. Foram treinadas utilizando o otimizador Adam (Kingma et al., 2014) com taxa de aprendizagem de 0,001, β_1 de 0,9, β_2 de 0,999 e decaimento nulo. A função de erro utilizada foi a entropia cruzada com foco (Lin et al., 2018), devido ao desbalanceamento das classes. (Havia mais sequências de período interictal do que de período pré-ictal.)

RESULTADOS E DISCUSSÃO

Realizou-se o treino e o teste das LSTM para os pacientes de 1 a 11, com exceção do 10, devido à sua falta de dados, porque todas as crises deste paciente são muito próximas, impossibilitando a definição de um intervalo pré-ictal para mais de uma crise.

Dessa forma, foram realizados 24 experimentos com cada paciente, resultando em um total de 240 experimentos. A Tabela 1 mostra a métrica F-1 calculada para os 5 primeiros pacientes, a Tabela 2 mostra a mesma métrica para os outros 5. As médias foram feitas agregando a quantidade de vetores por sequência. Então, cada valor nas tabelas é a média de 4 experimentos. Vale notar que esta métrica foi escolhida como principal, pois leva em conta o desbalanceamento dos dados, sendo mais justa do que uma análise de acurácia, por exemplo. A métrica F-1 foi calculada como

$$F1 = \frac{2VP}{2VP + FP + FN}$$

em que VP é o número de verdadeiros positivos, FP é o de falsos positivos e FN é o de falsos negativos, sendo consideradas positivas as sequências pré-ictais e negativas as interictais.

TABELA 1: Média das métricas F1 para os cinco primeiros pacientes

		Paciente				
One hot	Tipo	Paciente 1	Paciente 2	Paciente 3	Paciente 4	Paciente 5
Não	Correlação	35%	6%	18%	0%	9%
	Wavelets	17%	9%	69%	0%	17%
	Ambos	11%	29%	68%	0%	19%
Sim	Correlação	29%	19%	40%	0%	6%
	Wavelets	11%	39%	22%	0%	12%
	Ambos	11%	9%	68%	0%	19%

Fonte: Autor

TABELA 2: Média das métricas F1 para os pacientes 6 a 11 com exceção do paciente 10

		Paciente				
One hot	Tipo	Paciente 6	Paciente 7	Paciente 8	Paciente 9	Paciente 11
Não	Correlação	1%	8%	48%	4%	66%
	Wavelets	0%	4%	16%	2%	33%
	Ambos	5%	1%	12%	3%	66%
Sim	Correlação	4%	7%	56%	5%	2%
	Wavelets	3%	5%	4%	2%	0%
	Ambos	3%	2%	16%	3%	0%

Fonte: Autor

CONCLUSÕES

Como pode ser visto nas tabelas 1 e 2, com algumas poucas exceções, os resultados foram baixos, a maioria menor do que 10%, sendo apenas 6 deles acima de 50%. Além disso, seguindo o objetivo inicial do estudo de verificar se as junção das duas características traz um resultado melhor na predição, nesses 20 resultados houve 12 casos em que vetores com uma só característica trouxeram uma média de F-1 acima da junção dos vetores, 5 casos em que a junção trouxe resultados melhores e 3 empates, mostrando desta forma que, a predição com os vetores juntando características não é superior à predição com um único tipo.

Outra conclusão que é verificável a partir destes resultados é algo já visto antes: as sequências construídas com base em vetores de correlação se saem, na maioria das vezes, melhor do que aquelas montadas baseando-se em vetores de transformada Wavelet.

Como trabalho futuro, propõe-se a realização de experimentos combinando-se outras características extraídas dos sinais de EEG.

AGRADECIMENTOS

Os autores agradecem ao CNPq pelo apoio financeiro (Programa Institucional de Bolsas de Iniciação Científica e Tecnológica do Instituto Federal de Educação Ciência e Tecnologia de São Paulo PIBIFSP 2023)

REFERÊNCIAS

- Amorim, Luís O. L.; Sousa, Miguel A. de A de; Santos, Sara D. dos; Pires, Ricardo. **COMPARAÇÃO ENTRE MÉTODOS DE ESCOLHA DE JANELAS TEMPORAIS PARA TREINO DE REDE NEURAL DO TIPO LSTM EM SISTEMA PARA PREVISÃO DE SURTOS EPILÉPTICOS**. 12º CONCISTEC, outubro de 2022.
- BANDARABADI, M. et al. **On the proper selection of preictal period for seizure prediction**. *Epilepsy & Behavior*, Elsevier, v. 46, p. 158–166, 2015.
- BENESTY, J. et al. **Noise reduction in speech processing**. Dordrecht ; London ; New York: Springer, 2010.
- ELGOHARY, S.; ELDAWLATLY, S.; KHALIL, M. I. **Epileptic seizure prediction using zero-crossings analysis of EEG wavelet detail coefficients**. In: IEEE. 2016 IEEE conference on computational intelligence in bioinformatics and computational biology (CIBCB). [S.l.], 2016. p. 1–6.
- EPILEPSY FOUNDATION. **Epilepsy Foundation**. Disponível em: <<https://www.epilepsy.com/>>. Acesso em: 13 de set. 2023.
- GADHOUMI, K. et al. Seizure prediction for therapeutic devices: A review. **Journal of Neuroscience Methods**, v. 260, p. 270–282, fev. 2016.
- GADHOUMI, K.; LINA, J.-M.; GOTMAN, J. **Discriminating preictal and interictal states in patients with temporal lobe epilepsy using wavelet analysis of intracerebral EEG**. *Clinical neurophysiology*, Elsevier, v. 123, n. 10, p. 1906–1916, 2012.
- GERS, Felix A.; SCHMIDHUBER, Jürgen; CUMMINS, Fred. **Learning to forget: Continual prediction with LSTM**. *Neural computation*, v. 12, n. 10, p. 2451–2471, 2000.
- HOCHREITER, S.; SCHMIDHUBER, J. **Long Short-Term Memory**. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1 nov. 1997.
- Kingma Diederik P., Ba, Jimmy. Adam: **A Method for Stochastic Optimization**. arXiv preprint arXiv:1412.6980 (2014).
- LIANG, J. et al. **Predicting seizures from electroencephalography recordings: a knowledge transfer strategy**. In: IEEE. 2016 IEEE International Conference on Healthcare Informatics (ICHI). 2016. p. 184–191.
- Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). **Focal loss for dense object detection**. *Proceedings of the IEEE international conference on computer vision*. 2017.
- MALLAT, S. G. **A theory for multiresolution signal decomposition: the wavelet representation**. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Ieee, n. 7, p. 674–693, 1989.

MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH. **EEG (electroencephalogram)**. Disponível em: <<https://www.mayoclinic.org/tests-procedures/eeg/about/pac-20393875>>. Acesso em: 13 de set. 2023.

MULA, M.; MONACO, F. **Ictal and Peri-Ictal Psychopathology**. Behavioural Neurology, v. 24, n. 1, p. 21–25, 1 jan. 2011.

PARVEZ, M. Z.; PAUL, M. **Epileptic seizure prediction by exploiting spatiotemporal relationship of EEG signals using phase correlation**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, IEEE, v. 24, n. 1, p. 158–168, 2015.

PHYSIONET. **CHB-MIT Scalp EEG Database**. Disponível em: <<https://physionet.org/content/chbmit/1.0.0/>>. Acesso em 13 de set. 2023.

SHAFER, P., O.; SIRVEN, J., I. **About Epilepsy: The Basics**. Disponível em: <<https://www.epilepsy.com/learn/about-epilepsy-basics>>. Acesso em: 13 de set. 2023.

SHOEB, A. H. Application of machine learning to epileptic seizure onset detection and treatment. Tese (Doutorado) — Massachusetts Institute of Technology, 2009.

SINGH, K.; MALHOTRA, J. **Two-layer LSTM network-based prediction of epileptic seizures using EEG spectral features**. Complex & Intelligent Systems, Springer, p. 1–14, 2022.

SONG, Y.; ZHANG, J. **Discriminating preictal and interictal brain states in intracranial EEG by sample entropy and extreme learning machine**. Journal of neuroscience methods, Elsevier, v. 257, p. 45–54, 2016.

TRUONG, N. D. et al. **Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram**. Neural Networks, Elsevier, v. 105, p. 104–111, 2018.

TSIOURIS, K. M. et al. **A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals**. Computers in biology and medicine, Elsevier, v. 99, p. 24–37, 2018.

WORLD HEALTH ORGANIZATION. **Epilepsy**, 2019. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/epilepsy>>. Acesso em: 13 de set. 2023.