

REDES NEURAIS APLICADAS AO PROCESSAMENTO DE SINAIS DE EEG

Palavras-Chave: [REDES NEURAIS], [EEG], [PROCESSAMENTO DE SINAIS]

Autores/as:

GIULIA STECK [UNICAMP]

Prof. ROMIS ATTUX (orientador/a) [UNICAMP]

INTRODUÇÃO:

O intuito deste projeto de pesquisa é investigar o uso de redes neurais *shallow* e profundas para classificação de sinais coletados através de eletroencefalografia (EEG). Esse exame é realizado para registrar a atividade elétrica cerebral de um paciente e, posteriormente, a partir da análise dos sinais captados, diagnosticar e identificar a ocorrência de distúrbios neurológicos. O EEG, entre outras finalidades, é utilizado para diagnosticar epilepsia e identificar a ocorrência de crises epiléticas (CE). Tendo em vista a relevância desse tema, optamos por concentrar nossa análise em sinais cerebrais coletados em indivíduos epiléticos.

A epilepsia é uma doença neurológica, diagnosticada a partir da recorrência de crises epiléticas, sem a identificação de outros fatores causais, como AVC ou febre. Essas crises são resultado de atividades eletrônicas cerebrais anormais, decorrentes de descargas elétricas excessivas advindas de neurônios localizados no córtex pré-frontal [da Silva et al., 2013].

As crises epiléticas são de difícil previsão e podem ocorrer em situações inesperadas, representando, portanto, um grande risco para integridade física e mental de pacientes epiléticos. Portanto, dada essa realidade, é essencial o desenvolvimento de tecnologias que possibilitem um diagnóstico rápido da doença e do início de crises epiléticas, de forma a possibilitar uma melhora na qualidade e vida desses indivíduos.

Atualmente, esse diagnóstico é realizado manualmente por um neurologista, a partir da análise dos sinais captados pelo EEG. Entretanto, esse procedimento pode durar mais de horas, possibilitando que métodos mais rápidos e menos trabalhosos possam ser explorados de forma a facilitar esse diagnóstico [Shoeb e Guttag, 2004].

Dadas as considerações acima, um dos objetivos desse projeto é treinar diferentes algoritmos de classificação e regressão capazes de identificar a ocorrência ou não de surtos epiléticos ao longo de uma gravação EEG e, portanto, acelerar o

processo de diagnóstico e identificação de crises epiléticas.

Para isso, é necessário um grande volume de dados já classificados – indicando ocorrência ou não de CEs – para treinar os modelos a serem implementados. Até o momento, esses dados já foram extraídos e devidamente pré-processados, além das características mais relevantes dos sinais de cada gravação já terem sido extraídas para, posteriormente, alimentarem os modelos implementados.

METODOLOGIA:

Inicialmente, foi necessário estruturar uma base sólida acerca do funcionamento de algoritmos de classificação e as mecânicas por trás desses classificados. Portanto, foram estudados os materiais organizados para a matéria IA048 – Aprendizado de Máquina [Bocato e Attux, 2020], que abrangeram elementos básicos de probabilidade e teoria de informação, classificação, regressão e redes neurais. Além disso, estudos no escopo de análise e processamento de sinais também foram necessários.

Após a parte teórica da pesquisa estar bem consolidada, foi possível avançar para a implementação. Essa etapa pode ser dividida em 5 etapas: entendimento e extração das gravações de EEGs do banco de dados utilizado, pré-processamento do sinal, *feature extraction*, implementação dos classificadores e aplicação de métricas de análise de resultados.

i. Banco de dados

Nessa etapa, foi necessário, primeiramente, selecionar um banco de dados

que contivesse um volume grande o suficiente de gravações EEG de pacientes epiléticos, de forma que elas pudessem ser divididas em dois grupos: *training set* e *test set*. Enquanto aquele é utilizado para alimentar o modelo classificatório implementado, para que ele possa aprender padrões e ajustar pesos, este é utilizado para testar o modelo e avaliar o quão preciso ele é.

Ademais, fazia-se necessário um banco de dados que possuísse a classificação dos dados, ou seja, indicando em quais momentos as CEs estavam ocorrendo – ou não – durante as gravações.

A partir dessas considerações, o banco escolhido foi o TUH EEG Epilepsy Corpus, da Temple University Hospital (TUH) [Veloso et al., 2017], derivado da base de dados TUH EEG Corpus – o maior banco de dados público de EEG [Obeid e Picone, 2016]. O TUH EEG Epilepsy Corpus apresenta sinais coletados tanto de pacientes epiléticos como não epiléticos, somando 237 pacientes, com um total de 561 sessões realizadas.

Após escolha do banco de dados, é necessário compreender como esses dados estão armazenados e classificados. A base estudada coleta, em grande maioria das sessões presentes, os sinais cerebrais posicionando os eletrodos ao longo da cabeça do paciente de acordo com o sistema 10-20.

No caso, alguns dados podem apresentar uma quantidade maior ou menor de canais do que a convenção 10-20. No caso de dados que apresentam mais canais, é possível selecionar apenas os 21 que estão de acordo com a convenção e, em caso de

menos canais, é necessário descartar o sinal coletado, uma vez que não é possível padronizar os dados.

Além da questão dos canais, é necessário também recuperar a taxa de amostragem dos sinais coletados. Dessa forma, é possível associar as amplitudes do sinal ao longo da gravação nos 21 canais de interesse à vetores de amostras.

Sendo assim, os dados de extensão 'edf' apresentados no banco são extraídos a partir da utilização da biblioteca MNE em Python e são colocados em um DataFrame, da biblioteca Pandas, para permitir uma boa visualização e compreensão dos dados.

Por fim, o banco também conta com arquivos de extensão 'tse', que indica em quais intervalos de tempo o paciente da sessão gravada apresenta ou não a ocorrência de crises epilépticas. Portanto, como já temos o tempo associado às amplitudes, basta associar a classificação correspondente à cada intervalo no DataFrame.

ii. Pré-processamento

Após armazenamento correto dos dados no DataFrame, é possível avançar para a etapa de pré-processamento dos dados. Nela, é necessário filtrar os sinais obtidos, de forma a filtrar a tensão DC dos sinais e ainda garantir que frequências relevantes para o estudo se mantenham preservadas. De acordo com a literatura estudada, o filtro FIR (*Finite Impulse Response*), apesar de implicar em um alto custo computacional, quando projetados corretamente, não causam distorções de fase nos sinais analisados. [Z. Shang, Y. Zhao d Y. Lian,. 2018] Nesse

estudo, foi utilizado um filtro passa-baixa FIR com frequência de corte de 40Hz e faixa de transição de 10Hz. Nas Figuras 2 e 3, é possível observar o sinal no domínio do tempo, respectivamente, antes da filtragem e após ela.




Figura 2. Sinal EEG não filtrado




Figura 3. Sinal EEG após ser filtrado por um FIR passa-baixas em 40Hz

Por fim, o sinal é extraído em pequenas janelas de tempo de 500ms, valor esse que foi escolhido arbitrariamente. Portanto, cada janela contém 125 amostras de sinais, dada a frequência de amostragem de 250Hz. Segundo a literatura, sabe-se que, quanto maior a janela, maior a resolução no tempo, porém menor a fidedignidade a picos e vales do sinal. [Y. Qi et. al., 2003]

iii. Extração de Características

Após o pré-processamento, deseja-se extrair as características dos sinais. No caso, extração de características (em inglês, *feature extraction*) se refere ao processo de analisar os dados e extrair características numéricas importantes dele. Dessa forma, os modelos podem tratar os dados mais facilmente, uma vez que redundâncias são eliminadas e o volume de dados é reduzido.

Nessa etapa, o método de extração escolhido foi a Transformada Discreta de Wavelet (DWT). Na DWT, o sinal é decomposto em coeficientes de detalhe (cD) e aproximação (cA), sendo que aquele é resultado de um filtro passa-alta e este, de um filtro passa-baixa. Ademais, de cada coeficiente de aproximação, é possível decompor mais um cA e cD. Ao se definir o nível de decomposição de uma DWT, está se indicando quantas vezes se deseja decompor um cA já obtido, para obter coeficientes referentes a novas faixas de frequência do sinal. [Hezam et al., 2021]

Nesta pesquisa, o nível de decomposição escolhido foi 5 e somente os coeficientes de decomposição são de interesse, uma vez que são referentes à faixas de frequências relevantes no escopo de análise de sinais cerebrais. Essas faixas são denominadas Delta (0.5-4Hz), Theta (4-8Hz), Alpha (8-13Hz) e Beta (13-30Hz). Sendo assim, ao aplicarmos uma DWT de nível 5 no nosso sinal, previamente filtrado com uma passa-baixa de 40Hz, temos frequências variando entre 1.25Hz e 40Hz, que se aproximam dos intervalos mencionados.

Por fim, após os coeficientes de detalhamento serem extraídos para os 21 canais, é necessário computar as características baseadas nesses cDs. No caso, os modos iniciais escolhidos nesse trabalho são o cálculo da média dos coeficientes para cada nível de cada canal e o desvio padrão. [Hezam et al.] Sendo assim, ao fim dos dois métodos, são obtidos 110 características – 5 por canal – e uma marcação da classificação.

iv. Classificadores

Serão utilizados dois métodos de classificação: *k-nearest neighbors* (KNN) e redes neurais artificiais.

RESULTADOS E DISCUSSÃO:

Até o momento, ainda não foi obtido nenhum resultado final da pesquisa, uma vez que ela se encontra na etapa de implementação dos classificadores. Entretanto, pretende-se utilizar duas métricas de análise de desempenho dos algoritmos: acurácia e matriz de confusão. O primeiro é uma métrica mais simples, que apenas divide o número de acertos pelo número total de predições realizadas. O segundo, por sua vez, é a matriz de confusão, que possui falsos e verdadeiros positivos e negativos, e indica quantas vezes o modelo atingiu cada um desses casos. Essa abordagem avaliativa é interessante uma vez que permite um maior entendimento do modelo.

A partir dessas métricas avaliativas, é possível definir se o modelo atingiu resultados satisfatórios e ajustar parâmetros como o método utilizado e a forma como as

características dos sinais estão sendo extraídas.

CONCLUSÕES:

Neste trabalho, apresentamos, em linhas gerais, o projeto de pesquisa que ora desenvolvemos. Até a entrega do relatório final, realizaremos as simulações e análises que formarão a base experimental de nosso esforço.

BIBLIOGRAFIA

[da Silva et al., 2013] DA SILVA, C.R.A.; CARDOSO, I.S.Z.O.; MACHADO, N.R.

Considerações sobre epilepsia. Boletim Científico de Pediatria, vol. 2, n. 3, 2013.

[Gemein et al., 2020] GEMEIN, L.A.W. et al.

Machine-learning-based diagnostics of EEG pathology. NeuroImage, vol. 220, p. 117021, 2020.

[Hezam et al., 2021] HEZAM, A. et al.

Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree.

Biomedical Signal Processing and Control, vol. 70 p. 102957, 2021.

[Obeid e Picone, 2016] OBEID, I; PICONE, J.

The Temple University Hospital EEG Data Corpus. Frontiers in Neuroscience, Section Neural Technology, vol. 10, p. 196, 2016.

[Shoeb e Guttag, 2004] SHOEB, A.;

GUTTAG, J. **Application of Machine Learning To Epileptic Seizure Detection.**

27th International Conference on Machine Learning (ICML-10), 2010.

[Z. Shang, Y. Zhao and Y. Lian,. 2018]

SHANG, Z.; ZHAO, Y.; LIAN, Y. **Low power FIR filter bank for EEG processing using frequency-response masking technique.**

2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), IEEE, 2018.

[Y. Qi et. al., 2003] QI, Yingwei et al. **Sliding-**

window technique for the analysis of cerebral evoked potentials. Beijing da xue xue bao. Yi xue ban= Journal of Peking University. Health Sciences, vol. 35, n. 3, p. 231-235, 2003.