



Estudo de Métodos de Aprendizado de Máquina Profundo e de Ajuste de Domínio no Tratamento de Dados Eletroencefalográficos

Palavras-Chave: Aprendizado de Máquina; Redes Neurais Convolucionais; Interface Cérebro-Computador.

Autores(as):

Henrique Marques de Martim, UNICAMP

Prof. Dr. Denis Gustavo Fantinato (orientador), UNICAMP

Introdução:

O presente trabalho de pesquisa foca no estudo e implementação de Redes Neurais Artificiais (RNAs), com ênfase na EEGNet, para o processamento de sinais de eletroencefalografia (EEG) no desenvolvimento de Interfaces Cérebro-Computador (BCI). Dada a presença de intenso ruído, artefatos e alta variabilidade observada nos sinais de EEG, o uso de redes neurais profundas mostrou-se bastante efetivo para o tratamento desses sinais. Detalha-se as revisões bibliográficas, os desenvolvimentos práticos e os resultados obtidos, com o objetivo de buscar um entendimento aprofundado sobre as RNAs e os sinais de EEG.

Atividades Realizadas:

Como previsto no cronograma original, foram realizadas as revisões bibliográficas das etapas 1 e 2, que se referem ao estudo teórico das redes MLP e CNN; método de *backpropagation* e validação cruzada; e o estudo das etapas do sistema BCI. Para esse estudo, foram utilizados como referência os livros “*Pattern Recognition and Machine Learning*” [1]; “*Neural Networks and Learning Machines*” [2]; “*Deep Learning*” [3]; “*AlexNet*” [4]; “*ResNet*” [5]; “*Contribuições ao Desenvolvimento de Interfaces Cérebro-Computador Baseadas em Potenciais Evocados Visualmente em Regime Estacionário*” [6].

Adicionalmente, foram realizados diversos exercícios de implementação de redes neurais artificiais (RNAs) em python, conforme previsto na etapa 3. Isto teve como principal objetivo o aprendizado prático daquilo que foi visto nas revisões bibliográficas, seja os diversos tipos de redes implementadas ou as técnicas de treinamento, conforme ilustrado na Fig. 1.

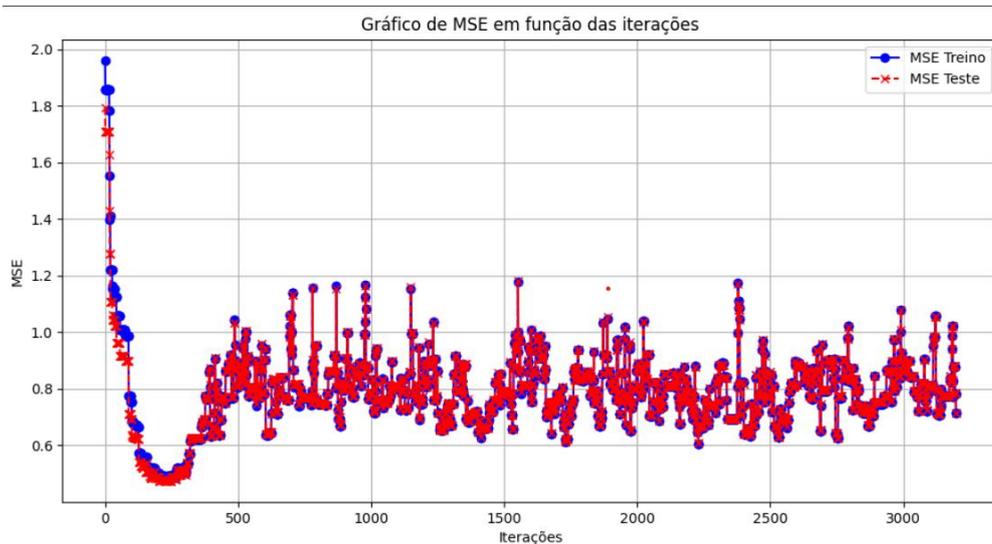


Fig. 1: Gráfico da função de erro quadrado da implementação por iteração de um algoritmo de perceptron

Além disso, foi realizado o aprendizado da EEGNet, que é uma rede profunda voltada para o processamento de sinais de EEG. O estudo teórico foi feito utilizando o artigo “*EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces*” [7].

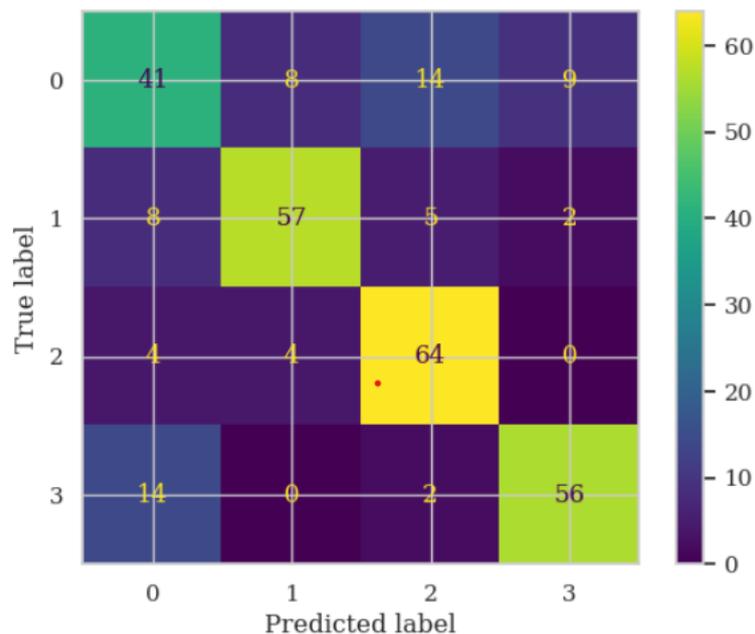


Fig. 2: Matriz de confusão com os dados de teste de um banco de dados de sinais de EEG, utilizando EEGNet para o treinamento de um único indivíduo.

Foi feita também a implementação da EEGNet utilizando “SingleTask Learning” com dados de 9 diferentes pessoas do dataset BCI Competition IV, dataset 2a [8], onde os sinais de EEG de diferentes indivíduos foram utilizados para treinar uma rede capaz de classificar os sinais de um único indivíduo.

A técnica de “Single Task Learning” se refere ao treinamento padrão de uma rede neural, em que os dados de todos os indivíduos são tratados como uma só tarefa e, portanto, são utilizados para treinamento, e a pessoa a ser testada possui apenas uma pequena quantidade de dados disponibilizados para o treinamento e o resto de seus dados é utilizado para os testes.

Resultados e Discussões:

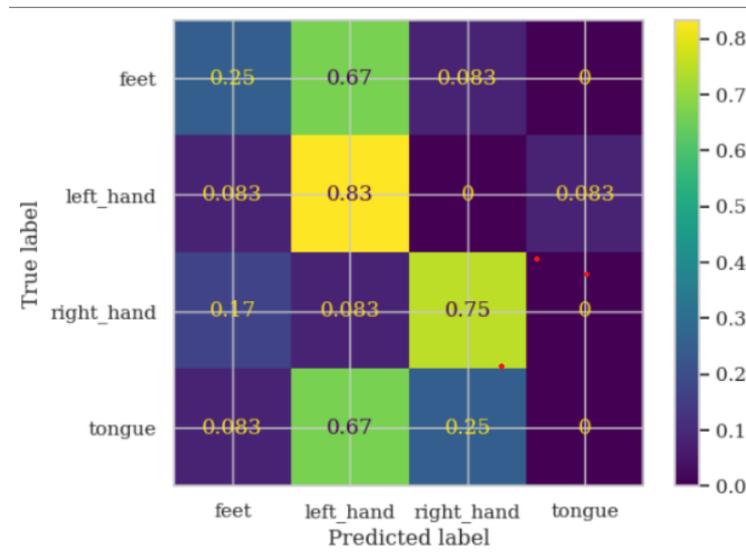


Fig. 3: Matriz de confusão dos dados do MOABB, utilizando “SingleTask Learning” e parâmetros F1: 8 e D:2.

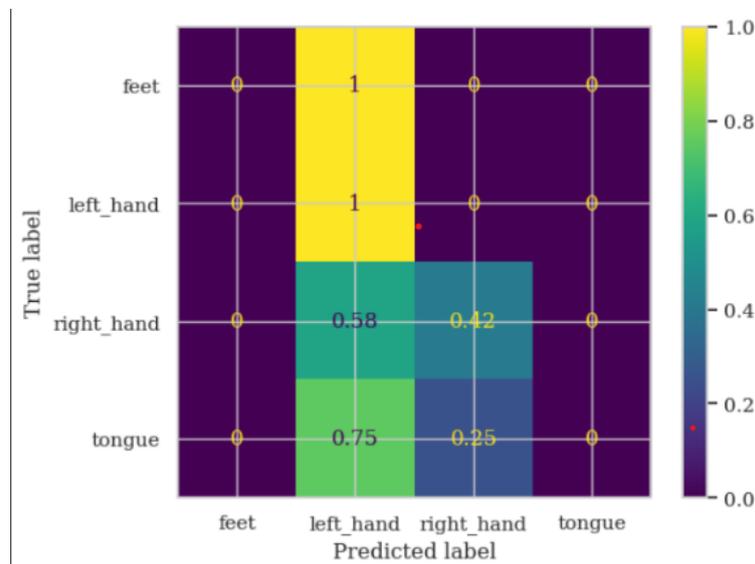


Fig. 4: Matriz de confusão dos dados do MOABB, utilizando “SingleTask Learning” e parâmetros F1: 4 e D:1.

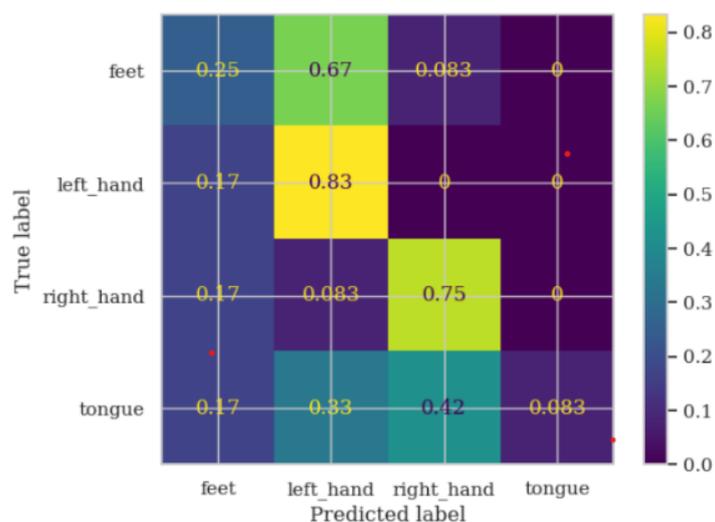


Fig. 5: Matriz de confusão dos dados do MOABB, utilizando “SingleTask Learning” e parâmetros F1: 16 e D:4.

Tabela 1: Acurácia para os diferentes parâmetros testados

Parâmetros	Acurácia
F1:4 D:1	30.73%
F1:8 D:2	43.06%
F1:16 D:4	46.18%

Com os resultados das figuras 3-5 e da tabela 1, podemos ver que o modelo teve um melhor desempenho com valores 16 e 4, tendo uma pequena melhora em relação aos parâmetros de valor 8 e 2 e com uma melhora significativa quando comparado aos valores 4 e 1. Analisando os dados das matrizes de confusão, podemos verificar que os dois parâmetros com maiores acurácias apresentaram acertos significativos na predição de movimentos de mão, tanto direita quanto esquerda, mas não conseguiram prever bem os movimentos de pés e língua. Já nos parâmetros F1: 4 e D: 1, não houve acertos nos movimentos de pés e língua, as previsões do movimento de mão direita foram incertas e houve um acerto de 100% no movimento de mão esquerda, que se deve muito pelo fato do modelo não ter aprendido a diferenciar os movimentos muito bem e por isso previu a mão esquerda como a maioria dos sinais de movimento, o que pode ser observado pela taxa de previsão deste movimento ser quase maior que 60% em todos os sinais.

Como pode ser observado, os resultados não foram muito positivos, com uma taxa de acerto de apenas 46 por cento no melhor modelo. Por isso, fica evidente a necessidade de técnicas diferentes para o treinamento dos dados de EEG de diferentes indivíduos futuramente, como por exemplo o “MultiTask Learning”. Técnica esta que trata cada indivíduo como uma tarefa diferente a ser aprendida, capturando melhor as diferentes características entre eles ao invés de criar uma generalização insuficiente como no “SingleTask Learning”.

Conclusão:

Este trabalho envolveu o estudo e implementação de RNAs, com foco na EEGNet, para análise de EEG em BCI. Os experimentos práticos, utilizando "SingleTask Learning", demonstraram que, embora o modelo tenha alcançado uma acurácia de 46.18%, houve limitações notáveis na classificação de movimentos específicos (pés e língua). Esses resultados evidenciam a necessidade de explorar metodologias de treinamento mais avançadas, como o "MultiTask Learning", para melhor capturar as características entre indivíduos e otimizar a performance em futuras etapas.

Referências:

- [1] BISHOP, C. M. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [2] HAYKIN, S. *Neural Networks and Learning Machines*. 3. ed. Pearson, 2009.
- [3] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016.
- [4] ALOM, Md Zahangir; TAHA, Tarek M.; YAKOPCIC, Christopher; WESTBERG, Stefan; PAHEDING, Sidike; NASRIN, Mst Shamima; VAN ESSEN, Brian C.; AWWAL, Abdul A. S.; ASARI, Vijayan K. *The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches*. arXiv preprint arXiv:1803.01164, 2018. Disponível em: <https://arxiv.org/pdf/1803.01164>.
- [5] LI, Sihan; JIAO, Jiantao; HAN, Yanjun; WEISSMAN, Tsachy. *Demystifying ResNet*. arXiv preprint arXiv:1611.01186, 2017. Disponível em: <https://arxiv.org/pdf/1611.01186>.
- [6] LEITE, S. N. C. Contribuições ao Desenvolvimento de Interfaces Cérebro-Computador Baseadas em Potenciais Evocados Visualmente em Regime Estacionário. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Espírito Santo, 2017.
- [7] LAWHERN, V. J.; SOLON, A. J.; WAYTOWICH, N. R.; GORDON, S. M.; HUNG, C. P.; LANCE, B. J. EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces. *arXiv preprint arXiv:1611.08024*, 2016. Disponível em: <https://arxiv.org/abs/1611.08024>.
- [8] BCI Competition IV, dataset 2a. Disponível em: <https://bbci.de/competition/iv/download/>.