

Aprendizado Multiusuário para o Treinamento de Classificadores em Interfaces Cérebro-Computador

Daniel Neri de Jesus
d216444@dac.unicamp.br

Gabriel da Costa
g216941@dac.unicamp.br

Henrique Marques de Martim
h248333@dac.unicamp.br

Denis Gustavo Fantinato
denisf@unicamp.br

Departamento de Engenharia de Computação e Automação (DCA)
Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)




Figura 1: Metodologia de aprendizado de tarefa única e aprendizado de múltiplas tarefas.

Resumo

A alta variabilidade nos sinais de EEG entre usuários distintos é um desafio central para a robustez de Interfaces Cérebro-Computador (BCI, do inglês Brain-Computer Interfaces) baseadas em Imagética Motora (IM). Embora redes neurais profundas como a EEG-Net tenham se mostrado eficazes, modelos treinados de forma convencional frequentemente falham em generalizar para novos indivíduos. Para enfrentar este problema, este trabalho propõe uma adaptação da abordagem de Multitask Learning (MTL): ao invés de utilizar múltiplos conjuntos de dados ou paradigmas, empregamos um único conjunto (BCI Competition IV - 2a) e tratamos cada usuário como uma tarefa distinta. A arquitetura proposta consiste de um encoder compartilhado, que aprende a projetar os dados de EEG em um espaço latente comum, seguido por cabeças de classificação dedicadas e especializadas para cada usuário. O objetivo é que o encoder capture características universais da IM, enquanto as cabeças individuais

modelam as especificidades de cada usuário. Os resultados demonstram que esta estratégia mitiga de forma eficaz os efeitos da variabilidade entre usuários, elevando o desempenho de classificação e oferecendo um caminho promissor para o desenvolvimento de sistemas BCI mais generalizáveis.

Palavras-Chave — Interfaces Cérebro-Computador, Imagética Motora, Multitask Learning.

1. Introdução

As Interfaces Cérebro-Computador (BCI, do inglês Brain-Computer Interface) baseadas em eletroencefalografia (EEG) emergiram como uma tecnologia promissora para restaurar a comunicação e o controle em indivíduos com graves limitações motoras. No entanto, a viabilidade de sistemas BCI robustos e de uso geral é constantemente desafiada pela alta variabilidade intrínseca aos sinais de EEG [1]. Essa variabilidade manifesta-se não apenas entre sessões experimentais

de um mesmo usuário, mas, de forma mais acentuada, entre diferentes indivíduos. Diferenças anatômicas, estados cognitivos, níveis de concentração e a própria técnica de colocação de eletrodos contribuem para que os dados cerebrais de diferentes usuários sejam altamente heterogêneos, dificultando a criação de classificadores universais [1].

Dentro do paradigma de Imagética Motora (IM), onde os usuários imaginam movimentos sem executá-los fisicamente, as Redes Neurais Profundas (DNNs, do inglês *Deep Neural Networks*) têm se mostrado ferramentas eficazes para a classificação de padrões complexos de EEG [2, 3]. Arquiteturas como a EEGNet [4] foram projetadas especificamente para extrair características espaciais e espectrais relevantes desses sinais. Não obstante, quando um modelo treinado em um conjunto de usuários é aplicado a um novo indivíduo, seu desempenho frequentemente é reduzido devido à mencionada variabilidade interusuário. Este fenômeno, conhecido como falta de generalização, representa um dos principais obstáculos para a adoção em larga escala de sistemas BCI [1, 5].

Para mitigar esse problema, diversas estratégias de processamento de sinais e de aprendizado de máquina têm sido exploradas. Técnicas como a projeção dos dados em um espaço de covariância na variedade Riemanniana [2, 5] e alinhamento de dados [1] visam reduzir a alta variabilidade entre sessões e sujeitos, criando um espaço de características mais homogêneo. Paralelamente, em cenários que envolvem múltiplos conjuntos de dados ou diferentes paradigmas de BCI, a abordagem de *Multitask Learning* (MTL) tem ganhado destaque [6, 7, 8]. Nesta configuração, um *encoder* compartilhado aprende a mapear os dados de entrada para um espaço latente comum, presumivelmente de menor variabilidade, enquanto múltiplas cabeças de classificação, especializadas para cada tarefa distinta, realizam a classificação final.

Com base na estratégia MTL, este trabalho propõe uma adaptação dessa abordagem para o desafio da variabilidade interusuário dentro de um *único* conjunto de dados. Em vez de empregar tarefas ou paradigmas diferentes, utilizamos o conjunto de dados da BCI Competition IV - 2a [2], tratando cada usuário como uma “tarefa” distinta. O cerne de nossa proposta reside na substituição das cabeças de classificação para tarefas distintas por cabeças de classificação especializadas para usuários distintos. Dessa forma, investigamos se um *encoder* comum pode aprender uma representação latente robusta que capture os padrões universais da

imagética motora, enquanto cabeças específicas para cada usuário se especializam em modelar as especialidades individuais, potencialmente superando as limitações de generalização dos modelos tradicionais.

2. Métodos

A maioria dos sistemas BCI emprega predominantemente o aprendizado de uma única tarefa (STL, do inglês *Single Task Learning*). No STL, um modelo é treinado de forma independente para cada tarefa. Em contraste, o MTL envolve treinar um modelo de aprendizado de máquina para otimizar simultaneamente múltiplos objetivos ou tarefas, conforme ilustrado na Figura 1. A suposição básica ao usar o MTL é que o desempenho do modelo aumentará ao compartilhar informações de várias tarefas correlacionadas [6].

Técnicas de MTL estão sendo usadas em vários domínios, como Processamento de Linguagem Natural, onde são utilizadas para treinar Modelos de Linguagem a fim de gerar simultaneamente múltiplas previsões de processamento com base em uma sentença de entrada [7], em Visão Computacional, para análise de falhas em materiais [8] e, adicionalmente, em aplicações de Séries Temporais, MTL para resolver problemas de reconhecimento de fala multilíngue [9].

Nesse âmbito, redes neurais profundas são amplamente usadas. No contexto de sistemas BCI, destacamos a rede EEGNet, que recebeu grande atenção na área de análise de dados de EEG [4, 10], se tornando um dos elementos centrais quando se considera os contextos para múltiplos conjuntos de dados. Na competição recente *The Benchmarks for EEG Transfer Learning* (BEETL), o desafio era treinar um modelo a partir de quatro conjuntos de dados distintos de imagética motora, que tinham sobreposição de algumas (mas não todas) classes. No pódio, as propostas baseadas na EEGNet ganharam o primeiro e o segundo lugares [11], mostrando-se como promissoras ferramentas para o uso de MTL [12].

2.1. EEGNet para Múltiplos Usuários

A Figura 2 ilustra a ideia geral da rede EEGNet usada na competição BEETL, em que há uma parte comum da rede com camadas convolucionais, o *encoder*, que é responsável por gerar um espaço latente com menor variância. Em seguida, os dados são encaminhados a uma cabeça de classificação específica para cada conjunto de dados, buscando-se focar nas características específicas deste.




Figura 2: EEGNet no contexto Multi-tarefas. Adaptado de [11].

Neste trabalho, buscamos, ao invés de vários conjuntos de dados, utilizar apenas um conjunto de dados e considerar uma cabeça de classificação por usuário. Ou seja, ao invés de uma abordagem “multitarefa”, seguiremos uma estratégia “multiusuário”.

2.2. Conjunto de Dados

O conjunto de dados utilizado neste estudo é o BCI Competition IV 2a, um *benchmark* amplamente reconhecido na área de Interfaces Cérebro-Computador [2, 5]. Este dataset é composto por sinais de EEG de 9 indivíduos, coletados em duas sessões realizadas em dias diferentes. O paradigma experimental envolvia quatro classes distintas de imagética motora: imaginação do movimento da mão esquerda, mão direita, ambos os pés e língua. Cada sessão contém 6 *runs*, totalizando 288 tentativas por sessão (48 por *run*, com 12 exemplares para cada classe). Os registros foram realizados utilizando 22 eletrodos de EEG posicionados no escalpo, com os sinais sendo amostrados a 250 Hz e filtrados entre 0,5 Hz e 100 Hz. Os dados utilizados tiveram duração de 4 segundos.

2.3. Leave-One-Subject-Out

O método “Leave-One-Subject-Out” (LOSO) foi utilizado como protocolo experimental para avaliar a capacidade de generalização do modelo proposto. Esta estratégia consiste em utilizar iterativamente os dados de todos os indivíduos, exceto um, para treinamento, enquanto o usuário excluído é reservado exclusivamente para teste – que chamaremos de usuário alvo. Este processo é repetido de forma exaustiva, rotacionando cada um dos nove sujeitos do conjunto BCI Competition IV 2a na função de conjunto de teste único. Dessa forma, o LOSO simula um cenário de aplicação real, onde o sistema encontra um novo usuário cujos dados

não foram vistos durante o treinamento. No caso STL, 20% dos dados de treinamento do usuário alvo foram utilizados para o treino do modelo – além dos dados dos demais indivíduos. Para o caso MTL, esses mesmos 20% de dados do usuário alvo foram usados para treinar o *encoder* e a cabeça de classificação associada a ele. A métrica de desempenho final é calculada pela média dos resultados de todas as iterações, fornecendo assim uma estimativa robusta e não enviesada da eficácia do modelo em generalizar para indivíduos completamente novos, que é o principal desafio enfrentado pelos sistemas BCI baseados em EEG.

3. Impactos da Pesquisa

O principal impacto desta pesquisa se dá no avanço significativo em direção a sistemas BCI robustos que não dependem de uma etapa de calibração exaustiva. Ao validar uma arquitetura que aprende representações neurais generalizáveis e, simultaneamente, adapta-se a usuários distintos, este trabalho mitiga um dos maiores obstáculos para a adoção clínica e comercial de BCIs baseadas em EEG: a custosa e demorada etapa de calibração para cada novo usuário. A estratégia proposta tem o potencial de reduzir drasticamente o tempo de configuração do sistema, tornando a tecnologia mais prática para aplicações de reabilitação motora, controle de dispositivos de assistência e comunicação para indivíduos com graves incapacidades. Além disso, o paradigma MTL com cabeças por usuário estabelece um novo *framework* conceitual para o desenvolvimento de algoritmos, que pode ser estendido a outros paradigmas de BCI e conjuntos de dados, influenciando futuras linhas investigativas no sentido de criar modelos mais adaptativos e inteligentes que atuem de forma mais orgânica com a variabilidade biológica humana.

4. Resultados e Discussão

Seguindo a abordagem LOSO, o método MTL proposto foi comparado, até o momento, com o paradigma tradicional STL, em que uma rede EEGNet (com uma única cabeça de classificação) foi utilizada.

As Figuras 3 e 4 ilustram o desempenho obtido para os casos STL e MTL, respectivamente. É possível observar que a abordagem MTL proposta apresenta um ganho para todos os usuários, elevando a média de 50,42% (STL) para 60,34% (MTL). Entretanto, consegue oferecer maior ganho de acurácia para alguns usuários específicos, como é o caso, por exemplo, dos indivíduos 1 e 6. Vale ressaltar que indivíduos que apresen-

taram pior desempenho na abordagem STL também beneficiaram-se de maneira significativa no MTL.




Figura 3: Gráfico Acurácia por indivíduo - STL.




Figura 4: Gráfico Acurácia por indivíduo - MTL

5. Conclusão

Propomos neste trabalho uma abordagem MTL adaptada para enfrentar o desafio da variabilidade entre usuários em sistemas BCI baseados em imagética motora. Os resultados experimentais, que utilizaram a validação Leave-One-Subject-Out no conjunto BCI Competition IV 2a, confirmaram a superioridade do método proposto. A arquitetura EEGNet para MTL, com um *encoder* compartilhado e cabeças de classificação especializadas por usuário, não apenas elevou a acurácia média de classificação de 50,42% para 60,34%, mas também se mostrou particularmente benéfica para indivíduos com baixo desempenho no modelo tradicional de aprendizado único (STL). Este ganho generalizado, especialmente para os usuários mais desafiadores, valida a premissa de que o modelo é capaz de aprender uma representação latente robusta enquanto captura

particularidades de cada usuário. Portanto, a estratégia MTL por usuário surge como uma solução promissora para a criação de sistemas BCI mais generalizáveis e com menor dependência de calibração, pavimentando o caminho para interfaces mais práticas e acessíveis.

Agradecimentos

Processos nº 2023/00640-1, 2025/06583-5, 2025/07333-2, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

Referências

- [1] R. Abiri, S. Borhani, E. W. Sellers, Y. Jiang, and X. Zhao, “A Comprehensive Review of EEG-based Brain-Computer Interface Paradigms,” *Journal of neural engineering*, vol. 16, no. 1, p. 011001, 2019.
- [2] A. H. Matias, L. H. Santos, and D. G. Fantinato, “Motor Imagery Classification with Deep Learning and Riemannian Geometry,” in *10th BRAINN Congress*, 2024.
- [3] P. O. de Paula, T. B. da Silva Costa, R. R. de Faisol Attux, and D. G. Fantinato, “Classification of Image Encoded SSVEP-based EEG Signals Using Convolutional Neural Networks,” *Expert Systems with Applications*, vol. 214, p. 119096, 2023.
- [4] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, “EEGNet: A Compact Convolutional Neural Network for EEG-based Brain-Computer Interfaces,” *Journal of neural engineering*, vol. 15, no. 5, p. 056013, 2018.
- [5] L. H. Santos, P. L. C. Rodrigues, and D. G. Fantinato, “Cross-Dataset Motor Imagery Classification with Deep Learning and Riemannian Geometry,” in *9th BRAINN Congress*, 2023.
- [6] O. Sener and V. Koltun, “Multi-Task Learning as Multi-Objective Optimization,” *Advances in neural information processing systems*, vol. 31, 2018.
- [7] R. Collobert and J. Weston, “A Unified Architecture for Natural Language Processing: Deep Neural Networks with Multitask Learning,” in *Proceedings of the 25th international conference on Machine learning*, 2008, pp. 160–167.

- [8] X. Gibert, V. M. Patel, and R. Chellappa, “Deep Multitask Learning for Railway Track Inspection,” *IEEE transactions on intelligent transportation systems*, vol. 18, no. 1, pp. 153–164, 2016.
- [9] L. Deng, G. Hinton, and B. Kingsbury, “New Types of Deep Neural Network Learning for Speech Recognition and Related Applications: An Overview,” in *2013 IEEE international conference on acoustics, speech and signal processing*. IEEE, 2013, pp. 8599–8603.
- [10] Z. Wan, R. Yang, M. Huang, N. Zeng, and X. Liu, “A Review on Transfer Learning in EEG Signal Analysis,” *Neurocomputing*, vol. 421, pp. 1–14, 2021.
- [11] X. Wei, A. A. Faisal, M. Grosse-Wentrup, A. Gramfort, S. Chevallier, V. Jayaram, C. Jeunet, S. Bakas, S. Ludwig, K. Barmpas *et al.*, “2021 BEETL Competition: Advancing Transfer Learning for Subject Independence and Heterogenous EEG Data Sets,” in *NeurIPS 2021 Competitions and Demonstrations Track*. PMLR, 2022, pp. 205–219.
- [12] C. S. Nam, A. Nijholt, and F. Lotte, *Brain-Computer Interfaces Handbook: Technological and Theoretical Advances*. CRC Press, 2018.