

Classificação de imagética motora baseada em EEG entre indivíduos por meio de Redes Neurais Convolucionais

Arthur Hauer¹, André Eugenio Lazzaretti¹, Daniel Prado de Almeida Campos², Eddy Krueger³, Heitor Silvério Lopes¹ and José Jair Alves Mendes Junior¹

¹ UTFPR/CPGEL, Avenida Sete de Setembro, 3165, Curitiba, Brasil

² UTFPR, Marcílio Dias, 635, Apucarana, Brasil

³ UEL/Departamento de Anatomia, Rodovia Celso Garcia Cid - Pr 445, Londrina, Brasil

Abstract— Apesar de existirem vários dados públicos disponíveis para pesquisa de classificação de imagética motora com sinais de EEG, a quantidade de dados referentes a um único sujeito é normalmente pequena. Além disso, o processo de aquisição de dados para um único indivíduo é longo, principalmente se o volume de dados requeridos é extenso. Isso pode causar desconforto ao sujeito na coleta, comprometendo a qualidade dos dados adquiridos. De modo a reduzir o volume de dados (e consequentemente seu tempo de coleta) necessário para o treinamento de um sistema de classificação especializado para um dado indivíduo, este trabalho visa avaliar a aplicação de *transfer learning* na classificação de imagética motora com dados de EEG entre indivíduos. Deste modo, avaliou-se um conjunto de dados de 3 classes, composto por aquisições de EEG com 64 canais de 109 indivíduos, em 3 sessões de 2 minutos de imagética motora. Avaliam-se 2 arquiteturas de redes convolucionais profundas, propostas na literatura, através da comparação de acurácia entre modelos treinados com indivíduos isoladamente (intra-sujeito) e modelos treinados com diversos indivíduos e retreinados com o sujeito-teste (entre-sujeito). Para ambas arquiteturas, comparando os esquemas intra-sujeito e entre-sujeito, os experimentos indicaram um incremento médio de acurácia superior a 10% com a abordagem proposta, resultando em acurácia média de aproximadamente 70%.

Keywords— EEG, Imagética Motora, Redes Neurais Convolucionais, *Transfer Learning*.

I. INTRODUÇÃO

Interfaces cérebro-computador (BCI, do inglês *Brain-Computer Interface*) baseadas em eletroencefalogramas (EEG) são uma tecnologia largamente pesquisada, principalmente no âmbito de recuperação do movimento de membros em indivíduos que sofreram danos no sistema nervoso [1, 2]. Uma abordagem comum em sessões de reabilitação fisioterápica de pessoas com este tipo de lesão é uma forma de

simulação mental de atividades motoras sem ativação muscular, chamada de imagética motora [2]. De maneira geral, os sistemas propostos para aplicações neste tipo de terapia consistem em um conjunto de captação de sinais de EEG que alimenta um processador, responsável por classificar a intenção de movimento e controlar um atuador, que por sua vez efetua o movimento propositado pelo usuário [3].

Considerando estes sistemas de classificação isoladamente, a abordagem mais comum é treiná-los e testá-los exclusivamente com dados coletados do usuário final. Apesar de pesquisas mostrarem resultados promissores quanto à qualidade de classificação atingida com esta abordagem, os atributos extraídos do sinal adquirido de um mesmo indivíduo podem variar entre sessões [4], reduzindo a utilidade de dados coletados no longo prazo.

É possível citar, entre os classificadores mais tipicamente usados em BCI baseada em EEG, métodos clássicos de aprendizagem supervisionada, como *Linear Discriminant Analysis* (LDA), *Support Vector Machines* (SVM) e árvores de decisão [5]. Redes Neurais (NN, do inglês *Neural Network*), por sua vez, não obtiveram tanta atenção, principalmente em função de limitações práticas, como seu longo tempo de computação e treinamento. Entretanto, o recente desenvolvimento de processadores de vídeo e a crescente facilidade de acesso à grandes conjuntos de dados levaram pesquisadores a investigar mais a fundo aplicações de RN com várias camadas, comumente denominado *deep learning*. Ainda, neste nicho, pode-se destacar as arquiteturas que empregam convoluções, chamadas Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*). Uma grande vantagem de CNNs é sua capacidade de aprender e extrair atributos, o que reduz a necessidade de *feature engineering*, normalmente necessária em tarefas de classificação [6, 7].

Apesar de proverem bons resultados quando comparadas aos métodos clássicos de aprendizagem, CNNs têm uma grande quantidade de parâmetros, o que requer um volume extenso de dados e tempo para treinamento. Particularmente

em aplicações de BCI baseadas em EEG, a necessidade de muitos dados torna o processo de aquisição longo e cansativo ao usuário, podendo comprometer a qualidade da captura [8]. Apesar de existirem conjuntos de dados públicos que auxiliam o desenvolvimento de pesquisas neste campo, estes normalmente contém pequenos volumes de dados relativos a um único indivíduo, dificultando seu uso em estudos onde grandes quantidades são necessárias.

De modo a superar este problema, propuseram-se abordagens que empregam a transferência de conhecimento (do inglês, *transfer learning*) obtida com dados coletados de indivíduos distintos.

Dentre estas abordagens, é possível citar o trabalho de Zancanaro *et al* [9]. Nele, os autores utilizam o conjunto de dados 2a da competição IV de BCI (D2a), (composto de 22 canais, 9 indivíduos, 4 classes e 576 *trials* por indivíduo), pré-processado com um filtro passa-faixa e rejeita-faixa. Os autores propõe a comparação entre sua própria implementação da arquitetura EEGNet, proposta em [10], e *Filter-Bank Common Spatial Pattern* (FBCSP) [11]. Reporta-se superioridade da arquitetura de CNN sob o método FBCSP, tanto nos esquemas intra-sujeito quanto entre-sujeito. O trabalho, no entanto, não aborda o problema de volume de dados individuais, e não reportam-se testes feitos com conjuntos de dados que contém um grande número de sujeitos com poucos dados individuais.

Também pode-se mencionar o trabalho de Zhang *et al* [8], onde os autores avaliam diferentes esquemas de adaptação de modelos pré-treinados com diversos indivíduos, comparando o número de camadas adaptáveis e a taxa de aprendizagem usada durante a adaptação para um novo sujeito. De maneira similar ao previamente citado, os autores não abordam o problema de volume de dados individuais. Nele, faz-se uso de um conjunto de dados que contém 54 indivíduos, com 800 *trials* por indivíduo.

Em [12], utilizando o conjunto de dados D2a, além de um conjunto de dados próprio, *High Gamma Dataset* (HGD) (composto por 20 indivíduos e 880 *trials* por indivíduo), os autores avaliam as arquiteturas propostas somente através da estratégia intra-sujeito, não havendo testes com *transfer learning*.

Em contrapartida, [10] reporta testes utilizando 4 datasets distintos com um máximo de 26 indivíduos, incluindo o já citado D2a. Nele, apesar de reportados testes comparando a arquitetura Deep4Net com a própria EEGNet, não fez-se uso da estratégia de treinamento recortado proposta em [12], sendo esta uma técnica de *data augmentation* potencialmente útil para conjuntos de dados de volume restrito.

No presente trabalho, utiliza-se o conjunto de dados *PhysioNet eegmmidb* com 109 indivíduos e 3 coletas de 2 minutos cada, descrito em [13], reporta-se a capacidade das

arquiteturas Deep4Net, proposta em [12], e EEGNet [10], de adaptarem-se a somente 4 minutos de dados de sessões de imagética motora de indivíduos inéditos ao sistema de classificação, combinando com o uso de técnicas de *transfer learning*.

Este trabalho está estruturado como segue. Apresenta-se a metodologia para desenvolvimento do trabalho na Seção II, enquanto a Seção III descreve os resultados obtidos e discute sua significância. Finalmente, a Seção IV apresenta a conclusão do trabalho.

II. METODOLOGIA

Nesta seção, primeiramente descreve-se o conjunto de dados utilizado. Em seguida, descrevem-se as arquiteturas utilizadas e, por fim, apresentam-se os experimentos propostos.

A. Conjunto de dados

Considerando o objetivo do trabalho, primou-se por um conjunto de dados que contivesse dados referentes a um grande número de indivíduos, divididos em um pequeno número de sessões curtas de coleta. O conjunto escolhido, coletado através do sistema BCI2000, proposto em [13], e disponível em [14], contém dados de 109 indivíduos e um total de 14 sessões experimentais de 1 e 2 minutos, obtidas com uso de 64 eletrodos, posicionados segundo o arranjo internacional 10-10 (exceto pelos eletrodos Nz, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9, e P10), amostrados a 160 Hz.

De forma geral, o conjunto contém 3 tipos de experimentos:

- *Baseline*: Sem intenção ou movimento, com olhos fechados ou olhos abertos;
- Intenção de movimento: Ordenado por estímulos visuais, o indivíduo imagina a execução de movimentos pré-definidos, de punhos ou pés;
- Ativação muscular: Ordenado por estímulos visuais, o indivíduo executa movimentos pré-definidos, de punhos ou pés.

Neste trabalho, utilizam-se apenas coletas referentes aos experimentos de intenção de movimento dos punhos, totalizando 3 sessões de 2 minutos por indivíduo, cada uma contendo aproximadamente 60 eventos pertencentes a uma das 3 classes:

- Repouso;
- Intenção de cerrar o punho esquerdo;
- Intenção de cerrar o punho direito.

Ademais, de modo a otimizar a utilização do número restrito de dados disponíveis, utiliza-se uma estratégia de treinamento segmentado, proposta em [12], em que uma janela deslizante gera exemplos de treinamento ao retirar trechos de dados de uma única sessão de coleta, gerando um conjunto significativamente maior de dados quando comparada à estratégia de separar os dados de treinamento por *trial* (período em que a intenção de movimento ou repouso ocorre, de seu início a seu fim). Para os experimentos, utilizou-se uma janela de 450 amostras (aproximadamente 2.8 segundos), com passo igual. Exceto pela separação dos dados em janelas, não houve qualquer pré-processamento dos dados.

B. Arquiteturas

Neste trabalho, avalia-se a arquitetura de CNN profunda descrita em [12], largamente testada pelos autores em busca de sua melhor combinação de parâmetros. A arquitetura consiste em filtros temporais e espaciais com *max-pooling*, seguidos de 3 blocos compostos por convolução e *max-pooling*. Sua saída é provida através de uma camada *softmax* de classificação totalmente conectada. Também experimenta-se a arquitetura de CNN compacta descrita em [10]. Os autores sugerem que mesmo com um pequeno conjunto de dados para treinamento a arquitetura é capaz de prover resultados satisfatórios, e a comparam com a arquitetura de CNN profunda descrita anteriormente, utilizando 3 conjuntos de dados distintos. No trabalho, reporta-se que em experimentos de classificação intra-sujeito a arquitetura equiparou-se ou superou suas bases de comparação, enquanto em experimentos de classificação entre-sujeito teve resultado similar à arquitetura proposta por [12].

C. Experimentos

Propõe-se a comparação entre as capacidades das arquiteturas de classificar corretamente utilizando o esquema clássico intra-sujeito e o esquema entre-sujeito com adaptação. A Figura 1 ilustra o arranjo experimental.

Durante testes, percebeu-se que nenhum dos experimentos obteve ganhos significativos de performance após 50 épocas. Portanto, treina-se cada classificador por, no máximo, 50 épocas em todos os experimentos desempenhados.

Utiliza-se o otimizador AdamW [15] com uma taxa de aprendizagem igual a $5e^{-4}$ e decaimento de pesos igual a $5e^{-4}$ para otimizar a função custo *negative log-likelihood*, conforme proposto por [8], em conjunto com *early stopping* com paciência de 10 épocas, selecionando-se os parâmetros que provém o melhor desempenho sob o conjunto de validação.

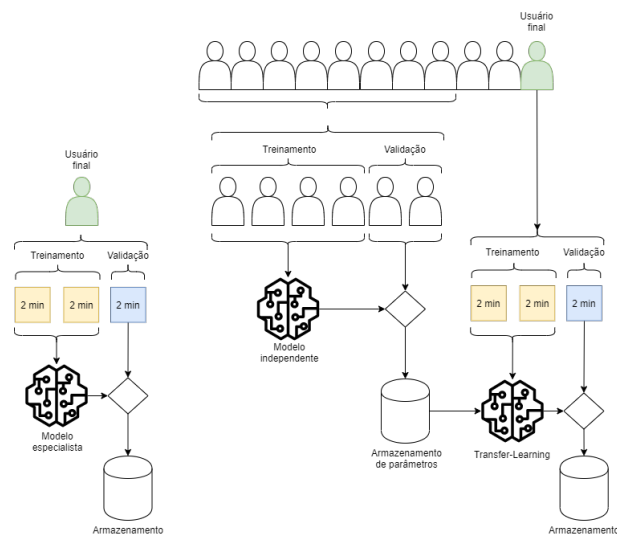


Fig. 1: Diagrama dos experimentos.

Os arranjos foram executados com o *framework* Torch [16], e as bibliotecas Braindecode [12] e MNE-Python [17]. O código fonte desenvolvido para o desempenho dos experimentos encontra-se disponível em [18].

Sendo assim, propõe-se 2 experimentos:

- **Intra-sujeito:** Aqui, utiliza-se o arranjo clássico em que tanto os dados de treinamento quanto de validação são coletados, exclusivamente, do usuário final. Deste modo, para cada indivíduo no conjunto, dividem-se os dados de forma que o conjunto de treinamento contenha os dados relativos a duas sessões de coleta (4 minutos) e que o conjunto de validação contenha dados relativos a somente uma sessão (2 minutos). Efetua-se validação cruzada em 3 subconjuntos, alternando a sessão de validação. Refere-se ao classificador resultante deste experimento como modelo especialista.
- **Entre-sujeito com adaptação:** A lista de indivíduos é aleatorizada, e, através de uma janela deslizante, selecionam-se dados relativos a 80 indivíduos, com passo igual a 15. Em seguida, os dados são divididos em 80% para treinamento e 20% para validação de modo a efetuar validação cruzada em 5 subconjuntos. Como o objetivo é otimizar a performance para dados de indivíduos inéditos ao classificador, essa divisão é feita por sujeito, resultando em dados de 64 indivíduos para treinamento e dados de 16 indivíduos para validação. Refere-se ao classificador resultante dessa etapa como modelo independente. Efetuado o treinamento, seleciona-se um dos indivíduos não contidos no grupo selecionado para

treinamento ou validação do modelo independente e, de maneira idêntica à proposta no experimento descrito no caso intra-sujeito, dividem-se os dados deste indivíduo de modo que o conjunto de treinamento contenha dados relativos a duas sessões de coleta (4 minutos) e que o conjunto de validação contenha dados relativos a somente uma sessão (2 minutos). Estes dados são então utilizados para *transfer learning* do modelo independente.

D. Transfer Learning

O processo de *transfer learning* é uma técnica que consiste em utilizar conhecimento obtido em um domínio e aplicá-lo a outro diferente. Pode-se afirmar que é fomentado, principalmente, pela disparidade no volume de dados em conjuntos de domínios diferentes. Utilizando *transfer-learning* pode-se evitar, por exemplo, o problema de *overfitting*, já que o grande número de parâmetros contidos em CNNs exigem um grande número de exemplos de treinamento.

Para problemas de visão computacional, por exemplo, pode-se utilizar um modelo treinado a priori sob um conjunto de dados colossal composto por imagens dos mais variados objetos, como pessoas, edifícios, carros, *etc.*, e então treiná-lo sob um pequeno conjunto que contém imagens de objetos específicos — como espécies de flores — obtendo um resultado de classificação satisfatório.

De maneira similar, propõe-se a utilização de um conjunto de dados de EEG de diversos indivíduos para o treinamento de um modelo de CNN, e o posterior refinamento com um pequeno número de exemplos de treinamento de um indivíduo inédito.

III. RESULTADOS E DISCUSSÃO

No experimento de classificação intra-sujeito, obteve-se acurácia média de 56.03% com a arquitetura Deep4Net, enquanto a arquitetura EEGNet obteve acurácia média de 58.47%, resultado que corrobora os resultados reportados pelos autores em [10]. A Figura 2 ilustra a distribuição de acurácia média por indivíduo do conjunto de dados obtida neste experimento.

Em contrapartida, o experimento de classificação entre-sujeito com adaptação apontou uma acurácia média de 73.65% através do uso da arquitetura Deep4Net, superando a arquitetura EEGNet, que obteve acurácia média de 69.65%. A Figura 3 ilustra a distribuição de acurácia média por indivíduo do conjunto de dados obtida neste experimento.

Destaca-se o fato de que os classificadores Deep4Net e EEGNet — testados sob o experimento entre-sujeito — provém a, respectivamente, 64.29% e 57.14% dos usuários,

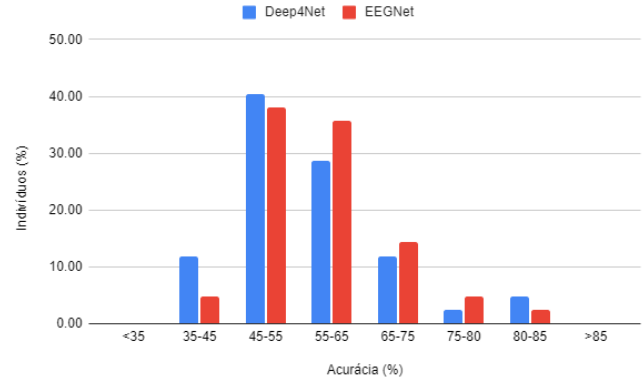


Fig. 2: Histograma de acurácia obtida com o experimento intra-sujeito, sob indivíduos.

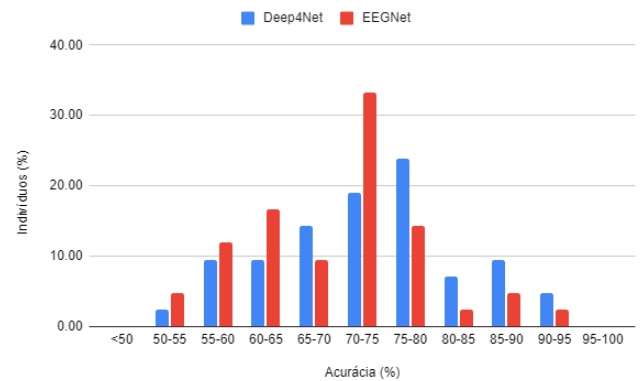


Fig. 3: Histograma de acurácia obtida com o experimento entre-sujeito, sob indivíduos.

uma acurácia superior a 75%. Estendendo o limiar por mais 10 pontos percentuais, os classificadores obtêm acurácia superior a 65% para 78.57% e 66.67% dos usuários, respectivamente. Ilustrando estes resultados, a Figura 4 apresenta a acurácia média acumulada sob indivíduos.

Através do teste de posto pareado de Wilcoxon [19], comprovou-se significância estatística na variação média de acurácia entre os experimentos ($p = 1.65e^{-08}$ para a arquitetura Deep4Net, e $p = 1.77e^{-08}$ para a arquitetura EEGNet). A distribuição da variação de acurácia média por indivíduos é ilustrada através da Figura 5.

Os resultados apresentados na Tabela 1 e na Figura 5 sugerem que há variabilidade na performance de cada método sob diferentes indivíduos. É notável que o desempenho da arquitetura EEGNet é mais consistente que o desempenho da arquitetura Deep4Net em todos os experimentos, produzindo maior repetibilidade de acurácia através dos indivíduos do conjunto de dados, embora o desempenho médio da última seja mais interessante.

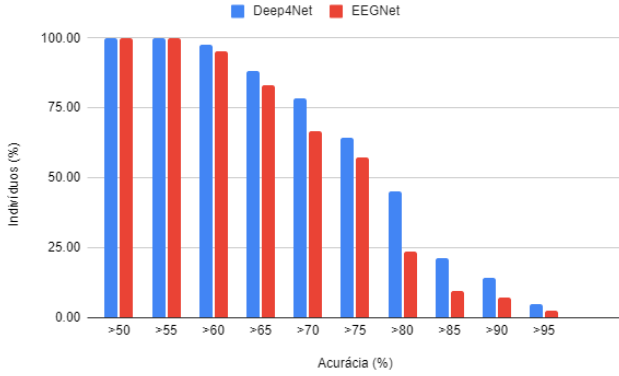


Fig. 4: Histograma de acurácia acumulada obtida com o experimento entre-sujeito, sob indivíduos.

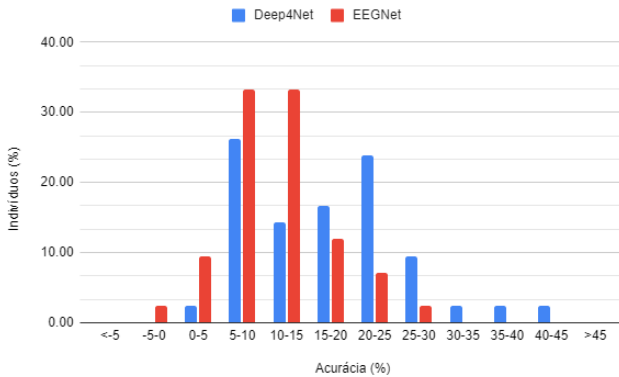


Fig. 5: Histograma de variação de acurácia entre métodos intra-sujeito e entre-sujeito, sob indivíduos.

Table 1: Comparação de acurácia (%) entre métodos.

Método	Média (σ)	Mediana	Range (Max - Min)
Intra-sujeito			
Deep4Net [8]	63.54 (14.25)	60.50	57.00 (100.00-43.00)
Deep4Net	56.03 (10.52)	54.25	47.40 (84.90-37.50)
EEGNet	58.47 (09.25)	57.55	36.46 (80.56-44.10)
Entre-sujeito			
Deep4Net [8]	86.89 (11.41)	88.50	44.00 (100.00-56.00)
Deep4Net	73.65 (10.16)	73.99	42.05 (94.79-52.74)
EEGNet	69.65 (08.68)	70.90	37.81 (91.56-53.75)
Varição			
Deep4Net [8]	23.35 (—)	—	— (— - —)
Deep4Net	17.62 (13.83)	16.10	40.14 (41.67-1.53)
EEGNet	11.18 (05.77)	10.99	26.15 (25.87-0.28)

É possível afirmar que os resultados obtidos neste trabalho, com a arquitetura Deep4Net, são coerentes àqueles reportados em [8], embora neste os autores tenham utilizado

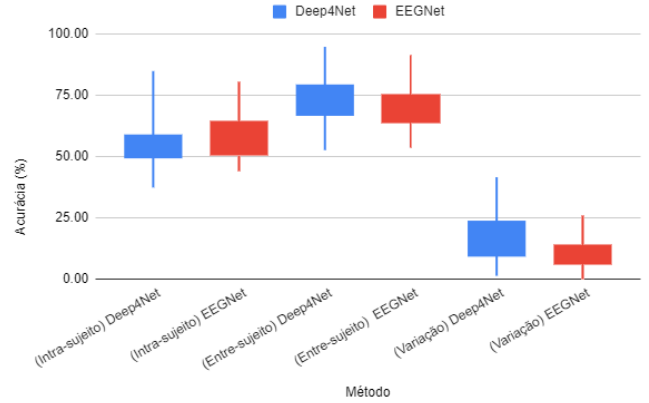


Fig. 6: Visão geral da acurácia obtida durante os experimentos.

um conjunto de dados com mais de 800 eventos por indivíduo, divididos em 2 sessões de coleta, o que pode justificar seus resultados superiores quando comparados aos deste trabalho.

De maneira análoga, a arquitetura EEGNet também apresentou-se consistente com os resultados expostos em [10]. No trabalho, os autores reportam um desvio padrão menor que o obtido pela arquitetura Deep4Net, alcançando resultados praticamente iguais à última em experimentos intra-sujeito, e ligeiramente inferiores em experimentos entre-sujeito.

Os resultados obtidos, com ambas arquiteturas, sugerem que, o treinamento realizado através de *transfer learning*, para CNNs, é mais adequado do que o treinamento realizado com dados individuais. Pode-se afirmar que isso ocorre pelo restrito número de exemplos de treinamento providos por dados individuais, além de, como exposto na Introdução, sabermos que embora possa existir um volume satisfatório de dados de um único indivíduo, estes podem ter seu valor intrínseco reduzido pela variabilidade entre seções. Deste modo, é possível dizer que, tendo em vista a utilidade de dados em longo prazo, classificadores mais capazes de generalização devem superar classificadores especialistas em aplicações como a proposta nesse trabalho, principalmente quando considera-se que nos últimos normalmente tem-se uma extensa engenharia de atributos específica ao problema a ser resolvido. Neste quesito, uma grande vantagem de CNNs é sua capacidade embarcada de aprender e adaptar extratores de atributos. Esta afirmação também é suportada pelos resultados de [8, 10].

IV. CONCLUSÕES

Neste trabalho, avaliaram-se 2 arquiteturas de CNN, classificáveis como estado-da-arte, em uma aplicação de classificação de sinais de EEG no contexto de imagética motora, sob o problema da obtenção de acurácia satisfatória em conjuntos de dados onde há poucos dados de indivíduos isoladamente. Ao comparar 2 métodos de treinamento — intra-sujeito e entre-sujeito —, obteve-se um incremento médio estatisticamente significativo de até 17.62% acurácia, sugerindo que, apesar da variabilidade de atributos entre indivíduos, é mais adequado treinar CNNs com dados de muitos indivíduos, para posteriormente realizar *transfer learning* de modo a adaptá-las ao usuário final.

CONFLITO DE INTERESSE

Os autores declaram não haver conflito de interesse.

REFERENCES

1. Brown Andrew R, Martinez Marina. From cortex to cord: motor circuit plasticity after spinal cord injury *Neural regeneration research*. 2019;14:2054.
2. Aggarwal Swati, Chugh Nupur. Signal processing techniques for motor imagery brain computer interface: A review *Array*. 2019;1:100003.
3. ABDALSALAM M. Eltaf, Yusoff M. Zuki, Kamel Nidal, Malik Aamir, Meselhy Mohamed. Mental task motor imagery classifications for non-invasive brain computer interface in *2014 5th International Conference on Intelligent and Advanced Systems: Technological Convergence for Sustainable Future, ICIAS 2014 - Proceedings* 2014.
4. Blankertz Benjamin, Tomioka Ryota, Lemm Steven, Kawanabe Motoaki, Muller Klaus-Robert. Optimizing spatial filters for robust EEG single-trial analysis *IEEE Signal processing magazine*. 2007;25:41–56.
5. Junior Paulo Broniera, Campos Daniel Prado, Lazzaretti André Eugenio, et al. EEG-FES-Force-MMG closed-loop control systems of a volunteer with paraplegia considering motor imagery with fatigue recognition and automatic shut-off *Biomedical Signal Processing and Control*. 2021;68:102662.
6. Ding Zhen, Yang Chifu, Tian Zhihong, Yi Chunzhi, Fu Yunsheng, Jiang Feng. sEMG-based gesture recognition with convolution neural networks *Sustainability (Switzerland)*. 2018;10:1–12.
7. Hu Yu, Wong Yongkang, Wei Wentao, Du Yu, Kankanhalli Mohan, Geng Weidong. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition *Plos One*. 2018;13:e0206049.
8. Zhang Kaishuo, Robinson Neethu, Lee Seong-Whan, Guan Cuntai. Adaptive transfer learning for EEG motor imagery classification with deep Convolutional Neural Network *Neural Networks*. 2021;136:1–10.
9. Zancanaro Alberto, Cisotto Giulia, Paulo João Ruivo, Pires Gabriel, Nunes Urbano J.. CNN-based Approaches For Cross-Subject Classification in Motor Imagery: From the State-of-The-Art to DynamicNet in *2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*:1-7 2021.
10. Lawhern Vernon J, Solon Amelia J, Waytowich Nicholas R, Gordon Stephen M, Hung Chou P, Lance Brent J. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces *Journal of neural engineering*. 2018;15:056013.
11. Ang Kai Keng, Chin Zheng Yang, Zhang Haihong, Guan Cuntai. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface in *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*:2390-2397 2008.
12. Schirrneister Robin Tibor, Springenberg Jost Tobias, Fiederer Lukas Dominique Josef, et al. Deep learning with convolutional neural networks for EEG decoding and visualization *Human Brain Mapping*. 2017;38:5391-5420.
13. Schalk G., McFarland D.J., Hinterberger T., Birbaumer N., Wolpaw J.R.. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System *IEEE Transactions on Biomedical Engineering*. 2004;51:1034–1043.
14. Schalk Gerwin, McFarland Dennis J, Hinterberger Thilo, Birbaumer Niels, Wolpaw Jonathan R. EEG Motor Movement/Imagery Dataset 2009.
15. Loshchilov Ilya, Hutter Frank. Decoupled Weight Decay Regularization 2019.
16. Paszke Adam, Gross Sam, Massa Francisco, et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library in *Advances in Neural Information Processing Systems 32* (Wallach H., Larochelle H., Beygelzimer A., Alché-Buc F., Fox E., Garnett R. . eds.):8024–8035Curran Associates, Inc. 2019.
17. Gramfort Alexandre, Luessi Martin, Larson Eric, et al. MEG and EEG data analysis with MNE-Python *Frontiers in Neuroscience*. 2013;7:267.
18. Hauer Arthur. Classificação de imagética motora entre indivíduos https://github.com/arthurhauer/CNN_CrossSubject_Classification 2022.
19. Wilcoxon Frank. Individual Comparisons by Ranking Methods *Biometrics Bulletin*. 1945;1:80–83.