

CCA+EEGNet para classificação de sinais de EEG em interfaces cérebro-computador baseadas em potenciais visualmente evocados

Mateus A. Chinelatto

Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)
Campinas, Brasil
m174303@dac.unicamp.br

Manoel R. Caetano Junior

Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)
Campinas, Brasil
m240652@dac.unicamp.br

Rafael Ferrari

Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)
Campinas, Brasil
rafaelf@unicamp.br

Romis Attux

Faculdade de Engenharia Elétrica e de Computação (FEEC)
Universidade Estadual de Campinas (UNICAMP)
Campinas, Brasil
attux@unicamp.br

Abstract—Interfaces cérebro-computador (BCIs) são capazes de criar canais de comunicação alternativos entre o córtex cerebral e o mundo externo. Por meio delas, indivíduos em reabilitação ou que perderam suas capacidades motoras podem controlar sistemas sem a necessidade de movimento. Este estudo propõe a combinação da análise de correlação canônica (CCA) com a rede neural artificial EEGNet para realizar o processamento e classificação de sinais de eletroencefalograma (EEG) em BCIs baseadas em potenciais visualmente evocados em regime estacionário (SSVEP). A combinação proposta melhorou o desempenho da rede em cerca de 20%, atingindo $59.69 \pm 2.98\%$ de acurácia e ITR de $89.75 \pm 6.40\%$ bpm.

Index Terms—Interfaces cérebro-computador, Redes neurais artificiais, Aprendizado de máquina, EEG.

I. INTRODUÇÃO

Interfaces cérebro-computador (BCIs) são um tipo de interface humano-computador na qual o canal de comunicação conecta o cérebro a algum dispositivo externo e o controle é realizado analisando-se diretamente os sinais elétricos gerados no córtex cerebral [1]. Este tipo de interface vem ganhando relevância cada vez maior em sistemas de reabilitação, já que permite que pacientes em recuperação interajam com o mundo sem a necessidade de atividade muscular [2]. A Figura 1 apresenta os principais processos envolvidos no funcionamento de uma BCI em um laço fechado: aquisição do sinal cerebral, amplificação e digitalização, processamento, interação com uma interface de controle e atuação do sistema. Dentre os métodos existentes para captar os sinais cerebrais, o eletroencefalograma (EEG) é o mais utilizado por ser não invasivo, barato e de simples utilização. Além disso, os sinais de EEG costumam apresentar uma alta resolução temporal quando comparados a outros métodos não invasivos [3].

Quando um indivíduo foca sua atenção em um estímulo visual que pisca a uma frequência constante, um potencial

estacionário é evocado no cérebro nesta mesma frequência. Dessa forma, para realizar a comunicação, a BCI deve interpretar o sinal cerebral e identificar o estímulo alvo. Este tipo de interface é chamada SSVEP (*Steady-State Visually Evoked Potential*) e possui uma alta taxa de transferência de informação quando comparada a outros paradigmas.




Fig. 1. Componentes principais de uma interface cérebro-computador, com destaque para as etapas de processamento do sinal de EEG.

A análise de correlação canônica (CCA) é um dos métodos mais consolidados em SSVEP. Seu objetivo é medir a correlação entre os sinais de EEG e os diferentes sinais de estimulação presentes no sistema a fim de identificar qual é o estímulo escolhido pelo usuário da BCI [4]. A ampla utilização do método levou ao surgimento de diversas melhorias e modificações. O FB-CCA (Filter Bank CCA), por exemplo, adiciona um banco de filtros a fim de separar o sinal de entrada em sub-bandas e incorporar componentes das harmônicas para melhorar a classificação [5]. O eCCA (Extended CCA) incorpora dados de treinamento à análise de correlação canônica para gerar sinais de referência individualizados e capturar a informação temporal das respostas SSVEP de cada usuário [6]. Outros métodos estatísticos também obtêm bons resultados,

como é o caso do TRCA (Task-Related Component Analysis), que apresenta taxas de transferência de informação mais altas que o CCA [7].

Para além dos métodos estatísticos, a pesquisa envolvendo redes neurais artificiais em SSVEP vem se desenvolvendo rapidamente, pelas potenciais vantagens em relação aos métodos clássicos. Estas redes, dotadas de não-linearidades e de uma estrutura de camadas sequenciais, filtros e transformações, têm capacidade significativa de encontrar / reconhecer padrões subjacentes aos sinais de EEG que contribuam para a classificação [8]. A maioria das arquiteturas destas redes são construídas integrando intuições e conhecimento prévio sobre as características das BCIs SSVEP. A EEGNet [9], a DNN [10] e a FB-tCNN [11] são redes convolucionais que utilizam *kernels* com dimensões unitárias para emular filtros espaciais e temporais. Além disso, a DNN e FB-tCNN utilizam bancos de filtros para separar os sinais que compõem a entrada da rede em sub-bandas. A C-CNN aplica a FFT para processar o sinal e passa as partes real e imaginária do espectro como entrada [12]. A ConvCA tem sua arquitetura projetada para se assemelhar a uma aplicação da análise de correlação canônica, porém com a vantagem de ser não linear [13]. Métodos mais recentes têm também estudado a aplicação de arquiteturas do tipo *transformer* em SSVEP, como é o caso do DG-Conformer [14] e da SSVEPFormer [15].

Alternativamente, alguns trabalhos propõem aliar técnicas estatísticas e redes neurais artificiais para obter melhores resultados. A TRCA-Net aplica o método TRCA (Task-Related Component Analysis) como um estágio de pré-processamento e usa os dados processados para realizar a classificação com a arquitetura DNN [16], melhorando de forma significativa o desempenho da rede.

Este trabalho propõe aliar a análise de correlação canônica à EEGNet para realizar toda a etapa de processamento do sinal de um sistema BCI. Nesta proposta, o CCA atua realizando um pré-processamento do sinal, combinando os sinais de diferentes eletrodos, atenuando ruído em frequências diferentes e ressaltando a frequência de estimulação. Ao aplicá-lo repetidamente para cada frequência, o método gera uma série de projeções que são então organizadas e utilizadas como entrada para a rede neural artificial EEGNet. Primeiramente, foi realizado um experimento para demonstrar a capacidade do CCA de gerar um conjunto de características útil para classificação. Após isso, foi realizada uma comparação entre os resultados obtidos treinando a EEGNet diretamente com os sinais de EEG ou com as projeções geradas pelo CCA. Os resultados demonstraram a efetividade do método CCA+EEGNet em melhorar as métricas de classificação e a taxa de transferência de informação.

A sequência deste trabalho é organizada da seguinte forma: a Seção 2 apresenta uma visão geral da análise de correlação canônica (CCA) e detalhes da EEGNet, seguindo com a proposta de combinação entre ambas as técnicas (CCA+EEGNet) para classificação de sinais EEG. A Seção 3 descreve os experimentos realizados, incluindo informações sobre a base de dados e detalhes do treinamento da rede. Os resultados e

discussões são apresentados na Seção 4 e, por fim, a Seção 5 conclui o artigo.

II. METODOLOGIA

A. CCA

A Análise de Correlação Canônica (CCA) é um método estatístico multivariável que busca encontrar correlações latentes entre dois conjuntos de variáveis aleatórias. Dados dois vetores de variáveis aleatórias X e Y , o método CCA encontra os vetores de pesos W_x e W_y que maximizam a correlação entre as combinações lineares $x = X^T W_x$ e $y = Y^T W_y$. Isso é feito resolvendo o seguinte problema de otimização:

$$\max_{W_x, W_y} \rho(x, y) = \frac{E[W_x^T X Y^T W_y]}{\sqrt{E[W_x^T X X^T W_x] E[W_y^T Y Y^T W_y]}} \quad (1)$$

em que $E[\cdot]$ é o operador de esperança estatística.

As variáveis x e y são chamadas de variáveis canônicas e $\rho(x, y)$ é o coeficiente de correlação canônica entre elas.

A aplicação deste método para classificação em BCIs baseadas em SSVEP consiste em maximizar a correlação entre um conjunto X formado pelos sinais dos canais de EEG e conjuntos de sinais de referência Y_m , formados por senos e cossenos nas frequências fundamental e harmônicas associadas à frequência de cintilação de cada um dos estímulos visuais da interface [4],

$$Y_m = \begin{bmatrix} \sin(2\pi f_m t) \\ \cos(2\pi f_m t) \\ \vdots \\ \sin(2\pi N_h f_m t) \\ \cos(2\pi N_h f_m t) \end{bmatrix}, \quad t = \frac{1}{f_s}, \frac{2}{f_s}, \dots, \frac{T}{f_s} \quad (2)$$

em que f_s é a frequência de amostragem do sistema, T é o número de amostras da janela de sinal de EEG a ser analisada, f_m é a frequência de cintilação do m -ésimo estímulo presente no sistema e N_h é o número de harmônicas considerado na análise. Após encontrar os coeficientes de correlação ρ_m entre o conjunto de sinais de EEG e cada um dos estímulos, a identificação da frequência alvo é feita com base no maior coeficiente obtido

$$k = \max_m \rho_m, \quad m = 1, 2, \dots, M \quad (3)$$

em que M é o número de estímulos presentes na interface e k é o índice do estímulo escolhido pelo usuário na janela analisada.

B. EEGNet

A EEGNet é uma arquitetura compacta proposta para classificar sinais de EEG no contexto de interfaces cérebro-computador. Dentre seus principais atributos está a capacidade de extrair características neurofisiologicamente interpretáveis e a possibilidade de treinamento com poucos dados [9]. Ela é extremamente flexível, podendo ser aplicada em diferentes paradigmas de BCI e apresenta resultados particularmente

interessantes quando aplicada em interfaces baseadas em potenciais visualmente evocados [17].

Sua estrutura é formada por três blocos principais, sendo duas sequências de camadas convolucionais e um bloco classificador composto por uma camada densa, como mostra a Figura 2. A entrada da rede é construída “empilhando-se” os sinais de cada canal de EEG de forma que a matriz resultante tenha dimensões $(1, C, T)$, em que C é o número de canais.




Fig. 2. Arquitetura da EEGNet utilizada.

No primeiro bloco são realizadas duas convoluções em sequência, sendo a primeira composta por F_1 filtros de tamanho $(1, f_s/2)$. Com estas dimensões, os filtros atuam nos canais de EEG separadamente, emulando um filtro temporal. A segunda convolução aplicada é uma *depthwise convolution* com filtros de tamanho $(C, 1)$, que realizam uma filtragem espacial, combinando os sinais resultantes da filtragem temporal da camada anterior. Além disso, este tipo de convolução possui um parâmetro D que indica a profundidade da convolução e define quantos filtros serão ajustados para cada mapa de características. Após esta sequência, são aplicados *batch normalization* e a função de ativação ELU (*exponential linear unit*) para introduzir um elemento de não linearidade. Uma operação de *average pooling* é aplicada para reduzir a dimensionalidade dos mapas de características e o *dropout* é utilizado como método de regularização.

O segundo bloco contém apenas uma camada convolucional separável com F_2 filtros. Este tipo de convolução é utilizado para reduzir o número de pesos que precisam ser ajustados e por sua capacidade de, separadamente, combinar as informações dentro de um mesmo mapa de características e, após isso, combinar os diferentes mapas. Novamente, após a convolução, é realizada a sequência de operações *batch normalization*, ELU, *average pooling* e *dropout*.

Por fim, no classificador, a saída do segundo bloco é formatada e passada diretamente para uma camada densa. Esta possui tamanho M igual ao número de frequências de estímulo e a função *Softmax* é aplicada para realizar a classificação.

C. CCA+EEGNet

Um sinal de entrada X é composto por C canais de EEG e tem tamanho de T amostras temporais. No método proposto, primeiro é aplicado o CCA, porém o objetivo não é obter os coeficientes de correlação canônica, mas sim o vetor de pesos W_{x_m} e, consequentemente, a projeção x_m .

A operação $x_m = X^T W_{x_m}$ atua como um filtro espacial, combinando todos os eletrodos do sinal original, reduzindo as interferências de outras frequências e ressaltando a frequência

m no sinal resultante. Este sinal terá apenas um canal e o mesmo número T de amostras.

Para cada sinal de entrada X , são calculadas as projeções x_m correspondentes a cada uma das M frequências de estimulação presentes no sistema BCI. Estas projeções são empilhadas e rearranjadas em uma matriz de tamanho (M, T) que é passada como entrada para a rede EEGNet. A Figura 3 ilustra este processo.

O processamento para obtenção da entrada da rede utilizando CCA é o mesmo tanto para o treinamento quanto para a etapa de teste ou inferência com a EEGNet.

III. EXPERIMENTOS

A. Dataset

Para a realização dos experimentos, foi utilizada a base de dados *Benchmark* [18], um *dataset* aberto amplamente usado no desenvolvimento de algoritmos de processamento e classificação para interfaces baseadas em SSVEP [8], que contém sinais de EEG de 64 canais. Essa base apresenta dados coletados de 35 voluntários saudáveis, sendo que 8 deles já possuíam experiência prévia com a utilização de BCIs. A coleta foi realizada utilizando um soletador na forma de um teclado virtual. Os estímulos apresentados vão de 8 a 15.8 Hz com um intervalo de 0.2 Hz entre eles, totalizando assim 40 diferentes frequências de estimulação associadas a 26 letras do alfabeto, 10 dígitos e 4 símbolos. As fases entre dois estímulos de frequências adjacentes são separadas por 0.5π .

Cada paciente realizou 6 blocos de capturas, abrangendo cada um dos 40 estímulos em ordem aleatória e guiada por uma pista visual apresentada por 0.5 segundos. A duração de cada estímulo foi de 5 segundos e mais 0.5 segundos foram gravados ao final da estimulação, totalizando assim 6 segundos de gravação. A latência visual para este conjunto de dados é estimada em 140 ms e as capturas foram gravadas a uma frequência de amostragem de 1000 Hz que foi posteriormente reduzida a 250 Hz ($f_s = 250$ Hz).

Este esquema de capturas resultou em um *dataset* para classificação contendo 40 classes balanceadas correspondentes a cada um dos possíveis estímulos apresentados.

B. Pré-processamento dos dados

O pré-processamento dos dados consistiu em duas etapas: filtragem e janelamento. Primeiramente, foi aplicado um filtro Butterworth passa-banda de ordem 10 e frequências de corte 6 Hz e 70 Hz. Após a filtragem, são desconsiderados os primeiros 0.64 segundos, 0.5 s da pista visual e 0.14 s da latência de evocação, e os 5 s seguintes de estimulação são divididos em janelas para gerar as amostras que compõem os conjuntos de dados de cada experimento.

C. Visualização com t-SNE

A fim de realizar uma primeira validação sobre a utilização do método CCA como pré-processamento, e obter indícios da capacidade do método de projetar os sinais em um espaço




Fig. 3. Método proposto CCA+EEGNet. O CCA é aplicado entre o sinal de entrada X e conjuntos de sinais de referência Y_m que contém senos e cossenos em cada uma das M frequências de estimulação. As projeções x_m geradas são concatenadas verticalmente para formar a entrada da rede. A EEGNet é responsável pela classificação do sinal.

latente de características que favoreça a classificação, foi aplicado o método de visualização t-SNE (*t-distributed stochastic neighbor embedding*) [19].

Os sinais de EEG para 8 frequências (8, 9, 10, 11, 12, 13, 14 e 15 Hz) do sujeito 1 da base de dados foram analisados utilizando t-SNE antes e depois da aplicação do CCA. No caso da aplicação da análise de correlação canônica, os dados utilizados são as projeções dos sinais de EEG geradas pelo método.

D. Combinação CCA e EEGNet

Para cada um dos 35 voluntários presentes no dataset *Benchmark*, foram testadas a EEGNet e a técnica combinada (CCA+EEGNet) proposta neste trabalho. Os parâmetros da EEGNet foram ajustados seguindo a configuração que obteve os melhores resultados reportados em [9], com $F_1 = 8$ filtros na primeira camada, profundidade $D = 2$, resultando num total de 16 filtros na segunda camada, e $F_2 = 16$ filtros na última camada convolucional. As taxas de *dropout* foram mantidas em 0.25, a fim de evitar *overfitting*. Todos os treinamentos utilizaram esta mesma configuração com o objetivo de avaliar a contribuição apenas da utilização do CCA no desempenho da rede.

Dentre os 64 canais EEG presentes no conjunto de dados, 9 canais das regiões occipital e parietal foram selecionados, já que estes apresentam maiores amplitudes e SNR (*Signal-to-Noise Ratio*) no dataset utilizado: Pz, PO5, PO3, POz, PO4, PO6, O1, Oz, e O2 [18].

Na aplicação do CCA, o conjunto Y_m dos sinais de referência para cada frequência f_m foi construído considerando-se até a quinta harmônica ($N_h = 5$). Esta escolha está de acordo com resultados reportados na literatura que indicam que esta é a melhor configuração para o método CCA padrão [5]. As 40 frequências de estimulação presentes no dataset foram utilizadas como sinais-alvo, constituindo assim uma

BCI com 40 possíveis comandos. Desta forma, as 40 projeções geradas pelo CCA são empilhadas para formar cada entrada da rede no esquema CCA+EEGNet.

Para avaliação do desempenho foi utilizado um esquema *leave-one-block-out* no qual, para cada voluntário, 5 blocos são utilizados para treino enquanto o sexto é utilizado para avaliação. O processo foi repetido 6 vezes, de forma que a avaliação fosse realizada uma vez em cada bloco do conjunto de dados. Uma parcela de 15% dos dados de treinamento foi separada para realizar a validação e acompanhamento de métricas durante o treino. Nenhum dado do bloco separado para avaliação foi utilizado em qualquer etapa do treinamento, apenas para testes.

A acurácia e a taxa de transferência para cada sujeito são obtidas pela média entre os 6 blocos de experimentos, e as métricas globais no dataset são obtidas pela média entre todos os 35 sujeitos. Esta metodologia foi repetida para janelas do EEG com 0.4, 0.6, 0.8 e 1 s de duração, a fim de avaliar também o impacto da duração da janela do sinal de entrada na capacidade de extração e transformação de características do CCA.

Os resultados foram obtidos utilizando-se um computador equipado com uma GPU NVIDIA RTX 3060. O otimizador escolhido foi o Adam com *learning rate* de 0.0001 e os modelos foram treinados por 1000 épocas, sem *early-stopping* e com *batches* de 64 amostras. A função de custo utilizada foi a entropia cruzada e o código dos modelos e de treino foi escrito em Python usando-se a biblioteca Pytorch.

IV. RESULTADOS E DISCUSSÃO

A. Visualização t-SNE

A Figura 4 apresenta a visualização obtida para 240 amostras de 1 segundo do sujeito 1 da base de dados, sendo 40 amostras de cada uma das 8 classes. É possível perceber a sobreposição das amostras das diferentes frequências no

gráfico da Figura 4(a), enquanto, na Figura 4(b), cada classe aparenta estar agrupada separadamente.




Fig. 4. (a) Visualização t-SNE das características do sinal bruto. (b) Visualização das características das projeções geradas pelo CCA.

A visualização com t-SNE demonstra que, após o processamento pelo CCA, os dados originalmente desordenados são agrupados em regiões facilmente distinguíveis. Isso sugere a viabilidade da utilização desta técnica para compor as etapas de pré-processamento e extração de características de uma BCI. Porém, ainda é possível que existam sobreposições de amostras de diferentes frequências, ainda mais com um número maior de estímulos, como os 40 presentes no conjunto de dados. Dessa forma, passar os dados processados como entrada para uma rede neural convolucional ou outro método de classificação pode apresentar resultados melhores do que apenas utilizar o sinal bruto como entrada ou classificar diretamente utilizando o CCA.

B. Acurácia e ITR no dataset Benchmark

A acurácia média obtida pela rede EEGNet e pela combinação CCA+EEGNet, para os 35 voluntários da base de dados, bem como ITR média e seus respectivos erros-padrão [5], [18] obtidos para janelas de 0.4, 0.6, 0.8 e 1 s

são apresentados nas Figuras 5 e 6. É possível observar que, para ambas as métricas e considerando todos os tamanhos do sinal de entrada testados, a utilização das projeções geradas pelo processamento com CCA resultou numa melhora de desempenho.




Fig. 5. Acurácia média e erro padrão dos 35 sujeitos do dataset Benchmark para sinais de 0.4, 0.6, 0.8 e 1 segundo.




Fig. 6. ITR média e erro padrão dos 35 sujeitos do dataset Benchmark para sinais de 0.4, 0.6, 0.8 e 1 segundo.

Como mostrado na Figura 5, os melhores resultados foram obtidos pela utilização da combinação CCA+EEGNet em sinais de entrada de 1 segundo, com $59.69 \pm 2.98\%$ de acurácia. Esse valor indica um aumento de desempenho de quase 20%, ou 10 pontos percentuais (p.p.), em relação aos $49.85 \pm 3.28\%$ obtidos utilizando apenas a rede EEGNet. Também é possível perceber que o aumento da duração do sinal também leva a um aumento da acurácia média da EEGNet, tanto com as projeções quanto com dados brutos na entrada.

É interessante notar também que a melhora incremental da utilização da combinação dos métodos aumenta com o

aumento do tamanho do sinal de entrada. O ganho de desempenho relativo para os sinais de entrada com 0.4 s foi de apenas 9%, para 0.6 s foi de 12.5% e com 0.8 s foi de aproximadamente 16%. Este comportamento pode estar ligado à natureza da análise de correlação canônica, que também apresenta um desempenho melhor com o aumento da duração das janelas [20].

A taxa de transmissão de informação (ITR) em bits/min é dada por

$$ITR = \left[\log_2 M + P \log_2 P + (1 - P) \log_2 \left(\frac{1 - P}{M - 1} \right) \right] \frac{60}{\tau},$$

em que τ é o tempo necessário para o sistema gerar um comando e P é a acurácia da classificação. Nesta análise foi considerado um valor de $\tau = \frac{T}{f_s} + 0.55$, em que 0.55 s é uma estimativa do tempo de desvio ocular reportada na literatura para os sujeitos presentes no *dataset* [18].

Assim como ocorrido com as acurácias, a melhor taxa de transferência foi obtida utilizando a combinação CCA+EEGNet e sinais de 1 segundo de duração: $89.75 \pm 6.40\%$. Este valor representa aumento de 29% em relação aos $69.75 \pm 6.45\%$ obtidos apenas com a EEGNet.

A Figura 7 apresenta as acurácias médias e respectivos erros padrão para cada sujeito da base de dados no experimento que obteve os melhores resultados para a combinação CCA+EEGNet. A grande variabilidade de resultados entre usuários é comum no contexto de interfaces cérebro-computador. Além disso, a experiência prévia com interfaces cérebro-computador e a fadiga de utilização têm grande influência no desempenho de cada usuário, gerando variabilidade até mesmo entre seções de teste realizadas por um mesmo sujeito. Porém, mesmo nesse contexto, é possível observar uma melhora na acurácia média para todos os indivíduos ao utilizar a combinação CCA+EEGNet.

V. CONCLUSÕES

Neste trabalho foi proposta uma combinação de técnicas CCA+EEGNet capaz de melhorar o desempenho da classificação de sinais em BCIs SSVEP em comparação com a utilização da rede de forma padrão. Os resultados se mostraram promissores, com o método proposto alcançando uma melhora de desempenho, tanto para acurácia quanto na ITR, em todos os 35 indivíduos do conjunto de dados. Para sinais de 1 segundo, a acurácia média de $59.69 \pm 2.98\%$ e ITR média de $89.75 \pm 6.40\%$ foram, respectivamente, 20% e 29% maiores do que as obtidas sem a combinação de técnicas. Estes resultados apontam que reaproveitar métodos clássicos aliando-os a classificadores poderosos como as redes neurais artificiais é uma boa direção a seguir para o desenvolvimento de novas interfaces cérebro-computador mais robustas.

Futuros estudos devem incluir a combinação de diferentes redes com versões mais otimizadas de técnicas baseadas em CCA e experimentos sobre a contribuição do número de amostras presentes no conjunto de treinamento para o desempenho das técnicas. Além disso, novas análises e modificações do método para aplicação em cenários *cross-subject* devem ser

realizadas e a combinação de dados de diferentes usuários para treinamento deve ser estudada.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, e do CNPq (Proc. 308425/2023-5). Romis Attux agradece ao CNPq (Proc. 308425/2023-5) e ao BIOS (FAPESP 2020/09838-0) o apoio financeiro.

REFERENCES

- [1] A. Besharat, N. Samadzadehaghdam, and R. Afghan, "A comparative review of detection methods in ssvep-based brain-computer interfaces," *IEEE Access*, 2024.
- [2] M. Orban, M. Elsamanty, K. Guo, S. Zhang, and H. Yang, "A review of brain activity and eeg-based brain-computer interfaces for rehabilitation application," *Bioengineering*, vol. 9, 12 2022.
- [3] A. Rezeika, M. Benda, P. Stawicki, F. Gembler, A. Saboor, and I. Volosyak, "Brain-computer interface spellers: A review," *Brain Sciences*, vol. 8, 4 2018.
- [4] Z. Lin, C. Zhang, W. Wu, and X. Gao, "Frequency recognition based on canonical correlation analysis for ssvep-based bcis," *IEEE Transactions on Biomedical Engineering*, vol. 54, pp. 1172–1176, 6 2007.
- [5] X. Chen, Y. Wang, S. Gao, T. P. Jung, and X. Gao, "Filter bank canonical correlation analysis for implementing a high-speed ssvep-based brain-computer interface," *Journal of Neural Engineering*, vol. 12, 8 2015.
- [6] M. Nakanishi, Y. Wang, Y. T. Wang, Y. Mitsukura, and T. P. Jung, "A high-speed brain speller using steady-state visual evoked potentials," *International Journal of Neural Systems*, vol. 24, 2014.
- [7] M. Nakanishi, Y. Wang, X. Chen, Y. T. Wang, X. Gao, and T. P. Jung, "Enhancing detection of ssveps for a high-speed brain speller using task-related component analysis," *IEEE Transactions on Biomedical Engineering*, vol. 65, pp. 104–112, 1 2018.
- [8] D. Xu, F. Tang, Y. Li, Q. Zhang, and X. Feng, "An analysis of deep learning models in ssvep-based bci: A survey," *Brain Sciences*, vol. 13, 3 2023.
- [9] 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, 7 2018.
- [10] O. B. Guney, M. Oblukulov, and H. Ozkan, "A deep neural network for ssvep-based brain-computer interfaces," *IEEE Transactions on Biomedical Engineering*, vol. 69, pp. 932–944, 2 2022.
- [11] W. Ding, J. Shan, B. Fang, C. Wang, F. Sun, and X. Li, "Filter bank convolutional neural network for short time-window steady-state visual evoked potential classification," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, pp. 2615–2624, 2021.
- [12] A. Ravi, N. H. Beni, J. Manuel, and N. Jiang, "Comparing user-dependent and user-independent training of cnn for ssvep bci," *Journal of Neural Engineering*, vol. 17, 4 2020.
- [13] Y. Li, J. Xiang, and T. Kesavadas, "Convolutional correlation analysis for enhancing the performance of ssvep-based brain-computer interface," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, pp. 2681–2690, 12 2020.
- [14] J. Liu, R. Wang, Y. Yang, Y. Zong, Y. Leng, W. Zheng, and S. Ge, "Convolutional transformer-based cross subject model for ssvep-based bci classification," *IEEE Journal of Biomedical and Health Informatics*, 2024.
- [15] J. Chen, Y. Zhang, Y. Pan, P. Xu, and C. Guan, "A transformer-based deep neural network model for ssvep classification," *Neural Networks*, vol. 164, pp. 521–534, 7 2023.
- [16] Y. Deng, Q. Sun, C. Wang, Y. Wang, and S. K. Zhou, "Trca-net: using trca filters to boost the ssvep classification with convolutional neural network," *Journal of Neural Engineering*, vol. 20, 8 2023.
- [17] N. Waytowich, V. J. Lawhern, J. O. Garcia, J. Cummings, J. Faller, P. Sajda, and J. M. Vettel, "Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials," *Journal of Neural Engineering*, vol. 15, 10 2018.




Fig. 7. Acurácia média e erro padrão de cada um 35 sujeitos do dataset Benchmark utilizando os dados brutos e as projeções geradas pelo CCA para o experimento com sinais de 1 segundo de duração.

- [18] Y. Wang, X. Chen, X. Gao, and S. Gao, "A benchmark dataset for ssvep-based brain-computer interfaces," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, pp. 1746–1752, 10 2017.
- [19] L. Van der Maaten and G. Hinton, "Visualizing data using t-sne," *Journal of machine learning research*, vol. 9, no. 11, 2008.
- [20] G. Bin, X. Gao, Z. Yan, B. Hong, and S. Gao, "An online multi-channel ssvep-based brain-computer interface using a canonical correlation analysis method," *Journal of Neural Engineering*, vol. 6, 2009.