

Detecção de Potenciais Visualmente Evocados em Janelas Curtas: Análise Comparativa de Algoritmos Durante o Transitório de Evocação

Caio Henrique do Amaral
c165444@dac.unicamp.br

Rafael Ferrari
rafaelf@unicamp.br

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

Resumo

As Interfaces Cérebro-Computador (BCI, do inglês *Brain-Computer Interface*) baseadas em Potenciais Evocados Visualmente em Regime Estacionário (SSVEP, do inglês *Steady-State Visual Evoked Potential*) exigem classificação rápida e precisa [1]. Este trabalho compara dois métodos de classificação que se destacam na literatura: a Análise de Correlação Canônica Supervisionada (sCCA, do inglês *Supervised Canonical Correlation Analysis*), que otimiza a correlação com modelos sintéticos, e a Análise de Componentes Relacionados à Tarefa (TRCA, do inglês *Task-related component analysis*), uma abordagem data-driven que maximiza a relação Sinal-Ruído por meio da consistência estatística do sinal do usuário, isto é, preservando padrões que são periódicos no tempo, como é o caso do estímulo SSVEP.[2].

A hipótese proposta é de que o TRCA possui uma capacidade superior em capturar o regime transitório da resposta SSVEP, enquanto o sCCA é otimizado para o regime de estado estacionário. Para investigar esta premissa, foi realizada uma comparação direta em um dataset público [3], analisando a acurácia em função da duração da janela de dados e da latência de evocação.

O TRCA demonstrou acurácia superior em resultados preliminares nas configurações de latência menores, enquanto o sCCA apresentou melhor desempenho no maior valor de latência considerado na análise. Os resultados sugerem que de fato o TRCA trata melhor o transitório do potencial evocado, o que pode explicar o seu desempenho superior em janelas de duração mais curta.

Palavras-Chave — BCI, SSVEP, TRCA, CCA

1. Introdução

As Interfaces Cérebro-Computador (BCIs) constituem um método de interação humano-computador, que vi-

abiliza a comunicação entre indivíduos com limitações motoras severas e dispositivos externos [1].

Entre os diversos paradigmas de BCI, o Potencial Evocado Visualmente em Regime Estacionário (SSVEP) é proeminente. O SSVEP é a resposta cerebral a estímulos visuais que piscam segundo padrões específicos, em frequências que variam tipicamente entre 1 Hz e 100 Hz, e é conhecido por proporcionar uma alta taxa de transferência de informação (ITR, do inglês *Information Transfer Rate*) [1, 3]. Em BCIs baseadas em SSVEP, a atividade cerebral geralmente é registrada por meio do eletroencefalograma (EEG), conhecido por ser um método não invasivo de registro de atividade cerebral a partir de eletrodos com alta resolução temporal, portabilidade e acessibilidade [1].

Para identificar a intenção do usuário a partir dos sinais SSVEP, diversos algoritmos de extração de características são empregados. Esses métodos podem ser divididos em duas categorias principais: Métodos Livres de Calibração (*Calibration-free*), sendo a Análise de Correlação Canônica (CCA), o exemplo clássico [1], e Métodos Baseados em Calibração (*Calibration-based*), categoria na qual se insere a Análise de Componentes Relacionados à Tarefa (TRCA). [1]. O CCA maximiza a correlação entre os sinais de EEG multi-canais e sinais de referência artificiais. Em contraste, o TRCA utiliza dados de calibração para criar filtros espaciais que maximizam a reprodutibilidade dos SSVEPs através de múltiplos ensaios [2, 4], visando estimar o potencial evocado por meio da atenuação do ruído e interferências . [2].

Na literatura, o TRCA e suas extensões (*Ensemble TRCA*) demonstram um desempenho superior em termos de acurácia para janelas curtas em comparação com métodos como o CCA e suas variantes [2, 1]. O método Ensemble TRCA, por exemplo, alcançou um ITR médio de 325.33 ± 38.17 bits/min em estudos *on-line* [2].

Apesar da superioridade empírica e dos resultados

significativos alcançados pelo TRCA, a complexidade de sua arquitetura merece um estudo aprofundado. O alto desempenho do TRCA decorre de uma combinação de etapas, incluindo a otimização de seus filtros espaciais e os estágios de fusão de informações de múltiplas sub-bandas [2, 4, 5].

Embora esses mecanismos sejam estatisticamente eficazes, as propriedades fundamentais que conferem essa robustez e o impacto de cada componente no desempenho geral são tópicos que demandam uma investigação detalhada [1].

O presente projeto de pesquisa visa, portanto, pesquisar, comparar e entender os mecanismos internos do TRCA e sua relação com o CCA. O objetivo é isolar e caracterizar as propriedades estatísticas e de filtragem que resultam na alta acurácia do TRCA. Espera-se que, com base nessa compreensão aprofundada, seja possível propor modificações estruturais e conceituais no CCA, explorando a possibilidade de transferir as propriedades vantajosas do TRCA para um método correlato, que possa exigir menos dados para um bom desempenho em sistemas computacionalmente limitados ou em tempo real.

2. Métodos

O CCA é classificado como um método *calibration-free* (livre de calibração) [1, 2] e é um dos algoritmos fundamentais na detecção de SSVEP [6]. O algoritmo CCA busca encontrar combinações lineares entre o sinal EEG multicanal e sinais de referência artificiais (*senos e cossenos*) que maximizem a correlação canônica entre os dois conjuntos de dados [1, 3]. A frequência alvo (f_t) é identificada como aquela que produz o maior coeficiente de correlação (ρ_m) [1]. Apesar de sua robustez inicial e da eliminação da necessidade de longos períodos de calibração, o CCA pode ter sua performance comprometida pela contaminação de ruído, variações de fase e pelo uso limitado das informações harmônicas do SSVEP [1].

O TRCA, proposto por Tanaka et al. [4], é um método *calibration-based* (baseado em calibração) [1] que atua como um filtro espacial baseado em dados. Sua função primária é maximizar a reprodutibilidade de atividades cerebrais *time-locked* (bloqueadas no tempo) através de múltiplos ensaios [2, 4, 1]. Ao maximizar a covariância inter-ensaio em relação à autocovariância total do potencial evocado estimado, é esperado que o TRCA melhore a Relação Sinal-Ruído dos sinais SSVEP, removendo a atividade de EEG de

fundo [2, 1]. O filtro espacial $\mathbf{w}$ é obtido a partir da solução do seguinte problema de otimização [4, 2]:

$$\mathbf{w}_{opt} = \arg \max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{S} \mathbf{w}}{\mathbf{w}^T \mathbf{Q} \mathbf{w}} \quad (1)$$

em que $\mathbf{S}$ é a soma das matrizes de covariância cruzada entre ensaios (variabilidade consistente (o sinal) que é reprodutível entre os ensaios) e $\mathbf{Q}$ é a soma das matrizes de autocovariância (variabilidade total do sinal (sinal + ruído) dentro dos ensaios) [2].

Para otimizar a detecção de SSVEP, que possui respostas nos harmônicos superiores (além da frequência fundamental), tanto o CCA quanto o TRCA são frequentemente estendidos através da estratégia de Banco de Filtros (*Filter Bank*, FB) [1]. A Análise de Banco de Filtros é aplicada para decompor o sinal EEG em múltiplas sub-bandas, extraíndo de forma mais eficiente as informações independentes incorporadas nos componentes harmônicos [2].

Além disso, o método Ensemble TRCA (eTRCA) aprimora o TRCA ao integrar múltiplos filtros espaciais. Visto que os coeficientes de mistura dos sinais de fonte SSVEP podem ser considerados similares dentro da faixa de frequência utilizada, um filtro espacial de *ensemble* é construído, combinando os múltiplos filtros individuais [2]. Esta abordagem potencialmente aumenta a reprodutibilidade dos sinais em diferentes frequências [2].

A superioridade do TRCA é atribuída, em parte, à sua capacidade de extrair componentes mais robustas mesmo em janelas de tempo curtas, sugerindo um melhor desempenho no regime transitório da resposta SSVEP. A hipótese inicial deste trabalho foi que o TRCA potencialmente captura melhor o sinal SSVEP nos estágios iniciais da resposta (regime transitório), devido à sua natureza estatística que maximiza a consistência do sinal entre ensaios (S_n). Postulou-se que esta métrica seria menos sensível a janelas curtas e ruidosas do que a correlação do CCA com um modelo sinusoidal fixo.

Para a análise comparativa, utilizamos o Benchmark Dataset de SSVEP [3, 1], que é amplamente empregado na literatura para avaliação de algoritmos [3]. Este dataset contém dados de 64 canais de EEG de 35 sujeitos (8 experientes e 27 ingênuos), gravados durante uma tarefa de seleção de estímulo guiada por um *speller* de 40 estímulos [3]. A frequência de amostragem do EEG é de 250 Hz [3]. Neste experimento, a análise foi restrita aos 9 eletrodos da região parieto-occipital, seguindo a metodologia proposta em [2].

A fase inicial da metodologia experimental consistiu em:

1. Implementação: Foram implementados o algoritmo CCA Supervisionado (sCCA) e o algoritmo TRCA padrão (sem a aplicação das extensões de Filter Bank e Ensemble). A escolha do sCCA, que também é *calibration-based*, foi feita para garantir uma comparação entre dois métodos supervisionados.
2. Aplicação: Ambos os algoritmos foram aplicados no Benchmark Dataset para comparar o desempenho na detecção de frequência em função do comprimento da janela, variando as janelas em incrementos de 100 ms, a partir de uma janela de 100 ms.
3. Comparação: A acurácia foi aferida utilizando um procedimento de validação cruzada, estabelecendo uma linha de base para a performance dos dois métodos em janelas curtas.

Um fator importante na extração de SSVEP em regimes transientes é o atraso de latência visual, que é o tempo entre o início do estímulo e o início da resposta SSVEP cortical [3]. O Benchmark Dataset possui uma latência média estimada de aproximadamente 136.91 ± 18.4 ms [3].

Para verificarmos se o TRCA é mais eficiente em capturar o componente transiente, realizamos um estudo de variação da latência visual. Os segmentos de EEG foram processados aplicando-se três atrasos distintos: 0 ms, 70 ms e 140 ms (correspondente à latência de referência do dataset [3]). Para cada valor de atraso testado, a acurácia foi calculada para janelas de tempo curtas e médias.

3. Resultados e Discussão

A performance dos algoritmos TRCA padrão (sem FB/Ensemble) e sCCA foi comparada em termos de acurácia de classificação em função do comprimento da janela. A análise foi conduzida sob três condições de latência de início: 0 ms, 70 ms e 140 ms.

Os resultados para as latências de 0 ms e 70 ms são apresentados nas Figuras 1 e 2, respectivamente. Em ambas as condições, o TRCA demonstrou uma acurácia superior à do sCCA em janelas de tempo mais curtas.

É relevante notar que o *benchmark dataset* inicia a janela de evocação da resposta SSVEP em 0,5 s (500

ms). Portanto, as três condições de latência testadas (0 ms, 70 ms e 140 ms) correspondem, no tempo absoluto do ensaio, a inícios de processamento em 0,50 s, 0,57 s e 0,64 s, respectivamente.




Figura 1: Comparação de Acurácia (TRCA vs. sCCA) com 0 ms (início em 0.5s) de latência.




Figura 2: Comparação de Acurácia (TRCA vs. sCCA) com 70 ms (início em 0.57s) de latência.

Em contrapartida, a Figura 3 ilustra o desempenho dos algoritmos utilizando a latência de 140 ms, valor de referência do *benchmark*. Nesta condição, o sCCA obteve uma performance superior ao TRCA na maioria das janelas analisadas.




Figura 3: Comparação de Acurácia (TRCA vs. sCCA) com 140 ms (início em 0.64s) de latência (Benchmark).

Este padrão de resultados oferece suporte à hipótese transitente, indicando que o TRCA é potencialmente mais robusto na captura dos componentes iniciais da resposta SSVEP (quando o atraso não é compensado), enquanto o sCCA depende do alinhamento temporal preciso (140 ms) com a resposta estabelecida para atingir seu desempenho ótimo.

4. Conclusão

Este trabalho investigou a hipótese de que o algoritmo TRCA possui maior robustez na captura de componentes transientes da resposta SSVEP em comparação com o sCCA. Para isso, foi realizada uma análise comparativa da acurácia em janelas de tempo curtas, variando a latência de início do processamento.

Os resultados obtidos dão suporte à hipótese inicial. O TRCA em condições de latência não compensada (0 ms e 70 ms), apresenta uma maior eficácia no regime transitório. Em contrapartida, o sCCA superou o TRCA apenas na condição de alinhamento temporal ideal (140 ms), sugerindo sua dependência de um modelo de resposta estabelecida e da correta compensação da latência visual.

A partir desta validação, os próximos passos da pesquisa focarão em duas frentes principais:

1. Análise Aprofundada do Ensemble TRCA: Será conduzida uma análise detalhada dos mecanismos internos do eTRCA, focando no processo de fusão, conforme sugerido na literatura [2].

2. Transferência de Técnicas: Com base na compreensão das propriedades estatísticas que conferem ao TRCA melhor desempenho transitente, a pesquisa explorará a possibilidade de propor modificações no algoritmo CCA para melhorar sua capacidade de capturar componentes SSVEP em janelas curtas, potencialmente integrando técnicas inspiradas na maximização da reprodutibilidade do TRCA.

Referências

- [1] A. Besharat, N. Samadzadehaghdam, and R. Afghan, “A Comparative Review of Detection Methods in SSVEP-Based Brain–Computer Interfaces,” *IEEE Access*, vol. 12, pp. 61 279–61 300, 2024.
- [2] 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, no. 1, pp. 104–112, 2018.
- [3] 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, no. 10, pp. 1746–1752, 2017.
- [4] H. Tanaka, T. Katura, and H. Sato, “Task-related component analysis for functional neuroimaging and application to near-infrared spectroscopy data,” *NeuroImage*, vol. 64, pp. 308–327, 2013.
- [5] —, “Task-related oxygenation and cerebral blood volume changes estimated from NIRS signals in motor and cognitive tasks,” *NeuroImage*, vol. 94, pp. 107–119, 2014.
- [6] 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. 53, no. 12, pp. 2610–2614, 2006.