

Pré-processamento com SVD para Interfaces Cérebro-Computador com paradigma SSVEP

Matheus C. Damasceno, Paula G. Rodrigues, Diogo C. Soriano e André K. Takahata

Resumo— Interfaces cérebro-computador são meios de comunicação capazes de gerar sinais de controle diretamente a partir de atividade cerebral. Neste estudo é apresentado o método de filtragem por Decomposição de Valores Singulares (SVD) para BCIs com paradigma SSVEP, como uma alternativa para a Média de Referência Comum (CAR), um método amplamente utilizado para esse tipo de aplicação.

Palavras-Chave— Processamento digital de sinais, interface cérebro-computador, reconhecimento de padrões.

Abstract— Brain-computer interfaces are systems capable of generating control signals directly from brain activity. This study presents a filtering method that uses Singular Value Decomposition (SVD) to BCIs with SSVEP paradigm as an alternative to the Common Average Reference, a widely used method to this type of application.

Keywords— Digital signal processing, brain-computer interface, pattern recognition.

I. INTRODUÇÃO

Interfaces cérebro-computador (*Brain-computer interfaces*, BCI) são meios de comunicação entre usuário e máquina que dispensam o uso do sistema nervoso periférico, obtendo as informações necessárias para executar um comando diretamente da atividade cerebral [1]. Dentre os paradigmas de BCI existentes, analisamos o baseado em potenciais visuais evocados em regime permanente (*Steady-State Visually Evoked Potentials*, SSVEP), que consiste na resposta cerebral que surge quando o usuário foca sua atenção em um estímulo visual repetitivo, observável como um sinal de mesma frequência no eletroencefalograma (EEG). Os comandos são associados a estímulos de diferentes frequências e o usuário os escolhe focando sua atenção no respectivo estímulo, sendo o algoritmo da BCI responsável por classificar corretamente o padrão SSVEP observado no EEG [2]. A partir da análise dos artefatos presentes no sinal de EEG, este trabalho teve como foco desenvolver técnicas de filtragem visando mitigar tais efeitos.

II. METODOLOGIA

Os estudos foram realizados de maneira *offline*, utilizando uma base de dados adquirida para a dissertação de mestrado [3], a partir de 15 indivíduos saudáveis com idade média de $27,4 \pm 7,5$ anos, sendo 5 homens e 10 mulheres, todos com visão normal ou corrigida. Foram utilizados estímulos

Matheus C. Damasceno, Paula G. Rodrigues, Diogo C. Soriano e André K. Takahata, Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas, Universidade Federal do ABC, Santo André/SP e Brazilian Institute of Neuroscience and Neurotechnology, e-mails: matheus.costa@aluno.ufabc.edu.br, {paula.rodrigues, diogo.soriano, andre.t}@ufabc.edu.br. Este trabalho foi parcialmente financiado pelo CNPq e FAPESP.

de 10, 11, 12 e 13 Hz e realizados 12 *trials* de 6 s para cada frequência, por indivíduo, que posteriormente foram redimensionados em janelas de 2 s. Os sinais foram obtidos por meio de 16 eletrodos secos, distribuídos pelo escalpo nas posições Oz, O2, O1, PO4, POz, PO3, P2, Pz, P1, CPz, C2, Cz, C1, FCz, CP2 e CP1, amplificados por um aparelho gUSBamp, com frequência de amostragem de 256 Hz, usando o processo mastoide como referência. Durante a coleta, foram utilizados filtros analógicos passa-faixa 5-60 Hz e rejeita-faixa 59-61 Hz.

A. Pré-processamento

A obtenção de dados de EEG a partir de uma referência comum está sujeita à interferências devido a ação de biopotenciais indesejados, tais como artefatos de ECG, EMG e piscadas [4]. A Média de Referência Comum (*Common Average Reference*, CAR) é um método de remoção de artefatos comuns aos os canais, que consiste em calcular a média de todos os canais e subtraí-la individualmente de cada canal [5], conforme (1)

$$\mathbf{X}_{CAR} = \mathbf{X} - \bar{\mathbf{x}} \mathbf{1}^t \quad (1)$$

sendo \mathbf{X} a matriz correspondente ao sinal original de tamanho $N_s \times N_C$ em que N_s é o número de amostras e N_C o número de canais, $\bar{\mathbf{x}} = \frac{1}{N_C} \sum_{i=1}^{N_C} \mathbf{x}_i$, sendo \mathbf{x}_i o vetor das amostras do i -ésimo canal e $\mathbf{1}$ o vetor de uns, de tamanho $N_C \times 1$, de modo que este método corresponde à subtração de uma matriz de posto unitário da matriz de sinal original. Assumindo que os artefatos, os sinais de interesse e o ruído são ortogonais, investigamos a possibilidade de realizar a separação de subespaços, de modo que $\mathbf{X} = \mathbf{X}_{art} + \mathbf{X}_{sinal} + \mathbf{X}_{ruído}$, sendo \mathbf{X}_{art} a componente com artefatos comuns, \mathbf{X}_{sinal} , sinais de interesse que possuem menor correlação entre os sensores se comparados com os artefatos, e $\mathbf{X}_{ruído}$, componentes espacialmente brancos. Como colocado em [6], uma forma de se fazer isso é por meio da Decomposição em Valores Singulares (*Singular Value Decomposition*, SVD), sendo $\mathbf{X} = \sum_{i=1}^{N_C} \sigma_i \mathbf{u}_i \mathbf{v}_i^t$ em que \mathbf{u}_i e \mathbf{v}_i são os vetores singulares à esquerda e direita respectivamente e σ_i são os valores singulares ordenados de modo que $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{N_C} \geq 0$, em que as parcelas relacionadas aos maiores valores singulares são relacionadas a componentes que possuem forte correlação entre os canais. Deste modo, investigamos os efeitos de se remover o primeiro e o último termos da somatória, de modo a obter a matriz de sinal com artefatos comuns e ruídos atenuados, partindo da hipótese de que os artefatos comuns estão presentes na componente de alta correlação, isto é, a primeira, e o ruído, na última. Observe que ao desconsiderar a influência da componente de ruído, não removendo-a, obtém-se o sinal

filtrado conforme (2), sendo $\mathbf{X}_{art} = \sigma_1 \mathbf{u}_1 \mathbf{v}_1^t$, semelhante à subtração de uma matriz de posto unitário no CAR.

$$\mathbf{X}_{SVD} = \mathbf{X} - \mathbf{X}_{art} \quad (2)$$

B. Extração de características

A Transformada Rápida de Fourier (*Fast Fourier Transform*, FFT) foi o método utilizado para obtenção das frequências utilizadas posteriormente para seleção de atributos. Neste estudo foram utilizadas as componentes fundamentais das frequências de estímulo e a segunda harmônica de cada uma.

C. Seleção de atributos

A seleção dos atributos foi baseada em *Wrappers*, que permite ao seletor de atributos considerar o classificador para selecionar os melhores atributos, por meio de uma busca gulosa. Na implementação realizada, o primeiro atributo foi o com maior pontuação no Índice Davies-Bouldin [7], e os demais, os que mais aumentaram a acurácia do classificador ao serem adicionados, sendo a ocorrência de 4 piores consecutivas o critério de parada. Os dados de treinamento e validação foram embaralhados para cada novo atributo selecionado, após observar que isso diminuía a presença de *overfitting* [8].

D. Classificação

Foi utilizado um classificador com uso de $K = 4$ funções discriminantes lineares na forma $g_k(\mathbf{a}_n) = \mathbf{w}_k^t \mathbf{a}_n$ em que $\mathbf{a}_n = [1 \ a_{n,1} \ a_{n,2} \ \dots \ a_{n,N_a}]$ é o vetor com os N_a atributos obtidos do n -ésimo *trial* e \mathbf{w}_k é o vetor de pesos de tamanho $N_a + 1 \times 1$ associado à k -ésima classe. Considerando a matriz $\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \mathbf{w}_3 \ \mathbf{w}_4]$, podemos obter os pesos pelo critério de mínimos quadrados [9] tal que $\mathbf{W} = \underset{\mathbf{W}}{\operatorname{argmin}} \|\mathbf{HW} - \mathbf{T}\|_F^2$, e, portanto, $\mathbf{W} = (\mathbf{H}^t \mathbf{H})^{-1} \mathbf{H}^t \mathbf{T}$, sendo \mathbf{H} uma matriz de tamanho $N_t \times N_a + 1$, obtida a partir dos dados de treinamento, cujas linhas correspondem a $\mathbf{a}_{n(i)}^t$, em que $n(i)$ é o *trial* associado à i -ésima linha, e a matriz \mathbf{T} de tamanho $N_t \times K$ em que $t_{ij} = 1$ se $j = n(i)$ e $t_{ij} = 0$, caso contrário. Para um novo vetor \mathbf{a}_n , calcula-se o $g_k(\mathbf{a}_n)$ para todas as classes e o resultado é designado para a classe cuja função atingiu o maior valor.

III. RESULTADOS

A utilização do SVD subtraindo as componentes com artefatos e ruído apresentou resultados semelhantes ao remover somente as com artefatos, enquanto a remoção somente do ruído apresentou resultados semelhantes à não utilização de filtro, conforme Tabela I, o que indica que os artefatos comuns são os que mais interferem no sinal de EEG. Comparando a acurácia do classificador por meio do teste t de 2 amostras com nível de significância 0,05 [10] não se observou diferença significativa comparando o pré-processamento com uso do SVD_A em relação ao CAR.

As acurácias médias também não evidenciaram diferenças significativas entre os dois métodos e apresentaram desempenho superior à não utilização de filtros. Comparando as componentes removidas do sinal para ambos os métodos, observou-se uma correlação média de 0,9506, que valida a hipótese, nos dados observados, dos artefatos pertencerem ao subespaço ligado ao maior valor singular, conforme Fig. 1.

TABELA I

ACURÁCIA DO CLASSIFICADOR DE ACORDO COM O FILTRO UTILIZADO. **NF** – Sem filtro, **SVD_R** – sem a componente ruído, **SVD_{AR}** – sem as componentes artefato e ruído, **SVD_A** – sem a componente artefato.

NF	SVD _R	SVD _{AR}	SVD _A	CAR
84,8 ± 3,8	84,4 ± 3,9	92,1 ± 2,6	93,4 ± 2,2	93,8 ± 1,7




Fig. 1. Comparativo das componentes removidas, isto é, a média \bar{x} do CAR e a primeira coluna do \mathbf{X}_{art} obtido com o SVD_A para um dos trials.

IV. CONCLUSÕES

Foi possível confirmar a eficácia do SVD como método de pré-processamento, tendo em vista o fato deste ter reproduzido de forma compatível os resultados obtidos com o CAR, um método de filtragem comum na literatura para filtragem de dados de BCI. Uma vantagem está nas possibilidades em aplicá-lo, uma vez que a utilização do CAR está restrita à média simples dos canais, enquanto o SVD oferece mais liberdade na atribuição de pesos para cada componente, o que possivelmente o torna uma poderosa ferramenta para este tipo de aplicação, o que será abordado em trabalhos futuros.

AGRADECIMENTOS

Agradecemos às agências de fomento pelos financiamentos grant CNPq 305616/2016-1, grant BRAINN/FAPESP 2013/07559-3, grant FINEP 01.16.0067.00 e PIBIC/CNPq.

REFERÊNCIAS

- [1] D. S. Tan e A. Nijholt. *Brain-Computer Interfaces: Applying our Minds to Human-Computer Interaction*. Springer London, 2010.
- [2] O. Falzon, K. Camilleri e J. Muscat. Complex-Valued Spatial Filters for SSVEP-Based BCIs With Phase Coding. *IEEE Transactions on Biomedical Engineering*, **59**(9), 2486–2495, 2012.
- [3] J. I. Silva Junior. *Comparativo de desempenho de sistemas BCI-SSVEP off-line e em tempo de execução utilizando técnicas de estimação de espectro e análise de correlação canônica*. Universidade Federal do ABC, Programa de Pós-Graduação em Engenharia Biomédica, 2017.
- [4] D. J. McFarland, L. M. McCane, S. V. David e J. R. Wolpaw. Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, **103**(3), 386-394, 1997.
- [5] S. N. Carvalho, et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, **21**(ago), 34-42, 2015.
- [6] V. D. Vrabie, J. I. Mars, J.-L. Lacoume. Modified singular value decomposition by means of independent component analysis. *Signal Processing* **84**, 645-652, 2004.
- [7] D. Davies e D. W. Bouldin. A cluster separation measure. *IEEE transactions on pattern analysis and machine intelligence*, (2), 224-227, 1979.
- [8] R. Kohavi e G. H. John. Wrappers for feature subset selection. *Artificial Intelligence*, **97**, 273-324, 1997.
- [9] C. M. Bishop. *Pattern recognition and machine learning*. Springer, 2006.
- [10] M. Pagano e K. Gauvreau. *Princípios de Bioestatística*, 2 ed. Cengage Learning, 2017.