

Aplicação da Análise de Correlação Canônica em Sistemas ICM Baseados em SSVEP

Sávio M. Sousa¹, Fablena K. N. Dias ², Cleison D. Silva¹

¹Faculdade de Engenharia Elétrica – Universidade Federal do Pará (UFPA)
CEP 68455-901 – Tucuruí – PA – Brasil

²Faculdade de Engenharia de Computação – Universidade Federal do Pará (UFPA)
CEP 68455-901 – Tucuruí – PA – Brasil

{savio.sousa, fablena.dias }@tucuruui.ufpa.br, cleison@ufpa.br

Abstract. *Brain-Computer Interface (BCI) systems are capable of performing communications between humans and machines through electroencephalogram (EEG) signals that are processed and converted into commands. The focus of this scientific research is on the study of information extraction and processing techniques using the Canonical Correlation Analysis (CCA) method for optimizing ICM systems based on Steady State Visually Evoked Potential (SSVEP). In this research, five approaches were performed using the CCA method, maintaining the same process of data acquisition, pre-processing and classification. In the end, the accuracy of the classifier was used as a parameter for discussions and conclusions.*

Resumo. *Sistemas de Interface Cérebro-Máquina (ICM) são capazes de realizar comunicações entre seres humanos e máquinas através de sinais de eletroencefalograma (EEG) que são processados e convertidos em comandos. O foco desta pesquisa científica está no estudo de técnicas de extração e processamento de informação utilizando o método de Análise de Correlação Canônica (CCA) para otimização de sistemas ICM baseado em Potencial Evocado Visualmente em Estado Estável (SSVEP). Nesta pesquisa foi realizado cinco abordagens utilizando o método CCA mantendo o mesmo processo de aquisição de dados, pré-processamento e classificação. Ao final, a acurácia do classificador foi utilizada como parâmetro para discussões e conclusões.*

1. Introdução

Em sistemas ICM baseados em SSVEP, a frequência do estímulo visual ao qual uma pessoa mantém o olhar atento está ligada a uma resposta potencial contínua no córtex cerebral [1]. Eletrodos coletam essa resposta, representada como um sinal de eletroencefalograma (EEG), e processam para se transformar em um sinal de controle. As etapas de uma ICM baseada em SSVEP são divididas em: Aquisição de sinais, pré-processamento, extração de características, classificação e aplicação.

A extração e classificação dos sinais são as partes mais importantes do processo. Para auxiliar esses processos, o método de Análise de Correlação Canônica (CCA) é bastante utilizado. Esse método aplicado em SSVEP usa sinais genéricos como referência e maximiza a correlação entre eles [1].

Cabe a este trabalho implementar o método CCA a fim de facilitar a classificação de sinais de EEG observando a acurácia do classificador. A capacidade do método CCA de capturar as complexas interações entre os sinais de EEG e os estímulos motiva o uso do método.

2. Métodos

Utilizou-se de dados de um repositório¹ de domínio público que incluem sinais de EEG de quatro sujeitos, coletados em três estímulos de SSVEP com frequências 8 Hz, 14 Hz e 28 Hz [2]. Foram escolhidos três canais da região occipital [1]. Cada sinal foi filtrado em faixas de bandas centradas nas respectivas frequências e segmentado em 75 períodos de tempo (época) de 1 segundo [3].

O método CCA busca matrizes de peso w_x e w_y que maximizam a correlação entre conjuntos de dados X e Y ao resolver a equação:

$$\max_{w_x, w_y}(\rho) = \frac{w_x^T X Y^T w_y}{\sqrt{w_x^T X X^T w_x w_y^T Y Y^T w_y}} \quad (1)$$

Onde ρ representa o coeficiente de correlação e o sobrescrito T a transposta da matriz. O resultado é um vetor com informações ponderadas de cada conjunto [4]. Aplicando a sistemas ICM baseados em SSVEP, X representa os sinais de EEG filtrados e Y um conjunto de senos e cossenos em cada frequência e de mesma dimensão que X . Dessa forma espera-se que haja uma correlação mais forte entre os sinais de mesma frequência.

Todas as abordagens utilizam o método CCA disponível na biblioteca `sklearn.cross_decomposition.CCA`² da linguagem de programação Python para averiguar a dinâmica dos dados com o método CCA. Em cada abordagem, manteve-se o mesmo processo de aquisição de dados, pré-processamento e classificação, variando apenas a forma como os dados são entregues as funções do CCA.

Abordagem A – Definição de um modelo CCA para cada sinal em cada época. Entrega de informações para as funções em relação a frequência de estímulo, ou seja, os sinais de mesma frequência estímulo, mas filtrados em diferentes bandas são entregues as funções correspondentes as frequências de estímulo.

Abordagem B – Definição de um modelo CCA para cada sinal a partir da primeira época. Entrega de informações para as funções em relação a frequência de estímulo.

Abordagem C – Definição de um modelo para cada sinal filtrado em sua respectiva banda de frequência a partir da primeira época. Entrega de informações para as funções em relação a banda de frequência, ou seja, os sinais filtrados na mesma banda são entregues as funções correspondentes as bandas.

¹ http://www.bakardjian.com/work/ssvep_data Bakardjian.html

² https://scikit-learn.org/stable/modules/generated/sklearn.cross_decomposition.CCA.html#sklearn.cross_decomposition.CCA.transform

Abordagem D – Definição de um modelo para cada sinal filtrado em sua respectiva banda de frequência a partir de uma média de todas as épocas. Entrega de informações para as funções em relação a banda de frequência.

Abordagem E – Definição de um modelo para cada sinal filtrado em sua respectiva banda de frequência a partir de uma média de todas as épocas. Entrega de informações para as funções em relação a frequência de estímulo.

A densidade espectral de potência (PSD) de um sinal pode ser calculada usando o periodograma, o que tem permitido a realização de várias análises baseadas em sinais de EEG [5]. Ao agregar o PSD ao CCA, é possível maximizar a obtenção de informações precisas sobre a distribuição de energia em várias faixas de frequências.

Para realizar a classificação dos sinais, são realizadas três combinações binárias entre as frequências para a criação das matrizes de características. Para classificar cada par de sinais foi utilizado a Análise do Discriminante Linear (LDA), método usado para encontrar uma combinação linear de características que caracterizam ou separam duas ou mais classes de objetos ou eventos [6].

3. Resultados

Com base no conjunto de dados e nos métodos usados neste trabalho, observou-se a acurácia do classificador como métrica para análise do desempenho de cada abordagem do método CCA desenvolvido. No Quadro 1 se encontra as acurácias de cada sujeito para cada combinação de frequência resultantes das abordagens.

Quadro 1: Acurácias de cada sujeito (Sj) de todas as abordagens.

		1º Par			2º Par			3º Par		
		8 Hz	14 Hz	Total	8 Hz	28 Hz	Total	14 Hz	8 Hz	Total
Abordagem A	Sj. 1	84%	20%	52%	92%	28%	60%	68%	16%	42%
	Sj. 2	44%	64%	54%	84%	40%	62%	64%	44%	54%
	Sj. 3	96%	72%	84%	92%	84%	88%	84%	56%	70%
	Sj. 4	75%	28%	52%	84%	44%	64%	60%	76%	68%
Abordagem B	Sj. 1	80%	100%	92%	96%	80%	88%	100%	80%	90%
	Sj. 2	100%	88%	94%	92%	44%	68%	56%	96%	76%
	Sj. 3	76%	100%	88%	76%	100%	88%	64%	92%	78%
	Sj. 4	72%	96%	84%	84%	100%	92%	96%	44%	70%
Abordagem C	Sj. 1	84%	88%	86%	80%	96%	88%	24%	92%	58%
	Sj. 2	100%	4%	82%	80%	40%	60%	88%	68%	78%
	Sj. 3	100%	92%	96%	76%	92%	84%	92%	100%	96%
	Sj. 4	80%	36%	56%	76%	68%	72%	84%	64%	74%

Abordagem D	Sj. 1	36%	40%	38%	76%	32%	54%	68%	72%	70%
	Sj. 2	55%	64%	58%	44%	92%	68%	56%	44%	50%
	Sj. 3	56%	48%	52%	48%	76%	62%	44%	96%	70%
	Sj. 4	48%	72%	60%	72%	56%	64%	60%	48%	54%
Abordagem E	Sj. 1	100%	76%	88%	100%	92%	96%	100%	76%	88%
	Sj. 2	64%	92%	78%	100%	100%	100%	100%	96%	98%
	Sj. 3	100%	80%	90%	100%	60%	80%	96%	48%	72%
	Sj. 4	88%	64%	76%	100%	88%	94%	100%	92%	96%

4. Considerações finais

Em todas as abordagens, é evidente que a seleção de cada parâmetro do sistema tem um impacto direto nos resultados. A escolha de cada canal deve ser cuidadosamente considerada para extrair as informações mais relevantes para o tipo de ICM utilizado. Além disso, notou-se que os resultados variam entre os indivíduos devido às diferentes respostas cerebrais aos estímulos em cada pessoa. Com os resultados dispostos, conclui-se que a abordagem E apresenta o melhor desempenho, sendo o segundo par o mais propício para aplicação.

Referências

- [1] MA, Pengfei et al. A classification algorithm of an SSVEP brain-Computer interface based on CCA fusion wavelet coefficients. *Journal of Neuroscience Methods*, v. 371, p. 109502, 2022.
- [2] H. Bakardjian, T. Tanaka, and A. Cichocki. “Optimization of SSVEP brain responses with application to eight-command Brain-Computer Interface”. In: *Neuroscience Letters* 469.1 (2010), pp. 34–38. doi: 10.1016/j.neulet.2009.11.039.
- [3] C. S. Nam, A. Nijholt, and F. Lotte, *Brain-Computer Interfaces Handbook: Technological and Theoretical Advances*. CRC Press, 2018.
- [4] BROGIN, João Angelo Ferres. *Generalização da técnica de correlação canônica para aplicações em interface cérebro-máquina*. 2018.
- [5] Mohammad Samin Nur et al. CHOWDHURY. “Deep neural network for visual stimulus-based reaction time estimation using the periodogram of single-trial eeg”. In: *Sensors* 20.21 (2020), p. 6090.
- [6] REZENDE, Ana Cláudia Barbosa; LOPES FILHO, Gilberto; VIEIRA, Flávio Henrique Teles. *Aplicação da Análise Discriminante Linear (LDA) para Classificação de Sinais Eletromiográficos (EMG) de Movimentos da Mão*. In: *Anais da VII Escola Regional de Informática de Goiás*. SBC, 2019. p. 351-360.