

Interface Cérebro-Máquina baseada em SSVEP: Análise de Extração de Época

Fablana K. N. Dias¹, Sávio M. Sousa², Cleison D. Silva²

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

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

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

Resumo. *O trabalho apresenta os resultados da análise comparativa da extração de épocas com tamanhos diferentes de sinais de eletroencefalograma (EEG) de sistema Interface Cérebro-Máquina na presença de três estímulos. O objetivo geral é analisar o desempenho de classificação de um sistema ICM-SSVEP ao processar sinais de EEG com diferentes durações de épocas, o sistema é ajustado para classificação binária usando Análise do Discriminante Linear para cada duração e combinação de frequências (8Hz×14Hz, 8Hz×28Hz e 14Hz×28Hz), apresentando as acurácias detalhadas para cada análise.*

1. Introdução

As Interfaces Cérebro-Máquina (ICM) são sistemas artificiais que proporcionam uma comunicação direta entre o cérebro e uma máquina, permitindo que pessoas com distúrbios motores ou sensoriais possam controlar dispositivos externos ao corpo humano [1]. As etapas de uma ICM são divididas em: Aquisição de sinais, processamento, classificação e aplicação.

O *Steady State Visual Evoked Potential* (SSVEP) é uma resposta gerada pela atividade neural em reação a um estímulo visual de frequência constante [2]. Esse fenômeno ocorre na região do lobo occipital, que é responsável pela percepção visual. Quando o usuário focaliza o olhar em uma frequência de estímulo permanente, é possível observar um aumento da atividade cerebral na mesma frequência e harmônicos, na região do córtex visual [2]. Um dos métodos utilizados para capturar os sinais cerebrais é o Eletroencefalograma (EEG) que consiste em uma técnica de neuroimagem, não invasiva, onde os sinais elétricos são coletados por eletrodos em contato com couro cabeludo [3].

Na literatura sobre a extração de épocas, algumas pesquisas utilizam épocas de estímulos com duração fixa de 2 ou 3 segundos [4], [5]. Outras buscam relacionar a acurácia da classificação dos sinais com a variação da duração das épocas, variando de 1 a 3 segundos [6], [7]. Por possuir mais informações, é comum optar por épocas com maior duração, no entanto épocas com duração menores que 2 segundos possuem vantagens em relação a agilidade de resposta ao sistema. Nesse sentido, o objetivo deste trabalho é realizar um estudo comparativo para analisar o desempenho de classificação de um sistema ICM-SSVEP ao processar sinais de EEG com duração de épocas de tempo iguais e inferiores a 2s.

2. Materiais e Métodos

2.1. Aquisição de sinal

Nessa etapa é utilizado um conjunto público contendo sinais de EEG adquiridos durante a presença de três estímulos visuais com frequências: 8 Hz, 14Hz e 28Hz [4]. O repositório¹ contém EEG de quatro sujeitos, com cinco ensaios por indivíduo para cada frequência de SSVEP. Para o trabalho, o sinal de EEG do eletrodo Oz é selecionado, pois ele está posicionado sobre o lobo occipital, relacionado ao processamento visual. Ao analisar a variação da energia, desta região, é possível discernir entre olhos abertos/fechados, concentrado/relaxado e estímulo luminoso de frequência conhecida [8].

2.2. Processamento dos sinais de EEG

Essa fase garante a qualidade dos resultados, uma vez que, ao coletar o sinal de EEG é comum a presença de ruídos. Os estímulos visuais, SSVEP, tendem a modular a atividade elétrica cerebral na mesma frequência do estímulo, desta forma, a detecção de estímulos na frequência F_0 pode ser realizada filtrando os sinais de EEG numa banda de frequência centrada em torno de F_0 . Para realçar e preservar as informações espectrais entorno do estímulo é comum utilizar filtros passa-banda. Os filtros necessitam de parâmetros que definem a banda de frequências de interesse, como o intervalo $\Delta f = [F_l, F_u]$, onde F_l e F_u representam as frequências de corte inferior e superior em Hertz, respectivamente [3]. Filtros passa-banda *butterworth* de 5ª ordem são utilizados para selecionar as frequências compendiadas por Δf .

Após a filtragem do sinal de EEG e a redução dos elementos ruidosos, proporcionando uma representação mais clara e precisa do sinal, a aplicação de técnicas de extração de características de sinais de EEG permitem obter informações mais confiáveis e relevantes para a etapa de classificação. Para isso, é necessário dividir os dados em épocas de tempo para análise. Segundo a descrição do *dataset* [4], o período de estimulação se define em 15 segundos para cada ensaio. A Figura 1 mostra os sinais de EEG que são segmentados em 5 épocas para cada frequência: 125ms, 250ms, 500ms, 1s e 2s. O *dataset* contém cinco ensaios, isso implica dizer que cada época será multiplicada pela quantidade de ensaios para obter mais informações.

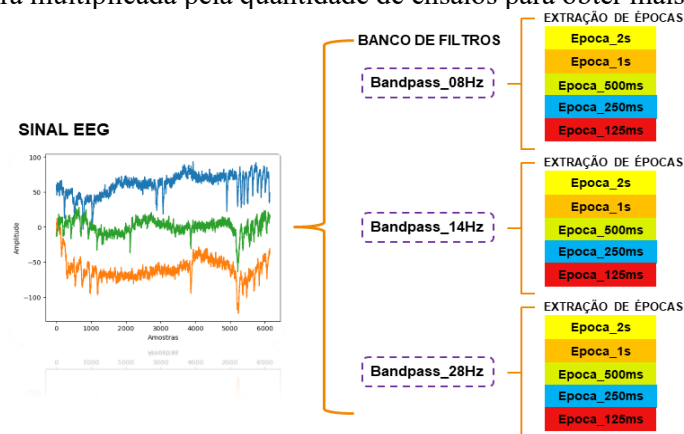


Figura 1: O sinal bruto passa por um banco de filtro e é dividido em épocas de tempo, representadas em diferentes bandas de frequência.

A partir da extração de épocas, aplica-se o periodograma que estima a densidade espectral de um sinal. Isso revela as relações entre a amplitude e a frequência do sinal, sendo uma técnica

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

amplamente utilizada em diversas análises baseadas em EEG [9]. Para calcular o periodograma do sinal de EEG discreto filtrado $x[n]$, faz-se uso da equação:

$$\hat{P}(k) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}nk} \right|^2, \forall k = 0, 1, \dots, N-1 \quad (1)$$

\hat{P} representa o periodograma, k é o ordinal no domínio da frequência, n é o ordinal no domínio do tempo discreto, o comprimento da sequência a ser transformada é descrito por N [9].

2.3. Classificação

Para realizar a classificação dos dados foram separados em 70% para treinamento e 30% para teste. São realizadas três combinações binárias entre as frequências para a criação das matrizes de características, que são aplicadas no classificador: 8Hz e 14Hz; 8Hz e 28Hz; e 14Hz e 28Hz. É crucial enfatizar que cada combinação é aplicada para a mesma época.

Por possuir estrutura simples, desempenho competitivo e treinamento eficiente, os classificadores lineares são um dos algoritmos mais populares usados para projetar sistemas de ICM [3], sendo capazes de separar duas classes de exemplos e de determinar a classe de um sinal de entrada, representado por:

$$Y = w^T X, \quad (2)$$

onde Y é a saída do classificador, o símbolo T indica a transposição de w que é o vetor de pesos do classificador determinado durante o treinamento do modelo é X e a matriz de características extraídas do sinal filtrado de entrada [10], sendo $X = \sum_k [\hat{P}_1(k), \hat{P}_2(k), \hat{P}_3(k)]^T$.

3. Resultados

O relatório de classificação é um importante recurso para análise de dados, uma métrica que oferece informações mais detalhadas do desempenho de classificação e da matriz de confusão [3]. Neste estudo, são geradas matrizes de confusão a fim de obter detalhes da acurácia para cada sujeito disponíveis no *dataset*, para cada janelas de tempo e combinação de frequências.

Tabela 1: Acurácia de todas as épocas, todos os voluntários e todas as combinações.

Voluntários	Épocas	8Hz × 14Hz	8Hz × 28Hz	14Hz × 28Hz
Sujeito 1	2s	90%	90%	70%
	1s	96%	72%	80%
	500ms	95.5%	57.7%	71.1%
	250ms	90%	51.1%	60%
	125ms	90.5%	51.1%	61.6%
Sujeito 2	2s	100%	80%	70%
	1s	96%	72%	68%
	500ms	97.7%	71.1%	62.2%
	250ms	96.6%	70%	56.6%
	125ms	96.6%	65%	55.5%
Sujeito 3	2s	50%	90%	60%
	1s	52%	88%	68%
	500ms	44.4%	77.7%	55.5%
	250ms	40%	81.1%	58.8%
	125ms	39.4%	80%	53.8%
Sujeito 4	2s	50%	50%	20%
	1s	48%	52%	20%
	500ms	42.2%	51.1%	28.8%
	250ms	35.5%	50%	31.1%
	125ms	38.3%	52.7%	28.8%

No desempenho do LDA combinado para 8Hz e de 14Hz, os sujeitos 1 e 2 mostram acurácia maior de 90% para 8Hz em épocas menores e iguais a 2s, porém, para 14Hz, eles tiveram 51,1% e 72% em épocas menores que 1s e 80-90% em 2s; sujeitos 3 e 4 tiveram baixa acurácia. Na combinação 8Hz e 28Hz, sujeitos 1 e 3 foram notáveis em todas as épocas para a frequência de 28Hz, sendo que o sujeito 3 alcançou acurácia maior que 98.8%. Para 14Hz e 28Hz, os sujeitos 1, 2 e 3 possuem desempenho variando entre 90% e 100%, sendo que o sujeito 3 apenas não obtém 100% de desempenho para a época de 125ms.

4. Considerações finais

O trabalho realiza a análise comparativa de cinco épocas de sinais de EEG com duração diferente para cada um dos sujeitos e estímulos disponibilizados no conjunto de dados. Destaca-se que quanto maior da duração da época maior tende a ser a acurácia de classificação do sistema ICM-SSVEP. A utilização de épocas com menor duração, como as épocas de 125ms ou 250ms podem proporcionar maior quantidade de comandos gerados pelo sistema ICM-SSVEP por unidade tempo. No entanto, segundo a análise comparativa, a taxa de erro de classificação também é aumentada. Indicando que se deve realizar um ajuste para selecionar a duração adequada da época a ser adotada para a aplicação de interesse.

References

- [1] J. P. G. Souza et al. “Interface Cérebro-Máquina (ICM): Da transdução do estímulo externo em impulso nervoso a tradução em comandos digitais”. In: Caderno De Graduação - Ciências Biológicas e da Saúde - UNIT/AL 3 (2015), pp. 139–152.
- [2] G. Garcia-Molina and D. Zhu. “Optimal spatial filtering for the steady state visual evoked potential: BCI application”. In: 5th International IEEE/EMBS Conference on Neural Engineering (2011). doi: 10.1109/ner.2011.5910512.
- [3] V. M. Vilas Boas. “AutoBCI: interface cérebro-máquina com configuração hiper-paramétrica automatizada”. In: (2021). Orientador: Cleison Daniel Silva; Coorientador: Otavio Noura Teixeira. url: <http://repositorio.ufpa.br/jspui/handle/2011/13211>.
- [4] 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.
- [5] Sarah N. et al. CARVALHO. “Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs.” In: Biomedical Signal Processing and Control 21 (2015), pp. 34–42.
- [6] Henrique Luiz Voni et al GIULIANI. “Influência da Janela de Estimação no Desempenho de Classificação em Sistemas BCI-SSVEP.” In: SIMPOSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS 39 (2021).
- [7] Pengfei et al. MA. “A classification algorithm of an SSVEP brain-Computer interface based on CCA fusion wavelet coefficients.” In: Journal of Neuroscience Methods 371 (2022), p. 109502.
- [8] L. Bueno. “A Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas”. In: (2017).
- [9] 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.
- [10] J. J. et al. BELMIR JR. “Análise do Potencial Evocado Visualmente em Sinais Cerebrais para Implementação de BCIs.” In: ~ Brazilian Technology Symposium (2016).