

Pré-processamento e Classificação de Sinais Para Interfaces Cérebro-Máquina

Lucas Prado Santos, André Kazuo Takahata

Resumo — Estudo sobre interface-cérebro computador (BCI) com uso do paradigma SSVEP (Potencial Evocado Visual de Regime Permanente) por meio da caracterização de resposta à estímulos visuais repetitivos. Foi feita a análise de sinais de eletroencefalograma (EEG) pré-adquiridos e comparados métodos de filtragem espacial, CAR e Laplaciano Curto, e classificadores com os métodos de mínimos quadrados (LS) e mínima distância do centroide. Foram realizados testes de validação pelo método *hold-out* com Monte Carlo.

Palavras-Chave— BCI, SSVEP, Interface cérebro-máquina.

Abstract — In this work, we present a study of Brain-computer interface (BCI) using the steady state visual evoked potential (SSVEP) paradigm through the characterization of neural responses of repetitive visual stimuli. Pre-acquired electroencephalogram (EEG) signals were analysed and spatial filtering methods, CAR and Short Laplacian, and classifiers based on Least Squares (LS) method and minimum centroid distance, were compared. Validation tests were conducted using the hold-out method with Monte Carlo.

Keywords— BCI, SSVEP, Brain-computer Interface.

I. INTRODUÇÃO

Interface cérebro-máquina (BCI) é um sistema que tem como objetivo prover ao usuário a capacidade de comunicação com dispositivos utilizando somente a sua atividade cerebral. Para isso, há necessidade da utilização de um método que processe e classifique os sinais gerados pelo cérebro, para que dessa forma seja possível identificar comandos desejados pelo usuário [1]. Neste projeto foram utilizados sinais de eletroencefalograma (EEG) utilizando o paradigma de potenciais evocados visuais em regime permanente (SSVEP), que consiste em uma resposta cerebral à estímulos visuais com mesma frequência do estímulo ao qual o usuário foca sua atenção [2]. Assim, nesse paradigma de BCI são atribuídos comandos específicos para estímulos visuais em diferentes frequências e por meio de um algoritmo classificador busca-se determinar o comando desejado por meio da resposta do EEG quando o usuário foca sua atenção no estímulo visual correspondente.

II. MATERIAIS E MÉTODOS

Foi utilizada a base de dados de sinais SSVEP-EEG pré-adquiridos em [3]. A base contém 12 ensaios (*trials*) para as frequências de estímulo de 10 Hz, 11 Hz, 12 Hz e 13 Hz, sendo 48 ensaios para cada sujeito. Frequências na faixa de 0,5 Hz até 30 Hz são conhecidas na literatura pela boa relação sinal ruído [2]. A coleta de dados foi feita com 15 sujeitos, 5 homens e 10 mulheres, com idade média de $27,40 \pm 7,5$. Foi solicitado aos indivíduos que focassem a atenção, durante 6 segundos, em uma

interface com quadrados oscilando nas frequências de estímulo em um monitor com taxa de atualização de 60 Hz. Os sinais cerebrais foram captados utilizando uma touca com 16 eletrodos secos posicionados de acordo com a Figura 1 e amplificados por um aparelho gUSBamp, com taxa de amostragem de 256 Hz.




Fig. 1. Distribuição dos eletrodos utilizados na aquisição [3].

A. Pré-processamento

Na captação de sinais EEG, usualmente há artefatos gerados por atividade cardíaca, movimentação das conexões dos eletrodos, movimento dos olhos, atividade muscular, entre outros. Uma técnica robusta e simples para realizar a mitigação de artefatos é a filtragem espacial por *Common Average Reference* (CAR) [4]. Em que é subtraído de cada canal o valor da média global dos canais, tal que $V_i^{CAR} = V_i^{ER} - \frac{1}{n} \sum_{j=1}^n V_j^{ER}$, onde V_j^{ER} representa o potencial do j -ésimo eletrodo e n o número de eletrodos. Desse modo, busca-se eliminar artefatos comuns a todos os eletrodos. Outro método de filtragem espacial utilizado foi o Laplaciano Curto (SL) [5]. O laplaciano pode ser definido como em (1), onde $V(r)$ é o potencial em um determinado ponto r do escalpo, definido pelo plano x e y , que está relacionado com a atividade cerebral local e prevê uma medida independente do eletrodo de referência [6]. Neste trabalho estimamos este valor com o uso do método de diferenças finitas exposto em [6].

$$Lap_s(V(r)) \equiv \frac{\partial^2 V}{\partial x^2} + \frac{\partial^2 V}{\partial y^2} \quad (1)$$

B. Extração de Características e Seleção de canais

Dado um *trial*, a extração de características foi realizada calculando-se a Transformada Rápida de Fourier (FFT) para o sinal de cada canal. Em seguida, foram obtidas as amplitudes relativas às componentes dos estímulos de interesse para cada canal e descartado manualmente os canais FCz, C1, CPz, CP2, PO3, O1, Oz e O2 em que a resposta de SSVEP foi baixa em todas as ocasiões.

C. Método de validação

Foi utilizado o método de validação *hold-out* com Monte Carlo. Em que uma seção aleatória de 20% do *dataset* foi selecionado como conjunto de teste e o restante como conjunto de treino. Foram realizados 100 vezes o processo de embaralhamento e treino e teste, obtendo-se então a acurácia média.

D. Classificadores

Os testes foram realizados com objetivo de distinguir 4 classes, correspondentes à 10 Hz, 11 Hz, 12 Hz e 13 Hz e 2 classes,

correspondentes à estímulos de 10 Hz e 13 Hz, para testar uma versão simplificada do problema, assumindo que as classes são mais separadas. Foram utilizados dois métodos de classificação, um baseado na mínima distância em relação aos centroides de cada classe [7] e o outro utilizando funções discriminantes obtidas pelo método de mínimos quadrados (LS) [8]. Dado um *trial*, são calculadas as médias das amplitudes das frequências de estímulo entre os canais obtendo um vetor de características de tamanho $1 \times N_f$ onde N_f é o número de classes. No primeiro classificador, o centroide dos dados do conjunto de treinamento no espaço de *features* é obtido para cada classe. A partir disso, um vetor de *features* de um *trial* qualquer é classificado como sendo correspondente à classe cujo centroide apresenta a menor distância. O segundo classificador compara C funções discriminantes lineares, $g_c(\mathbf{x}_t) = \mathbf{w}_c^t \mathbf{x}_t$, em que C é o número de classes, $\mathbf{x}_t = [1, x_{1,t}, \dots, x_{N_f,t}]^T$ é o vetor com N_f características retiradas do t -ésimo *trial* e \mathbf{w}_c o vetor de pesos com tamanho $(N_f + 1) \times 1$ da c -ésima classe obtido por meio do método dos mínimos quadrados. Para cada novo vetor \mathbf{x}_t , é calculado $g_c(\mathbf{x}_t)$ para as C classes e o resultado da estimação é dado pela classe com maior valor.

III. RESULTADOS

A Tabela I mostra a acurácia média para todas as combinações de filtros espaciais e classificadores no cenário de duas classes, 10 Hz e 13 Hz.

TABELA I. ACURÁCIA MÉDIA PERCENTUAL PARA CADA SUJEITO, PARA AS CLASSES DE 10 HZ E 13 HZ.

Sujeitos	Acurácia			
	CAR—Centroide	CAR—LS	Laplaciano—Centroide	Laplaciano—LS
1	94,8	98,6	66,4	91,8
2	89,2	75,4	56,2	36,4
3	86,6	89,8	81,2	80,4
4	96,2	96,6	95,4	99,8
5	99,0	100,0	100,0	100,0
6	87,2	79,8	92,6	86,2
7	70,8	43,0	79,4	76,8
8	100,0	98,6	100,0	99,4
9	85,6	86,8	83,0	78,8
10	96,4	93,2	73,2	47,2
11	95,6	92,8	93,4	88,4
12	95,8	92,8	90,2	87,6
13	94,8	96,2	93,0	87,0
14	100,0	100,0	100,0	98,0
15	94,6	100,0	71,0	77,2
Média ± Desvio Padrão	92 ± 2	90 ± 4	85 ± 4	82 ± 5

Em média, os métodos testados utilizando filtro CAR e Laplaciano apresentaram acurácia aproximada de 90% e 80%, respectivamente. Para quatro frequências é possível observar na Tabela II que a acurácia apresenta valores maiores de desvio, similar a separação de duas classes o filtro CAR e Laplaciano obtiveram acurácia média de aproximadamente 80% e 70%, respectivamente.

TABELA II. ACURÁCIA MÉDIA PERCENTUAL PARA CADA SUJEITO, PARA AS CLASSES DE 10 HZ, 11 HZ, 12 HZ E 13 HZ.

Sujeitos	Acurácia			
	CAR—Centroide	CAR—LS	Laplaciano—Centroide	Laplaciano—LS
1	89,5	95,0	68,3	82,6
2	64,7	52,7	39,1	24,1
3	67,4	73,8	71,5	66,2
4	95,1	97,4	93,4	94,9
5	96,0	98,7	90,6	93,2
6	74,1	73,1	71,3	65,6
7	41,5	26,1	75,9	60,1
8	100,0	99,7	99,9	100,0
9	62,8	67,7	42,7	41,1
10	86,6	84,2	52,1	47,0
11	96,4	96,3	79,4	75,5
12	90,1	85,3	86,0	84,9
13	81,1	74,2	77,1	63,6
14	100,0	100,0	96,3	96,1
15	98,2	99,0	52,6	34,2
Média ± Desvio Padrão	83 ± 5	82 ± 6	73 ± 5	69 ± 6

Houve sujeitos em que todos os métodos utilizados se mostraram abaixo das médias, como no caso dos Sujeitos 2, 3 e 9 na Tabela I e Tabela II, mostrando que o sucesso dos métodos depende também das condições das respostas observadas em cada indivíduo. Toda a computação foi realizada no software Octave em um processador Intel Core i5-7200U. O tempo de processamento do classificador por centroide para cada um dos sujeitos é de aproximadamente 60 ms e 170 ms para duas e quatro classes, respectivamente. Para o classificador por LS o tempo de processamento aumenta 9 e 13 vezes para duas e quatro classes, respectivamente. O filtro CAR apresentou tempo de processamento em torno de 37 ms enquanto o Laplaciano mostrou o dobro desse valor.

IV. CONCLUSÃO

Tendo em vista que as frequências utilizadas possuem valores relativamente próximos, foi possível distinguir razoavelmente duas e quatro classes. O melhor método, CAR-Centroide, obteve em 10 sujeitos acurácia média maior que 90% e 80%, para duas e quatro classes, respectivamente. Comparando os métodos de classificação, o com métrica baseada na distância do centroide apresentou maior acurácia em comparação com LS. O melhor método utilizando LS obteve acurácia média de 90% e 82%, para duas e quatro classes, respectivamente. Além disso, o LS demanda maior tempo computacional, 2210 ms em comparação com 170 ms do método por mínima distância centroide, no caso de quatro classes. Comparando os filtros espaciais, o filtro CAR foi superior ao Laplaciano em todos os cenários. Para os sujeitos testados em que a resposta foi abaixo da média, convém investigar mais a fundo a causa do problema, possivelmente aplicando um seletor de canais automático para cada sujeito seja uma solução. Por fim, considerando a acurácia obtida e o curto tempo de resposta existe potencial para esse sistema operar em tempo real.

AGRADECIMENTOS

Agradecemos ao professor Diogo Soriano Coutinho por disponibilizar a pesquisa de Silva Junior [3]. Este trabalho foi realizado no contexto dos programas Pesquisando Desde o Primeiro Dia (PDPD) e Iniciação Científica (IC) da UFABC.

REFERÊNCIAS

- [1] Carvalho, Sarah N., et al., Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, v. 21, pp. 34-42, 2015.
- [2] Leuthardt, Eric C., et al., A brain-computer interface using. *Neural Engineering*, Springer, pp. 63-71, 2004.
- [3] Silva Junior, José I., 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, 2017.
- [4] Ludwig, Kip A., et al., Using a Common Average Reference to Improve Cortical Neuron Recordings From Microelectrode Arrays. *Journal of Neurophysiology*, v. 101, pp. 1679-1689, 2009.
- [5] Mcfarland, D. J., Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, v. 103, pp. 386-394, 1997.
- [6] Carvalhaes, C. e Barros, J. A., The surface Laplacian technique in EEG: Theory and methods. *International Journal of Psychophysiology*, v. 97, pp. 174-188, 2015.
- [7] Duda, Richard O., et al., *Pattern classification*. John Wiley & Sons, 2001
- [8] Bishop, Christopher M. *Pattern recognition and machine learning*. Springer, pp. 184-186 2006.