

Avaliação do desempenho de técnicas de estimação espectral em interfaces cérebro-computador

Erick Monteiro e Rafael Ferrari

Resumo— Interfaces cérebro-computador (BCI) são sistemas que, ao interpretar a atividade cerebral, fornecem um meio de comunicação alternativo, possibilitando diversas aplicações, principalmente para reabilitação. Nesse estudo, foi realizada uma avaliação de diferentes técnicas de estimação espectral aplicadas à extração de características para BCI no paradigma de Potenciais Evocados Visualmente em Regime Estacionário (SSVEP). Os resultados mostram que, embora não haja uma técnica que se sobressaia decisivamente para o conjunto de dados utilizado, algumas podem ser mais robustas em relação ao método de seleção de características e ao tamanho da janela de estimação.

Palavras-Chave— SSVEP, estimação espectral, seleção de atributos

Abstract— Brain-computer interfaces (BCI) are systems that, when analysing brain activity, provide an alternative means of communication, enabling several applications, mainly in rehabilitation. In this study, an analysis of different data processing techniques for BCI was done for the Steady State Visual Evoked Potentials (SSVEP) paradigm. Results show that, although there is not a technique that stands out for the dataset used, some may be more robust when using given a estimation time window and a feature selection method.

Keywords— SSVEP, spectral estimation, feature selection

I. INTRODUÇÃO

Interfaces cérebro-computador (BCI, no inglês *Brain-computer interfaces*) são sistemas capazes de fornecer a um usuário, através da análise de sua atividade cerebral, um meio de comunicação alternativo capaz de transmitir mensagens e realizar ações [Wol+02]. O desenvolvimento desta tecnologia pode possibilitar mudanças importantes, principalmente, na acessibilidade da parcela da população que sofre de distúrbios neuromusculares que limitam ou bloqueiam outros meios de comunicação do corpo com o mundo.

Para a aquisição dos sinais produzidos pela atividade cerebral, existem várias técnicas que podem ser empregadas no contexto de BCI, dentre elas a eletroencefalografia (EEG) [Rei82]. A técnica consiste em registrar sinais, através de eletrodos posicionados no couro cabeludo, que representam uma observação da atividade eletro-encefálica do indivíduo. A EEG possui certas vantagens em relação a outros métodos por ser não invasiva e menos custosa. Entretanto, os sinais obtidos por essa tecnologia possuem uma relação sinal-ruído menor que outras técnicas, visto que o sinal é obtido de forma indireta, através de eletrodos posicionados sobre o escalpo [Dor+07].

Erick Leonardo de Sousa Monteiro, Rafael Ferrari, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas (Unicamp), Campinas, SP, Brasil. E-mails: e211494@dac.unicamp.br, rferari@dca.fee.unicamp.br. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Dentre os paradigmas de BCI atualmente existentes, o modelo de Potenciais Evocados Visualmente em Regime Estacionário (SSVEP, no inglês *Steady State Visual Evoked Potentials*) consiste em apresentar ao usuário estímulos cintilantes em frequências precisas e conhecidas. Quando o usuário foca a atenção em algum destes estímulos, observa-se um aumento perceptível da densidade espectral de potência da atividade cerebral exatamente na frequência de incitação.

A extração da informação em uma BCI-SSVEP é realizada através do processamento dos sinais cerebrais, que pode ser dividido em quatro etapas. Primeiramente é realizada a etapa de pré-processamento cujo objetivo é aumentar a relação sinal-ruído por meio da remoção de artefatos extrínsecos ao sinal de interesse. Após esta etapa, é realizada a extração de características ou atributos, que tem por objetivo reduzir a dimensionalidade do sinal e obter um conjunto de características com alto teor informativo. Na próxima etapa, é feita a seleção de características que é utilizada para definir um subconjunto dos atributos extraídos dos sinais com o objetivo de separar as informações mais relevantes para a classificação. Na última etapa, é realizada a classificação, que consiste no mapeamento dos dados, representados por seus conjuntos de características, sobre um conjunto finito de classes, cada uma associada a um estímulo visual distinto. Dessa forma, as classes permitem generalizar dados que contenham similaridades entre os seus conjuntos de características.

O uso de atributos baseados nas amplitudes do espectro do sinal de EEG nas frequências dos estímulos visuais é um opção natural no contexto de BCIs baseadas em SSVEP [FS+11]. Nesse sentido, uma estimativa precisa do espectro nessas frequências é fundamental para o bom desempenho de um classificador.

Diante desse contexto, o foco central deste estudo é avaliar o impacto que diferentes técnicas de estimação espectral apresentam no desempenho de sistemas BCI-SSVEP. Os experimentos realizados buscam verificar a influência isolada de cada técnica de estimação, bem como o impacto combinado da estimação espectral com a heurística de seleção de características *Forward Selection* [SC+20] [Car+21]. A taxa de acerto na classificação é utilizada como métrica de desempenho nos ensaios experimentais.

II. TÉCNICAS DE ESTIMAÇÃO ESPECTRAL PARA EXTRAÇÃO DE ATRIBUTOS

O uso do sinal de EEG em sua forma temporal implica em uma maior dificuldade em treinar um classificador, pois os dados possuem uma alta dimensionalidade. Para contornar isso, características de menor dimensionalidade são extraídas.

Como o foco deste estudo é a aplicação no cenário de SSVEP, torna-se natural que a amplitude das frequências de estímulo e de suas respectivas harmônicas representem bem o sinal [BTC10]. A Transformada Discreta de Fourier (DFT, no inglês *Discrete Fourier Transform*) é uma técnica muito empregada para este fim em BCI. Entretanto, há outras técnicas de estimação espectral na literatura que também podem ser utilizadas para extração de atributos em SSVEP-BCI. Estes estimadores realizam a estimativa de um vetor de fasores complexos, $\mathbf{p} = [p_1, \dots, p_K]^T$, usado para representar o sinal como uma soma de K senóides complexas imersa em ruído, conforme a equação [SLL00]

$$x(n) = \sum_{k=1}^K p_k e^{j\omega_k n} + v(n), \quad (1)$$

em que o sinal $x(n)$ é decomposto em K senóides complexas, sendo que a k -ésima senóide apresenta amplitude complexa p_k e frequência ω_k ; $v(n)$ é um ruído de observação aleatório.

A seguir, descrevemos os estimadores que serão avaliados neste trabalho.

A. Estimadores LS

Os estimadores do tipo LS usam a regressão de quadrados mínimos [Sto+01] na equação (1) para obter \mathbf{p} . Isso pode ser feito de duas maneiras: (i) estimação das K componentes do vetor \mathbf{p} de uma só vez, método denominado LSEK, ou (ii) através da estimação de uma componente por vez (LSE1), considerando as demais $K - 1$ frequências como parte do ruído.

O método LSEK pode ser expresso por

$$\hat{\mathbf{p}} = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{x}, \quad (2)$$

em que \mathbf{x} é o vetor do sinal de entrada e \mathbf{A} pode ser expresso por

$$\mathbf{A} = \begin{bmatrix} 1 & \dots & 1 \\ e^{j\omega_1} & \dots & e^{j\omega_K} \\ \vdots & \ddots & \vdots \\ e^{j(N-1)\omega_1} & \dots & e^{j(N-1)\omega_K} \end{bmatrix}, \quad (3)$$

em que N é a dimensão de \mathbf{x} .

O método LSE1 pode ser expresso por

$$\hat{p}_k = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j\omega_k n} \quad (4)$$

que é proporcional à componente da DFT [OBS01] do sinal na frequência ω_k . A equivalência entre o LSE1 e a DFT estabelece uma base para a comparação dos estimadores, visto que a DFT é uma técnica muito conhecida e usual de estimação espectral.

B. Estimadores Capon

Os estimadores Capon (ASC, no inglês *Amplitude Spectrum Capon*) são estimadores de alta resolução espectral que apresentam picos espectrais mais concentrados com menores lóbulos laterais que a DFT [LS95]. Este estimador pode ser deduzido como um banco de filtros ou como uma aplicação

de quadrados mínimos ponderados [KK04]. A implementação do método de Capon como estimador espectral divide os dados em seções de tamanho M , com $M - 1$ amostras de sobreposição, resultando em L ($L = N - M + 1$) janelas de dados. Cada janela pode ser expressa por

$$\mathbf{y}(l) = [x(l) \quad x(l+1) \quad \dots \quad x(l+M-1)]^T. \quad (5)$$

Estes estimadores também podem ser usados para estimar as K frequências ao mesmo tempo (ASCK) ou uma frequência por vez (ASC1).

O estimador ASCK pode ser expresso por

$$\hat{\mathbf{p}} = \left[\sum_{l=0}^{L-1} (\mathbf{A}_l^H \hat{\mathbf{R}}^{-1} \mathbf{A}_l) \right]^{-1} \left[\sum_{l=0}^{L-1} (\mathbf{A}_l^H \hat{\mathbf{R}}^{-1} \mathbf{y}(l)) \right], \quad (6)$$

em que

$$\mathbf{A}_l = \mathbf{A} \begin{bmatrix} e^{j\omega_1 l} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & e^{j\omega_K l} \end{bmatrix}, \quad (7)$$

e

$$\hat{\mathbf{R}} = \frac{1}{L} \sum_{l=0}^{L-1} \mathbf{y}(l) \mathbf{y}^H(l), \quad (8)$$

sendo $\hat{\mathbf{R}}$ a matriz de autocorrelação do sinal $x(n)$.

O estimador ASC1 pode ser expresso por

$$\hat{p}_k = \frac{\mathbf{a}^H(\omega_k) \hat{\mathbf{R}}^{-1} \mathbf{g}(\omega_k)}{\mathbf{a}^H(\omega_k) \hat{\mathbf{R}}^{-1} \mathbf{a}(\omega_k)} \quad (9)$$

em que

$$\mathbf{g}(\omega_k) = \frac{1}{L} \sum_{l=0}^{L-1} \mathbf{y}(l) e^{-j\omega_k l}. \quad (10)$$

C. Estimadores APES

O Estimador de Amplitude e Fase (APES, no inglês *Amplitude and Phase Estimator*) também é um estimador de alta resolução espectral que é bastante similar aos estimadores baseados no método Capon. Em performance, o APES possui estimativas espectrais mais precisas que o método Capon porém possui picos mais largos [Gle08]. A principal diferença entre o APES e o Capon é que o método APES utiliza estimativas iniciais dos fasores, obtidas por um estimador LS.

A implementação do estimador APES para K frequências simultâneas (APESK) é bastante semelhante à do estimador ASCK, como pode ser visto em

$$\hat{\mathbf{p}} = \left[\sum_{l=0}^{L-1} (\mathbf{A}_l^H \hat{\mathbf{Q}}^{-1} \mathbf{A}_l) \right]^{-1} \left[\sum_{l=0}^{L-1} (\mathbf{A}_l^H \hat{\mathbf{Q}}^{-1} \mathbf{y}(l)) \right], \quad (11)$$

em que $\hat{\mathbf{Q}}$ é uma estimativa da matriz de autocorrelação do ruído de observação. Considerando que o sinal e o ruído de observação são decorrelacionados, $\hat{\mathbf{Q}}$ pode ser obtida pela expressão

$$\hat{\mathbf{Q}} = \hat{\mathbf{R}} - \mathbf{A} \hat{\mathbf{P}} \mathbf{A}^H, \quad (12)$$

em que $\hat{\mathbf{P}}$ é uma matriz diagonal tal que $P_{ii} = p_{i_{LSE}}$, sendo $p_{i_{LSE}}$ a estimativa do fasor da i -ésima frequência obtida por um estimador do tipo LSE.

A implementação para estimar uma frequência por iteração (APES1) pode ser expressa por

$$\hat{p}_k = \frac{\mathbf{a}^H(\omega_k)\hat{\mathbf{R}}^{-1}\mathbf{g}(\omega_k)}{\mathbf{a}^H(\omega_k)\hat{\mathbf{R}}^{-1}\mathbf{a}(\omega_k)}. \quad (13)$$

D. Estimadores baseados em Bancos de Filtros

Bancos de filtros têm como objetivo filtrar sinais em determinadas bandas de frequência simultaneamente [Hay08], o que torna interessante aplicar esta técnica em conjunto com as técnicas anteriormente apresentadas.

Contudo, a técnica de banco de filtros utilizada neste estudo também tem como objetivo maximizar a relação sinal-ruído de suas saídas, que pode ser expressa por

$$\mathbf{H} = \arg \max_{\mathbf{H}} \text{tr}[(\mathbf{H}^H \hat{\mathbf{Q}} \mathbf{H})^{-1} \mathbf{H}^H (\mathbf{A} \hat{\mathbf{P}} \mathbf{A}^H \mathbf{H})], \quad (14)$$

em que $\text{tr}[\cdot]$ representa a operação traço e \mathbf{H} está sujeito a um conjunto de restrições lineares definidos na seguinte expressão

$$\mathbf{H}^H \mathbf{A} = \mathbf{I}_K. \quad (15)$$

A solução para este problema (MAFI1) pode ser expressa por

$$\mathbf{H} = \hat{\mathbf{Q}}^{-1} \mathbf{A} (\mathbf{A}^H \hat{\mathbf{Q}}^{-1} \mathbf{A})^{-1}. \quad (16)$$

O vetor $\hat{\mathbf{p}}$ pode ser obtido após a estimação por quadrados mínimos do sinal filtrado, como pode ser visto na expressão

$$\hat{\mathbf{p}} = \frac{1}{L} \sum_{l=0}^{L-1} (\mathbf{H}^H \mathbf{x}(l)) \circ \mathbf{z}(l) \quad (17)$$

em que \circ é o produto de Schur e

$$\mathbf{z}(l) = [e^{-j\omega_1 l} \quad e^{-j\omega_2 l} \quad e^{-j\omega_3 l} \quad \dots \quad e^{-j\omega_K l}]^T. \quad (18)$$

III. SELEÇÃO DE ATRIBUTOS

Em aprendizado de máquina, é comum que haja um grande número de características que descrevam as classes do conjunto de dados. Entretanto, algumas delas podem influenciar negativamente o desempenho do decisor, devido à influência de ruído em sua estimativa. Tendo isso em mente, a seleção de características tem como objetivo determinar o conjunto de características que, ao serem usadas no treinamento do classificador, maximizam um critério de desempenho. A seleção de características possui várias vantagens, entre elas o aumento do desempenho, velocidade e eficácia do classificador, além de possibilitar uma melhor compreensão do fenômeno [Bis+95] [GE03]. Os principais procedimentos utilizados para realizar uma seleção são os filtros e *wrappers*. Neste estudo contudo, serão apenas avaliados o uso de *wrappers*.

A. Busca exaustiva

A busca exaustiva é o algoritmo que garante a obtenção da solução ótima no problema combinatorial no qual se traduz a seleção de atributos. Ela consiste em verificar qual subconjunto de atributos, dentre todos os possíveis, apresenta o melhor desempenho para o problema. Entretanto, o número de subconjuntos possíveis cresce exponencialmente com o número de atributos, o que torna este método muito custoso computacionalmente. Contudo, pode ser uma solução viável em problemas com poucos atributos e também serve de referência para o desempenho de outras estratégias de seleção. A complexidade do algoritmo de busca exaustiva é $O(2^A O(\text{Classificador}(S)))$, em que A é o número de atributos dos dados e $\text{Classificador}(S)$ é a função do classificador utilizado.

B. Forward Selection

O *wrapper Forward Selection* [Hoc76] consiste em um algoritmo iterativo que constrói um subconjunto de características a partir de um subconjunto vazio. A cada iteração, é verificado dentre todas as características que ainda não pertencem ao subconjunto, se há alguma característica cuja adição implica no aumento da acurácia do classificador. Caso haja, a característica que proporcionou o maior aumento é adicionada ao subconjunto. Caso não haja alguma característica que aumente a acurácia de classificação ou o subconjunto seja igual ao conjunto total de características, o subconjunto atual é a resposta para esta heurística. Apesar de sua complexidade ser $O(A^2 O(\text{Classificador}(S)))$, que é menos custoso que a busca exaustiva, este *wrapper* possui uma solução sub-ótima para o conjunto de treinamento.

IV. EXPERIMENTO

Para este estudo, foi elaborado um experimento para avaliar as técnicas de estimação de atributos espectrais apresentadas anteriormente. Os experimentos têm como objetivo processar os dados registrados para frequências de incitação de 12Hz e 15Hz, classificando-os em dados da classe 1, referentes à frequência de 12Hz, e da classe 2, referentes à frequência de 15 Hz. O experimento utilizou a base de dados [Car+15], produzida no projeto BRAINN, que possui dados de 10 indivíduos. Os dados de EEG de cada indivíduo consistem em 6 sessões de 12 segundos para cada frequência de incitação utilizada, amostrados a uma taxa de 256Hz. Os eletrodos utilizados para o experimento foram O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz e FCz, conforme o sistema internacional 10-20 [HHP87].

O procedimento de classificação dos experimentos consiste em realizar o pré-processamento do sistema com um filtro CAR (*Common Average Reference*) [McF+97] e utilizar na etapa de classificação um classificador linear treinado por quadrados mínimos [Sto+01]. Na etapa de extração de características foram utilizados os sete estimadores descritos anteriormente para obter a amplitude das frequências de 12Hz e 15Hz e também de suas duas primeiras harmônicas. Na etapa de seleção foi utilizada a busca exaustiva e o *Forward Selection*, aplicando-os no conjunto de atributos de cada

eletrodo, isto é, a seleção de um atributo resulta na seleção da amplitude das estimativas de 12Hz, 15Hz, 24Hz, 30Hz, 36Hz e 45Hz, correspondendo às frequências das fundamentais e as suas duas primeiras harmônicas. A seleção baseada na busca exaustiva permite a avaliação do impacto isolado de cada técnica de estimação espectral, uma vez que, nesse caso, há garantia de otimalidade nas etapas que sucedem a seleção, seleção e classificação. Dessa forma, o desempenho do sistema tem relação maior com a qualidade da extração de características, ou seja, com a estimativa produzida pela técnica de estimação espectral. Como a estratégia de busca exaustiva não é computacionalmente factível em um contexto prático devido à natureza combinatorial do problema de seleção, o emprego do *Forward Selection* permite uma avaliação das técnicas de estimação em condições mais realistas, em que há um efeito combinado da extração e da seleção no desempenho do sistema. A combinação entre as técnicas de extração e seleção totaliza 14 cenários diferentes de classificação. Os dados de cada indivíduo foram segmentados em um conjunto de treinamento, composto por 75% dos dados, e em um conjunto de validação, com 25% dos dados.

V. RESULTADOS

Primeiramente, os dados de cada canal de EEG foram divididos em janelas de 1s sem sobreposição entre elas, totalizando 72 janelas de dados para cada indivíduo, onde 54 delas foram utilizadas para o treinamento e 18 foram utilizadas para a validação. A taxa de acerto obtida no conjunto de validação para cada configuração de estimador e de seletor é mostrada na Figura 1.

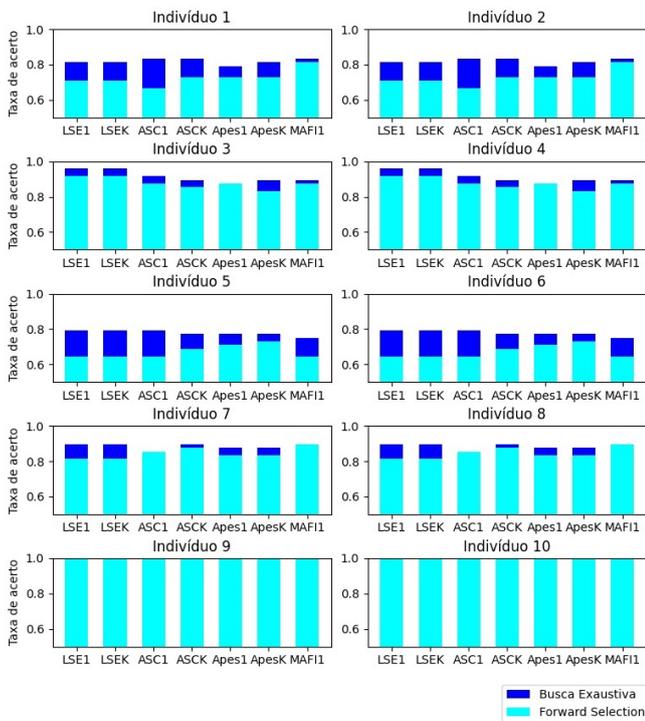


Fig. 1. Taxas de acerto do experimento para janelas de 1s

Os resultados referentes à seleção com busca exaustiva permitem uma comparação melhor da influência dos estimadores

no desempenho, uma vez que o sistema opera garantidamente com o melhor conjunto de atributos nesse caso. Por outro lado, os resultados do *Forward Selection* possibilitam a observação do impacto da combinação da estimação com a heurística de seleção.

Considerando-se a seleção por busca exaustiva, observa-se que a melhor técnica de estimação pode variar de acordo com o indivíduo, ou seja, nenhuma técnica é superior às demais para todos os cenários. Além disso, para a maioria dos indivíduos, a diferença de desempenho entre os estimadores é pequena.

Quando adota-se a heurística de seleção *Forward Selection*, o desempenho geral cai, uma vez que essa técnica não garante otimalidade na escolha do subconjunto de atributos. Entretanto, a queda de desempenho não é igual para todos os estimadores, alguns são mais afetados do que outros. O estimador APES1 é o que apresenta menor perda de desempenho de um modo geral, como pode ser visto na tabela I.

TABELA I

PERDA DE DESEMPENHO MÉDIA DO FORWARD SELECTION EM RELAÇÃO À SOLUÇÃO ÓTIMA (BUSCA EXAUSTIVA).

	Janela de 1s (%)	Janela de 3s (%)
LSE1	6.47	3.52
LSEK	6.47	3.52
ASC1	8.00	2.80
ASCK	5.96	3.43
Apes1	4.35	2.81
ApesK	5.01	3.96
MAFI1	4.59	3.74

Aumentando-se a janela de extração de atributos para 3s, com sobreposição de 2s entre janelas vizinhas, foram obtidos os resultados de taxa de acerto de classificação no conjunto de validação mostrados na Figura 2. Nesse caso, são produzidas 60 janelas para cada indivíduo, sendo 45 para treinamento e 15 para a validação.

O aumento da janela se traduz em um aumento do número de amostras usadas na obtenção das estimativas dos atributos. Como efeito, observamos um aumento geral no desempenho, acompanhado de uma diminuição do impacto do tipo de estimador na taxa de acerto. A redução média de desempenho devido ao uso do *Forward Selection* foi menor do que a observada com a janela de 1s e, novamente, o APES1 foi o menos afetado, juntamente com o ASC1, conforme mostrado na tabela I.

VI. CONCLUSÕES

Este trabalho avaliou o desempenho de diferentes técnicas de estimação espectral aplicadas na extração de características de BCIs baseadas em SSVEP. Foi possível verificar a partir dos resultados experimentais que nenhuma das técnicas testadas se sobressaiu de maneira significativa em relação às demais. Entretanto, quando se considera o efeito combinado da estimação dos atributos com a heurística de seleção, algumas técnicas apresentaram menor perda de desempenho em relação ao obtido utilizando busca exaustiva, com destaque para a APES1. Ainda é preciso confirmar se esse comportamento se reproduz em outros bancos de dados e investigar a razão pela qual

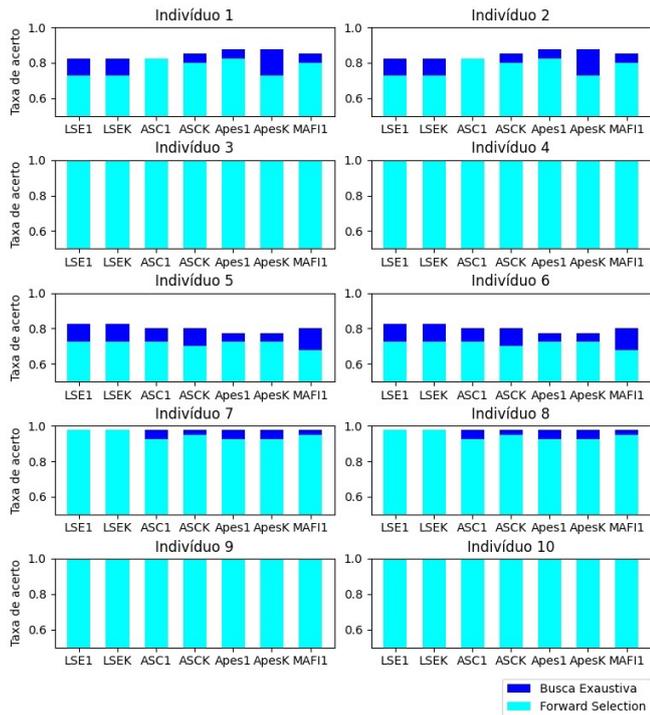


Fig. 2. Taxas de acerto do experimento para janelas de 3s

o APES1 parece favorecer a heurística de seleção. Quando comparados ao resultado do LSE1 (DFT) com *Forward Selection*, também é interessante ver que os outros estimadores apresentaram incrementos significativos quando a janela é menor, o que aumenta pode aumentar a confiabilidade do sistema perante um período de aquisição menor, possivelmente levando a uma taxa de transferência de informação maior também.

REFERÊNCIAS

- [Hoc76] Ronald R Hocking. “A Biometrics invited paper. The analysis and selection of variables in linear regression”. Em: *Biometrics* 32.1 (1976), pp. 1–49.
- [Rei82] Edward L Reilly. “EEG recording and operation of the apparatus”. Em: *Electroencephalography* (1982).
- [HHP87] Richard W Homan, John Herman e Phillip Purdy. “Cerebral location of international 10–20 system electrode placement”. Em: *Electroencephalography and clinical neurophysiology* 66.4 (1987), pp. 376–382.
- [Bis+95] Christopher M Bishop et al. *Neural networks for pattern recognition*. Oxford university press, 1995.
- [LS95] Jian Li e Peter Stoica. “Adaptive filtering approach to spectral estimation and SAR imaging”. Em: *Algorithms for Synthetic Aperture Radar Imagery II*. Vol. 2487. International Society for Optics e Photonics. 1995, pp. 153–164.
- [McF+97] Dennis J McFarland et al. “Spatial filter selection for EEG-based communication”. Em: *Electroencephalography and clinical Neurophysiology* 103.3 (1997), pp. 386–394.
- [SLL00] Petre Stoica, Hongbin Li e Jian Li. “Amplitude estimation of sinusoidal signals: survey, new results, and an application”. Em: *IEEE Transactions on Signal Processing* 48.2 (2000), pp. 338–352.
- [OBS01] Alan V Oppenheim, John R Buck e Ronald W Schafer. *Discrete-time signal processing. Vol. 2*. Upper Saddle River, NJ: Prentice Hall, 2001.
- [Sto+01] David G Stork et al. “Pattern classification”. Em: *A Wiley-Interscience Publication* (2001).
- [Wol+02] Jonathan R Wolpaw et al. “Brain–computer interfaces for communication and control”. Em: *Clinical neurophysiology* 113.6 (2002), pp. 767–791.
- [GE03] Isabelle Guyon e André Elisseeff. “An introduction to variable and feature selection”. Em: *Journal of machine learning research* 3.Mar (2003), pp. 1157–1182.
- [KK04] Takeaki Kariya e Hiroshi Kurata. *Generalized least squares*. John Wiley & Sons, 2004.
- [Dor+07] Guido Dornhege et al. *Toward brain-computer interfacing*. Vol. 63. MIT press Cambridge, MA, 2007.
- [Gle08] George-Othon Glentis. “A fast algorithm for APES and Capon spectral estimation”. Em: *IEEE Transactions on Signal Processing* 56.9 (2008), pp. 4207–4220.
- [Hay08] Simon S Haykin. *Adaptive filter theory*. Pearson Education India, 2008.
- [BTC10] Hovagim Bakardjian, Toshihisa Tanaka e Andrzej Cichocki. “Optimization of SSVEP brain responses with application to eight-command brain–computer interface”. Em: *Neuroscience letters* 469.1 (2010), pp. 34–38.
- [FS+11] Toka Abdul-Hameed Fatehi, Abdul-Barry Raouf Suleiman et al. “Features extraction techniques of eeg signals for Bci application”. Em: *International Arab Conference for Information Technology*. 2011.
- [Car+15] Sarah N Carvalho et al. “Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs”. Em: *Biomedical Signal Processing and Control* 21 (2015), pp. 34–42.
- [SC+20] Thiago Bulhões da Silva Costa et al. “Channel capacity in brain–computer interfaces”. Em: *Journal of neural engineering* 17.1 (2020), p. 016060.
- [Car+21] Sarah Negreiros de Carvalho et al. “Space-time filter for SSVEP brain-computer interface based on the minimum variance distortionless response”. Em: *Medical & Biological Engineering & Computing* (2021), pp. 1–18.