

## ANÁLISE DE DIFERENTES TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS EM INTERFACE CÉREBRO-MÁQUINA

D. C. Soriano<sup>1</sup>, G. F. Slenes<sup>2</sup>, G. C. Beltramini<sup>2</sup>, E. L. Silva<sup>3</sup>, S. N. Carvalho<sup>4</sup>, T. B.S. Costa<sup>5</sup>,  
G. Castellano<sup>2</sup> e R. Attux<sup>5</sup>

<sup>1</sup>Centro de Eng., Modelagem e Ciências Sociais Aplicadas, UFABC, Santo André, Brasil.

<sup>2</sup>Grupo de Neurofísica, Inst. de Física Gleb Wataghin, UNICAMP, Campinas, Brasil.

<sup>3</sup>Instituto de Física, UFMT, Cuiabá, Brasil.

<sup>4</sup>Dept. de Eng. Elétrica, UFOP, João Monlevade, Brasil.

<sup>5</sup>Dept. de Eng. da Computação e Automação Industrial, FEEC, UNICAMP, Campinas, Brasil.

e-mail: [diogo.soriano@ufabc.edu.br](mailto:diogo.soriano@ufabc.edu.br)

**Resumo:** Este trabalho apresenta uma análise comparativa do desempenho de uma interface cérebro-máquina baseada em imaginação de tarefas (imaginação de música, movimento e repouso) considerando quatro técnicas distintas para a extração de características: coeficientes da densidade espectral de potência (PSD), a PSD média nas bandas clássicas dos ritmos de EEG, medidas baseadas na análise por quantificação de recorrência e coeficientes de modelos auto regressivos. Os resultados apontaram os coeficientes associados a PSD como os atributos de melhor desempenho para a classificação, atingindo taxas de erro entre 20 e 25 % para os indivíduos analisados utilizando um classificador projetado com base na análise do discriminante linear (LDA).

**Palavras-chave:** interface cérebro-máquina, extração de características, reconhecimento de padrões, EEG.

**Abstract:** *This study presents a comparative analysis of a brain-computer interface based on imagery task (music imagery, movement imagery and rest) considering four distinct feature extraction techniques: power spectral density coefficients (PSD), the mean PSD in classical EEG rhythms, measures based on recurrence quantification analysis and coefficients of autoregressive models. The results indicate that the PSD attributes provided the best classification performance, attaining an error rate among 20 - 25 % for the subjects analyzed using a classifier designed based on linear discriminant analysis (LDA).*

**Keywords:** *brain-computer interface, features extraction pattern recognition, EEG.*

### Introdução

A extração de características define um dos módulos fundamentais para o reconhecimento de padrões [1], delineando, portanto, uma tarefa particularmente importante na concepção de interfaces cérebro-máquina ou sistemas BCI (do inglês, *brain-computer interface*). Tais sistemas visam prover um canal de comunicação

alternativo às vias biológicas clássicas [2], realizando assim um mapeamento direto entre os sinais cerebrais registrados (usualmente captados de forma não invasiva pela eletroencefalografia – EEG – de superfície) em comandos para dispositivos externos.

Dentre os principais paradigmas utilizados em BCI destacam-se a imaginação de tarefas, as técnicas baseadas em potenciais relacionados a eventos (e.g., P300) [3] e os potenciais visualmente evocados em regime estacionário (SSVEP) [2]. O primeiro desses paradigmas é particularmente atrativo para a concepção de sistemas BCI assíncronos, i.e., independentes da sincronização com estímulos externos, contribuindo para a autonomia e conforto dos seus usuários [2]. No entanto, a imaginação de tarefas pode evocar atividades complexas do ponto de vista cognitivo e de biopotenciais (EEG), o que dificulta substancialmente o processo de reconhecimento de padrões – isso gera o risco de que se obtenham taxas de acerto aquém das necessárias para um bom desempenho de tais sistemas.

Classicamente, um sistema BCI é constituído das seguintes etapas: aquisição do sinal cerebral, pré-processamento dos sinais, seleção de características e classificação [2]. O presente trabalho focou-se na análise de desempenho do BCI baseado em imaginação de tarefas (música, movimento e repouso) utilizando diferentes técnicas de extração de características: coeficientes PSD com resolução espectral de aproximadamente 1 Hz, PSD média nos ritmos clássicos de EEG, medidas baseadas na análise por quantificação por recorrência e coeficientes de modelos auto regressivos. O processo de classificação se deu por meio da análise do discriminante linear (LDA) e validação por meio da abordagem *k-fold cross validation*.

A análise comparativa destas quatro técnicas de extração de características foi realizada *off-line* e as outras etapas do BCI foram definidas por opções clássicas de processamento, i.e. frequentemente utilizada na literatura. Assim, o desempenho de classificação do sistema, para os diferentes paradigmas, serve para delinear o perfil de sistemas BCI baseados

em tarefas cognitivas mais complexas e factibilidade para a operação em *real time*.

### Materiais e métodos

Os sinais de EEG de 5 sujeitos (idade média 28.8  $\pm$  5.4) saudáveis foram adquiridos por meio de um amplificador de biopotenciais BrainAmp (Brain Products, Munique, Alemanha) e 63 eletrodos de Ag/AgCl, com amostragem a 250 Hz.

O paradigma de imaginação de tarefas consistiu de 21 blocos (ou *trials*) de 20 s cada, intercalando períodos de repouso com imaginação de movimento ou imaginação de música. As instruções foram passadas aos sujeitos por meio de uma tela de computador, sendo que uma cruz, uma seta para direita e uma nota musical simbolizavam, respectivamente, o estado repouso, de imaginação de movimento da mão direita e de imaginação de música. Esse paradigma foi repetido duas vezes para cada sujeito, totalizando 42 *trials*. O procedimento experimental foi aprovado pelo comitê de ética da UNICAMP (protocolo n. 0617.0.146.000-10) e todos os sujeitos assinaram um termo de consentimento. Mais detalhes sobre o procedimento experimental podem ser encontrados em [4].

O pré-processamento foi realizado por meio de um filtro passa banda com faixa de 2-35 Hz, seguido de uma filtragem espacial do tipo média de referência comum (CAR, do inglês *common average reference*) [2]. Segue-se a esse processo, a segmentação dos sinais em *trials* para cada eletrodo, segundo os estímulos do experimento descrito.

O módulo de extração de características foi implementado tendo em vista 4 técnicas distintas. A primeira usou os coeficientes da densidade espectral de potência (PSD), estimados pelo método de Welch tal como detalhadamente descrito em [4] e com resolução espectral de aproximadamente 1 Hz. Esses mesmos coeficientes foram utilizados na segunda, para calcular a PSD média nos ritmos clássicos de EEG (Delta: 1-4 Hz, Theta: 4-8 Hz, Alfa: 8-13 Hz e Beta: 8-30 Hz).

Como alternativa à análise espectral, na terceira técnica foi empregada a análise por quantificação por recorrência (RQA) que visa quantificar o reaparecimento de estados por meio de uma medida de correlação não linear [5]. Na prática, emprega-se o método da reconstrução de Takens para observar uma possível estrutura (atrator) no espaço de estados  $\mathbf{x}(k)$ :

$$\mathbf{x}(k) = [x(k) \quad x(k-\tau) \quad \dots \quad x(k-(d_e-1)\tau)], \quad (1)$$

onde  $d_e$  é a dimensão de imersão e  $\tau$  o atraso entre amostras para a construção das demais coordenadas de  $\mathbf{x}(k)$ , a partir do qual se determina a matriz de distância binária  $\mathbf{R}_{i,j}$  que indica quando um estado  $\mathbf{x}(i)$  está próximo de  $\mathbf{x}(j)$  de um tanto  $\varepsilon$ , i.e:

$$\mathbf{R}_{i,j} = \Theta\{\varepsilon - \|\mathbf{x}(i) - \mathbf{x}(j)\|\}, \quad (2)$$

sendo que  $\Theta\{x\}$  representa a função de Heaviside e vale 0 para  $x < 0$  e 1 caso contrário. Assim,  $\mathbf{R}_{i,j}$  define uma matriz binária, ou mapa de retorno (RP) caso um pixel preto seja associado a posição  $(i,j)$  quando  $\mathbf{R}_{i,j} = 1$ . Neste caso, pontos de  $\mathbf{x}(k)$  que evoluem no tempo, próximos de um  $\varepsilon$  tendem a formar diagonais no RP, as quais caracterizam o padrão oscilatório por meio de métricas clássicas [5]: (DET) - porcentagem de pontos em diagonais de  $a$  até  $b$ ; Entr - entropia de Shannon das diagonais;  $L_{\max}$  - comprimento máximo da diagonal presente em RP (excluindo a diagonal principal) e a taxa de recorrência RR que define a porcentagem de pontos do RP. Em particular, utilizou-se  $d_e = 5$  e  $\tau = 5$ . O limiar  $\varepsilon$  foi escolhido tomando aleatoriamente um *trial* de cada eletrodo e ajustando seu valor para fornecer uma RR = 2.5% (valor típico para RP de boa qualidade [5]). A média dos  $\varepsilon$  obtidos foi tomada para a obtenção de todas as matrizes  $\mathbf{R}_{i,j}$ , de forma a minimizar a escolha de valores inadequados e muito arbitrários de  $\varepsilon$ . As medidas DET<sub>1</sub>, DET<sub>2</sub> e DET<sub>3</sub> associam-se com a porcentagem de pontos em diagonais que partem de comprimento 5, 10 e de 15 e vão até 100 (comprimento a partir do qual não se encontram mais pontos), respectivamente.

A quarta técnica utilizada para a extração de características consistiu na estimação dos coeficientes  $\alpha(k)$  de um modelo auto regressivo de ordem 30, ajustado de modo a minimizar o valor quadrático médio do erro de predição  $e(n)$  definido a seguir:

$$e[n] = x[n] - y[n] = x(n) - \sum_{k=1}^p \alpha(k)x[n-k], \quad (3)$$

onde  $y[n]$  é o valor da saída atual do modelo,  $x[n]$  é a série temporal analisada e  $p$  é a ordem do modelo.

O módulo de seleção de características foi implementado a partir de uma medida de clusterização definida pelo índice de Davies-Bouldin modificado [4]:

$$DBinv = \frac{1}{M} \sum_{i=1}^M \max_{i \neq j} \left[ \frac{d(\mu_i, \mu_j)}{\text{diam}(C_i) + \text{diam}(C_j)} \right], \quad (4)$$

em que  $d(\mu_i, \mu_j)$  é a distância entre os centros das classes  $i$  e da classe  $j$ ,  $\text{diam}(C_i)$  é a máxima distância entre todos os pares de amostras da classe  $i$  e  $M$  é o número de classes. Neste caso, altos valores de  $DBinv$  indicam atributos promissores para a separação das classes, uma vez que relacionam classes com centróides distantes e com baixa dispersão de suas amostras.

O estágio de classificação foi implementado por meio do ajuste dos parâmetros de um classificador linear utilizando a análise do discriminante linear (LDA) [1] tal como classicamente feito em BCI. Neste caso, o classificador recebe como entradas atributos ranqueados segundo o índice  $DBinv$ , que são progressivamente adicionados até o limiar superior de 10, visando evitar o clássico problema de inversão da

matriz de covariância na LDA, dado o reduzido número de *trials* disponíveis.

O desempenho dos classificadores foi avaliado usando uma estratégia de *k-fold cross validation*, em que 100 diferentes partições foram definidas, com 30 *trials* para treinamento e 12 *trials* para teste do classificador. Desta forma, o desempenho é mostrado em termos do erro médio de classificação e o desvio padrão.

**Resultados**

A partir da extração dos atributos, um mapa quantificando a capacidade de discriminação de cada característica foi construído utilizando o índice *DBinv*, dado pela expressão (4). Tal mapa mostrou-se informativo para alguns sujeitos no caso da PSD, evidenciando um determinado padrão de atributos promissores.

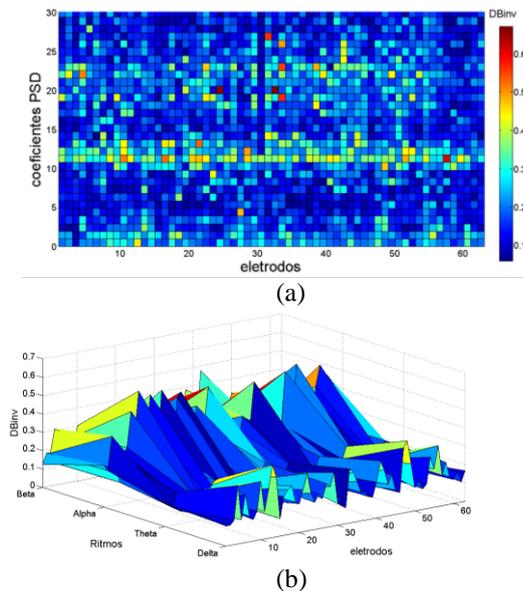


Figura 1: O painel (a) mostra o mapa *DBinv* para os coeficientes PSD para os 63 eletrodos, enquanto o painel (b) mostra o mapa *DBinv* para a PSD média nos ritmos de EEG para os 63 eletrodos.

Por exemplo, a Figura 1(a) mostra o mapa de discriminação, na qual se pode observar claramente que os coeficientes da PSD para diversos eletrodos associados às frequências entre 11 e 13 Hz oferecem um cenário favorável para a discriminação das classes, o que também se manifesta na banda alfa do EEG, conforme se vê na Figura 1(b).

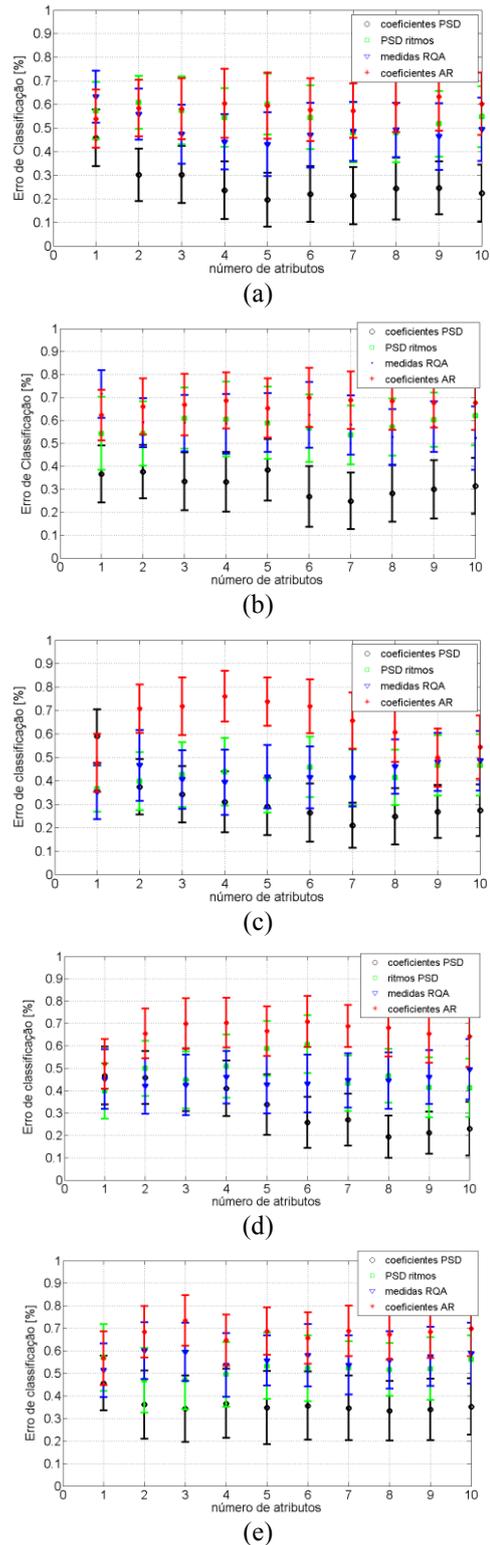


Figura 2: Os painéis (a)-(e) mostram a evolução do erro médio de classificação para 5 sujeitos quando os atributos previamente ranqueados são progressivamente adicionados considerando as diferentes técnicas de extração de características.

No entanto, as medidas de recorrência e coeficientes AR não apresentaram padrões tão nítidos de ativação, e

tiveram desempenho de classificação inferior para todos os sujeitos analisados. Assim, com o intuito de analisar o desempenho do sistema BCI proposto, os atributos ranqueados pelo o índice  $DBinv$  para cada técnica de extração de características foram passados a um mesmo classificador linear. Neste caso, a evolução do erro médio de classificação foi obtida conforme o número de atributos foi incrementado até um total de 10. A Figura 2 mostra o desempenho de classificação para todos os indivíduos considerando as diferentes técnicas de extração de características utilizadas. Nota-se claramente que o método de extração baseado nos coeficientes da PSD estimados pelo método de Welch com resolução espectral de aproximadamente 1 Hz obteve o melhor desempenho, atingindo taxa de erro entre 20 e 25 % para 4 dos 5 indivíduos. Na sequência, os atributos PSD média nos ritmos de EEG e medidas de recorrência apresentaram taxa de erro entre 50 e 40% e entre 60 e 50%, respectivamente. Os coeficientes AR obtiveram uma taxa de erro superior a 50% para todos os sujeitos.

### Discussão e Conclusão

Um dos principais aspectos levantados pelos resultados obtidos reside na diferença de desempenho entre as técnicas que utilizam coeficientes PSD com melhor resolução espectral frente ao cálculo da PSD média nas bandas clássicas de EEG. Esse resultado sugere que informação relevante para o processo de classificação associa-se com frequências mais específicas e a redução de dimensionalidade ocasionada pela opção de se trabalhar apenas com os ritmos pode comprometer o desempenho do sistema, opção essa não rara em BCI.

Destaca-se ainda o desempenho (comparativamente) ruim das medidas de recorrência e dos coeficientes AR na discriminação das classes. Provavelmente, esse desempenho se associa com a variabilidade intrínseca dos sinais obtidos mediante tarefas de imaginação consideradas complexas do ponto de vista cognitivo, o que pode dificultar o processo de reconhecimento de padrões quando técnicas muito sensíveis a transições de fase, que geram mudança no padrão oscilatório, são consideradas, como é o caso da RQA. Curiosamente, paradigmas baseados em estímulos externos (e.g. SSVEP) oferecem uma plataforma mais estável para o emprego da RQA, na qual desempenho superior à clássica abordagem espectral já foi alcançado [6].

No caso dos coeficientes AR, o baixo desempenho pode ter sido influenciado pela escolha de atributos com boa discriminação em relação ao índice  $DBinv$ , mas ainda assim correlacionados, o que pode ter contribuído para uma configuração de atributos que desfavorece a separação das classes. De fato, uma estratégia multi-objetivo de ranqueamento de características não foi adotada aqui dado o aumento de complexidade e custo computacional decorrente desta opção. Enfatiza-se que os sistemas BCI mais eficientes operando em tempo real primam essencialmente por estratégias simples de

seleção de características e classificação, o que vai de encontro à proposta dos estágios clássicos de processamento de sinais adotados neste trabalho.

Como uma perspectiva natural, este trabalho propõe-se ainda a estudar o desempenho de métodos alternativos de classificação (e.g. máquinas de vetores de suporte,  $k$ -vizinhos mais próximos, etc.), bem como de técnicas alternativas de seleção de características [1] com propósito de evoluir na concepção de interfaces homem-máquina mais eficientes e dispositivos assistivos mais robustos.

### Agradecimentos

Os autores agradecem o apoio financeiro da FINEP (projeto DesTine), CNPq, CAPES e multicentro – UFABC.

### Referências

- [1] Theodoridis S, Koutroumbas, K. Pattern Recognition, 4<sup>th</sup> ed, 2008.
- [2] Wolpaw R, Wolpaw EW. Brain-Computer Interfaces: Principles and Practice. Oxford University Press, 2012.
- [3] Guger, Christoph, et al. How many people are able to control a P300-based brain-computer interface (BCI)?. Neuroscience letters 462.1 (2009): 94-98.
- [4] Soriano DC et al. Music versus motor imagery for BCI systems. A study using fMRI and EEG: preliminary results. In: Proceedings of the 4<sup>th</sup> Biosignals and Biorobotics Conference; 2013 Feb 18-20; Rio de Janeiro, Brazil. 2013. p. 1-6.
- [5] Marwan N, Romano MC, Thiel M, Kurths J. Recurrence plots for the analysis of complex systems. Physics Reports. 2007; 438: 237-329.
- [6] Uribe LFS et al. A Recurrence-Based Approach for Feature Extraction in Brain-Computer Interface Systems. Aceito para publicação em: N. Marwan, editor. Translation Recurrences: From Mathematical Theory to Real-World Applications, Springer Proceedings in Mathematics, 2014.