

# Uma contribuição à matriz de informações em sistemas BCI baseados em imagética motora

Paulo H. Gubert, Márcio H. Costa, Cleison D. Silva e Alexandre Trofino

**Resumo** — Esse trabalho propõe uma nova contribuição à formação da matriz de informações em um classificador de imagética motora para interfaces cérebro-máquina. A técnica consiste na inclusão de correlação temporal intra e inter-eletrodos na matriz de informações utilizada pelo método de padrões espaciais comuns. Simulações em um contexto de diferenciação entre movimentos da mão esquerda e direita resultaram em um aumento médio de acurácia de 4% na classificação. Os resultados obtidos indicam que a correlação inter e intra-eletrodos possui informação relevante até então descartada pela literatura em aplicações de imagética motora.

**Palavras-Chave** — Interface cérebro máquina, aprendizado de máquina, BCI, CSP, FLDA.

**Abstract** — This work proposes a new contribution to the information matrix in a classifier of motor imagery for brain-computer interfaces. The technique consists in the inclusion of intra and inter-electrode temporal correlation in the information matrix used by the common spatial patterns method. Simulations in a context of differentiation between left and right hand movements resulted in an average increase of accuracy of 4% in the classification process. Results indicate that inter and intra-electrode correlation have relevant information previously discarded by the literature in motor imagery applications.

**Keywords** — Brain computer interface, machine learning, BCI, CSP, FLDA.

## I. INTRODUÇÃO

A interface cérebro-máquina (*Brain-Computer Interface* - BCI) é uma tecnologia assistiva que permite que comandos cerebrais de um usuário acionem diretamente sistemas ou dispositivos eletrônicos/mecânicos, sem a participação de ações musculares. Entre suas diversas aplicações está a compensação de deficiências graves de comunicação [1] [2].

A imagética motora é uma forma particular de sistema BCI, que consiste na simulação mental de um ato motor, sem real execução muscular, sendo posteriormente associada à execução de uma determinada tarefa desejada como, por exemplo, o acionamento de um alarme. O meio mais comum de registro desses sinais é o eletroencefalograma (EEG) [3]. Em [2] [4] [5] [6] [7] são descritas aplicações de BCI, nas quais o EEG é utilizado para identificação do imageamento motor (simulação mental dos movimentos das mãos, pés e língua) realizado.

A técnica de imagética motora convencional consiste basicamente na análise do EEG e diferenciação entre eventos de dessincronização (*Event Related Desynchronization* - ERD) e sincronização (*Event Related Synchronization* - ERS) elétrica que se referem, respectivamente, à diminuição e ao aumento de energia em uma determinada região cortical, devido à desativação ou ativação do sistema neural [8].

Sistemas de imagética motora são compostos por dois subsistemas de processamento: uma técnica de extração de características, seguida pela aplicação de um classificador [6].

Diversas técnicas têm sido utilizadas para a extração de características, como por exemplo: a técnica de padrões espaciais comuns (*Common Spatial Patterns* - CSP) [6], a Transformada de Fourier de Tempo Curto [3], algoritmos genéticos [9], bancos de filtros [10] e o uso de desigualdades matriciais lineares [11] [12].

O CSP tem se apresentado como uma das técnicas mais populares e eficientes na extração de características para imagética motora [6]. Ele é um método de projeto de filtros espaciais para maximizar a discriminação entre padrões associados às ações motoras de um indivíduo.

Existem também várias possibilidades para o processo de classificação, entre elas: análise de discriminantes lineares de Fisher (*Fisher Linear Discriminant Analysis* - FLDA) [2], máquinas de vetores de suporte (*Support Vector Machines* - SVM) [7] e ferramentas de *Riemann* [11] [12] [13].

Neste trabalho é apresentada uma nova proposta para a formação da matriz de informações utilizada pelo método CSP em um sistema BCI de imagética motora. Adicionalmente à informação espacial convencionalmente utilizada, é incluída informação da correlação (intra e inter-eletrodos) entre as diversas épocas disponíveis do sinal EEG. Na seção II, os métodos CSP e FLDA são introduzidos; enquanto que na seção III é apresentada a nova proposta. Na seção IV são descritos os materiais e métodos utilizados e na seção V são apresentados os resultados obtidos. Na seção VI é apresentada a conclusão do trabalho.

Ao longo desse texto, letras maiúsculas e minúsculas em negrito representam, respectivamente, matrizes e vetores. Letras em itálico são escalares.

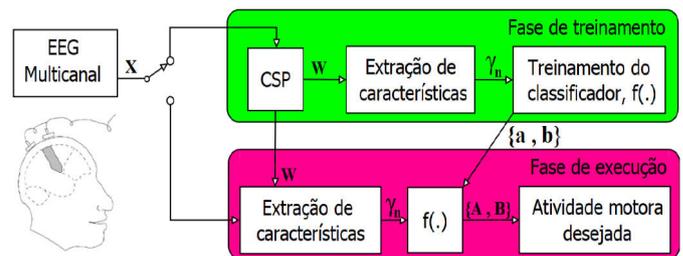


Fig. 1. Fluxograma do sistema BCI.

## II. CLASSIFICADOR CSP-FLDA PARA BCI

A literatura científica na área de interfaces cérebro-máquina baseadas em imagética motora apresenta diversos métodos para a classificação do EEG. Entre as técnicas mais empregadas encontra-se o método CSP-FLDA que é composto por três etapas principais: (a) filtragem espacial; (b) extração de características; e (c) classificação (Fig. 1).

### A. Método de Padrões Espaciais Comuns

O CSP é um método utilizado para o projeto de filtros espaciais que tem como objetivo, obter uma discriminação ótima entre duas classes de sinais. Isso é obtido pela maximização da variância dos sinais de uma classe em contraposição à minimização da variância da outra [6]. O sinal resultante é determinado por uma combinação linear dos sinais EEG captados pelo conjunto de eletrodos em um determinado instante de tempo, de forma que:

$$y_n = \mathbf{w}^T \mathbf{x}_n \quad (1)$$

em que  $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_Q]^T$  é o vetor de coeficientes do filtro espacial;  $\mathbf{x}_n = [x_{n,1} \ x_{n,2} \ \dots \ x_{n,Q}]^T$  contém as amostras do EEG dos  $Q$  eletrodos no instante de tempo  $n$ ; e  $y_n$  é o sinal filtrado no instante  $n$ . Assumindo uma janela de tempo de  $P$  amostras de duração, denominada de época, na qual é esperada a ocorrência do processo de imagética motora, o procedimento de filtragem pode ser representado na forma vetorial, como:

$$\mathbf{y}_n = \mathbf{X}_n^T \mathbf{w}, \quad (2)$$

em que  $\mathbf{y}_n = [y_{n,1} \ y_{n,2} \ \dots \ y_{n,P}]^T$  é um vetor contendo os sinais processados para cada instante de tempo que compõe a época analisada, e

$$\mathbf{X}_n = [\mathbf{x}_n \ \mathbf{x}_{n+1} \ \dots \ \mathbf{x}_{n+P-1}], \quad (3)$$

é a matriz de sinais EEG da época analisada, com dimensão  $Q \times P$ . Os vetores de coeficientes ótimos são obtidos pela maximização/minimização do quociente generalizado de Rayleigh [6]:

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{C}_A \mathbf{w}}{\mathbf{w}^T \mathbf{C}_B \mathbf{w}}, \quad (4)$$

em que

$$\mathbf{C}_\rho = \frac{1}{N_\rho} \sum_{n=1}^{N_\rho} \mathbf{X}_n^\rho \mathbf{X}_n^{\rho T}, \quad (5)$$

A e B são as classes associadas ao problema de classificação;  $\rho \in \{A, B\}$ ;  $\mathbf{C}_\rho$  é a matriz de informações da classe  $\rho$ , convencionalmente constituída pelas potências inter e intra-eletrodos;  $\mathbf{X}_n^\rho$ , para  $n = 1, 2, \dots, N_\rho$ , refere-se a cada uma das  $N_\rho$  épocas, associadas à classe  $\rho$ , disponíveis para treinamento.

O problema de minimização/maximização da equação (4) pode ser resolvido observando que a função  $J(\mathbf{w})$  é invariante ao escalamento de  $\mathbf{w}$ , de tal forma que  $J(k\mathbf{w}) = J(\mathbf{w})$ , sendo  $k$  uma constante real. Dessa forma, encontrar os pontos críticos em (4) equivale a realizar o mesmo procedimento em  $\mathbf{w}^T \mathbf{C}_A \mathbf{w}$  sujeito à restrição  $\mathbf{w}^T \mathbf{C}_B \mathbf{w} = 1$  [6], assim:

$$\min_{\mathbf{w}} / \max_{\mathbf{w}} J(\mathbf{w}) = \mathbf{w}^T \mathbf{C}_A \mathbf{w} \quad \text{s. t. q. } \mathbf{w}^T \mathbf{C}_B \mathbf{w} = 1. \quad (6)$$

Usando o método do multiplicador de Lagrange em (6) chega-se em:

$$L(\lambda, \mathbf{w}) = \mathbf{w}^T \mathbf{C}_A \mathbf{w} + \lambda (\mathbf{w}^T \mathbf{C}_B \mathbf{w} - 1). \quad (7)$$

Derivando-se (7) e igualando-se a zero, chega-se ao problema clássico de autovalores e autovetores generalizados [5]:

$$\mathbf{C}_B^{-1} \mathbf{C}_A \mathbf{w} = \lambda \mathbf{w} \quad (8)$$

e, portanto, o conjunto de vetores de coeficientes que maximiza

a diferença entre as classes é determinado pelos autovetores de

$$\mathbf{Z} = \mathbf{C}_B^{-1} \mathbf{C}_A, \quad (9)$$

associados ao maior e menor autovalor [6].

### B. Extração de características

Uma vez determinados os vetores que maximizam a discriminação das classes desejadas (utilizando os sinais  $\mathbf{X}_n^\rho$  disponibilizados durante o processo de treinamento) é realizada a filtragem das épocas em avaliação:

$$\mathbf{Y}_n = \mathbf{W}^T \mathbf{X}_n, \quad (10)$$

em que  $\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \dots \ \mathbf{w}_K]$  é a matriz de vetores de coeficientes, de dimensão  $Q \times K$ ;  $K$  é o número de vetores (características extraídas); e  $\mathbf{Y}_n = [\mathbf{y}_1 \ \mathbf{y}_2 \ \dots \ \mathbf{y}_K]^T$  é a matriz de sinais processados. Os vetores de coeficientes são determinados a partir da escolha dos autovetores de  $\mathbf{Z}$  associados aos  $K/2$  maiores e menores autovalores. Se o número  $K$  de componentes for muito pequeno, a discriminação entre as classes poderá não ser efetiva. Por outro lado, valores elevados de  $K$  podem levar à condição de *overfitting* [4].

Finalmente, é realizada uma transformação não linear na matriz  $\mathbf{Y}_n$  de forma a aproximar a função densidade de probabilidade das amostras de cada linha a uma distribuição gaussiana [14]:

$$\gamma_n = \log(\text{var}(\mathbf{Y}_n)), \quad (11)$$

em que  $\text{var}(\mathbf{Y}_n)$  resulta em um vetor coluna em que cada linha ( $l$ ) é dada por  $\gamma_l = (1/P) \sum_{c=1}^P (y_{l,c} - m_l)^2$ ;  $m_l = (1/P) \sum_{c=1}^P y_{l,c}$  é a média da  $l$ -linha e  $y_{l,c}$  é o elemento da  $l$ -ésima linha e  $c$ -ésima coluna da matriz  $\mathbf{Y}_n$ .

### C. Classificação

O FLDA [6] é um classificador linear de baixo custo computacional que tem sido utilizado com sucesso em aplicações de BCI [15]. A classificação binária é realizada em um hiperplano definido por um vetor de pesos  $\mathbf{a} \in \mathfrak{R}^N$  e um *offset*  $b \in \mathfrak{R}$  determinados empiricamente a partir de um conjunto de treinamento de  $N_A + N_B$  vetores de características associados a ambas as classes. O critério de Fischer é utilizado para otimização de um de hiperplano [2] dado por:

$$f(\gamma_n) = \begin{cases} \mathbf{a}^T \gamma_n - b \geq 0 & \gamma_n \in \text{classe A} \\ \mathbf{a}^T \gamma_n - b < 0 & \gamma_n \in \text{classe B} \end{cases}, \quad (12)$$

em que  $\gamma_n$  é o vetor de características para a época  $n$  e o vetor de pesos é dado por:

$$\mathbf{a} = \frac{1}{2} (\mathbf{S}_A + \mathbf{S}_B)^{-1} (\mathbf{m}_A - \mathbf{m}_B), \quad (13)$$

em que  $\mathbf{m}_A$  e  $\mathbf{m}_B$  denotam as médias para as classes A e B, respectivamente, calculadas como:

$$\mathbf{m}_\rho = \frac{1}{N_\rho} \sum_{n=1}^{N_\rho} \gamma_{\rho,n}, \quad (14)$$

em que  $\rho \in \{A, B\}$  e as matrizes de correlação são definidas como:

$$\mathbf{S}_\rho = \frac{1}{N_\rho} \sum_{n=1}^{N_\rho} (\gamma_{\rho,n} - \mathbf{m}_{\rho,n}) (\gamma_{\rho,n}^T - \mathbf{m}_{\rho,n}). \quad (15)$$

O parâmetro de *offset* é calculado como:

$$b = \frac{1}{2} \mathbf{a}^T (\mathbf{m}_A + \mathbf{m}_B). \quad (16)$$

### III. MATRIZ DE INFORMAÇÕES ESTENDIDA

O método CSP-FLDA, amplamente utilizado em aplicações de imagética motora [2] [5] faz uso de uma matriz de informações espaciais associadas à distribuição dos sinais de EEG ao longo do escalpo. Particularmente, a imagética motora das mãos está associada aos ritmos  $\mu$  (córtex motor) e  $\beta$  (regiões anteriores) [2]. Esses ritmos possuem características de amplitude e frequência bem definidas, o que possibilita a sua identificação por sistemas especialistas.

A informação empregada comumente em classificadores CSP-FLDA utiliza estimativas de um conjunto de momentos de segunda ordem inter-eletrodos dentro de uma determinada época. Essas correlações podem ser visualizadas substituindo-se (3) em (5) e tomando-se seu valor esperado, de forma que:

$$E\{\mathbf{C}_\rho\} = P \times \begin{bmatrix} E\{x_{\rho,n,1}^2\} & E\{x_{\rho,n,1}x_{\rho,n,2}\} & \cdots & E\{x_{\rho,n,1}x_{\rho,n,Q}\} \\ E\{x_{\rho,n,2}x_{\rho,n,1}\} & E\{x_{\rho,n,2}^2\} & \cdots & E\{x_{\rho,n,2}x_{\rho,n,Q}\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{x_{\rho,n,Q}x_{\rho,n,1}\} & E\{x_{\rho,n,Q}x_{\rho,n,2}\} & \cdots & E\{x_{\rho,n,Q}^2\} \end{bmatrix}, \quad (17)$$

ou ainda

$$E\{\tilde{\mathbf{C}}_\rho\}_{l,c} = P \times E\{x_{\rho,n,l}x_{\rho,n,c}\}, \quad (18)$$

em que  $l$  e  $c$  correspondem a  $l$ -ésima linha e  $c$ -ésima coluna da matriz  $\mathbf{C}_\rho$ . Dessa forma verifica-se que as informações espaciais estão associadas às potências dos sinais de cada canal e às suas correlações cruzadas para uma determinada época (instante de tempo).

No presente trabalho propõe-se expandir o conjunto de informações contidos na matriz de informação original do método CSP, através da inclusão de momentos de segunda ordem contendo correlações para  $(L)$  atrasos não nulos (diferentes épocas) entre os diferentes canais. Essas correlações adicionais são obtidas diretamente das matrizes de épocas  $\mathbf{X}_n^\rho$ , originalmente utilizadas para a obtenção de  $\mathbf{C}_\rho$ , ou seja, sem acréscimo de novos sinais. Com esse procedimento deseja-se não apenas utilizar informações referentes à sincronização e dessincronização (potência) de eventos, como também informação temporal relevante, associada às estatísticas dos ritmos envolvidos em um mesmo eletrodo, como também às correlações entre os sinais dos eletrodos no escalpo do paciente para diferentes atrasos (*lags*). Dessa forma, propõe-se a nova matriz de épocas como:

$$\tilde{\mathbf{X}}_n = [\tilde{x}_{n,1,0} \ \tilde{x}_{n,1,1} \ \cdots \ \tilde{x}_{n,1,L} \ \tilde{x}_{n,2,0} \ \tilde{x}_{n,2,1} \ \cdots \ \tilde{x}_{n,2,L} \ \cdots \ \tilde{x}_{n,Q,0} \ \cdots \ \tilde{x}_{n,Q,L}]^T, \quad (19)$$

em que  $\tilde{\mathbf{X}}_n$  possui dimensão  $Q(L+1) \times (P-L)$   $\tilde{x}_{n,q,l} = [x_{n,q}(1+l) \ x_{n,q}(2+l) \ \cdots \ x_{n,q}(P-L+l)]^T$ . Como resultado, os elementos da nova matriz de informações são descritos por:

$$\tilde{\mathbf{C}}_\rho = \sum_{n=1}^{N_\rho} \tilde{\mathbf{X}}_n \tilde{\mathbf{X}}_n^T. \quad (20)$$

Tomando-se o valor esperado de (20), a nova matriz de informações proposta é dada por:

$$E\{\mathbf{C}'_\rho\} = P \times$$

$$\begin{bmatrix} E\{\tilde{x}_{\rho,n,1,0}^2\} & E\{\tilde{x}_{\rho,n,1,0}\tilde{x}_{\rho,n,1,1}\} & \cdots & E\{\tilde{x}_{\rho,n,1,0}\tilde{x}_{\rho,n,Q,L}\} \\ E\{\tilde{x}_{\rho,n,1,1}\tilde{x}_{\rho,n,1,0}\} & E\{\tilde{x}_{\rho,n,1,1}^2\} & \cdots & E\{\tilde{x}_{\rho,n,1,1}\tilde{x}_{\rho,n,Q,L}\} \\ E\{\tilde{x}_{\rho,n,1,2}\tilde{x}_{\rho,n,1,0}\} & E\{\tilde{x}_{\rho,n,1,2}\tilde{x}_{\rho,n,1,1}\} & \cdots & E\{\tilde{x}_{\rho,n,1,2}\tilde{x}_{\rho,n,Q,L}\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{\tilde{x}_{\rho,n,Q,L}\tilde{x}_{\rho,n,1,0}\} & E\{\tilde{x}_{\rho,n,Q,L}\tilde{x}_{\rho,n,1,1}\} & \cdots & E\{\tilde{x}_{\rho,n,Q,L}^2\} \end{bmatrix}, \quad (21)$$

ou ainda

$$E\{\tilde{\mathbf{C}}_\rho\}_{l,c} = P \times E\{\tilde{x}_{\rho,n,a_1,b_1}\tilde{x}_{\rho,n,a_2,b_2}\} \quad (22)$$

em que

$$a_1 = \left\lfloor \frac{(l-1)}{(L+1)} \right\rfloor + 1, \quad a_2 = \left\lfloor \frac{(c-1)}{(L+1)} \right\rfloor + 1$$

$$\begin{cases} b_1 = L, & u_1 = 0 \\ b_1 = u_1 - 1, & u_1 > 0 \end{cases}, \quad \begin{cases} b_2 = L, & u_2 = 0 \\ b_2 = u_2 - 1, & u_2 > 0 \end{cases} \quad (23)$$

$$u_1 = \text{mod}(l, (L+1)), \quad u_2 = \text{mod}(c, (L+1))$$

em que  $a_1$  e  $a_2$  correspondem aos eletrodos e  $b_1$  e  $b_2$  aos atrasos, nas posições dadas respectivamente pelo par de  $l$  e  $c$  na matriz  $\tilde{\mathbf{C}}_\rho$ . O operador  $\text{mod}\{\cdot\}$  resulta no resto da divisão de seu argumento.

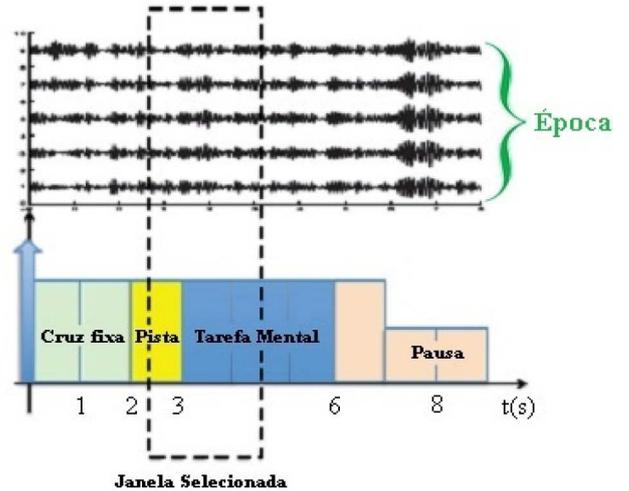


Fig. 2. Protocolo de imagética motora.

### IV. MATERIAIS E MÉTODOS

Os sinais utilizados para validação do método proposto pertencem à 4ª competição de BCI, realizada em 2008 [16]. Os sinais contêm quatro classes: mão esquerda, mão direita, pés e língua. Nesse trabalho foram selecionados apenas sinais associados aos movimentos de mão direita e esquerda. Estão disponíveis sinais de nove sujeitos (referidos como  $S_1$  a  $S_9$ ). O mastoide esquerdo é adotado como referência e o direito como potencial de terra. São 2592 épocas disponíveis, metade delas utilizadas para treinamento e a outra para validação. Para realizar uma comparação justa, todos os métodos analisados têm acesso ao mesmo conjunto de sinais EEG (22 canais, 500 amostras = 1 época), resultando matrizes  $\tilde{\mathbf{X}}_n$  com diferentes dimensões para diferentes valores de  $L$ .

#### A. Geração dos Sinais de Imagética Motora

No banco de dados utilizado, os sinais de EEG para imagética motora foram gerados utilizando o seguinte protocolo (Fig. 2) [16]. O voluntário está sentado em uma cadeira em frente a um monitor de vídeo. No início do experimento ( $t = 0s$ ),

a imagem de uma cruz de fixação aparece na tela, em conjunto com um aviso sonoro. Dois segundos depois ( $t = 2s$ ) uma pista visual, na forma de uma flecha apontando para a esquerda, direita, cima ou baixo (correspondendo a quatro classes) aparece na tela, permanecendo por 1,25s. Essa pista indica que o voluntário deve executar a tarefa de imagética motora desejada até que a cruz de fixação desapareça da tela, o que ocorre em  $t = 6s$ . Uma pequena pausa é realizada, de 6 a 7s, e uma nova sequência é iniciada. Cada época  $\mathbf{X}_n$  é selecionada a partir de um *offset* de tempo após a indicação da pista visual, apresentando uma duração que pode variar entre 1 e 2s [6] [7].

### B. Comparação entre técnicas

O desempenho do método proposto foi comparado com o método CSP-LDA convencional e mais oito classificadores previamente apresentados na literatura [6]. De forma inversa ao procedimento realizado em [6], primeiramente foi realizada a filtragem passa-faixa (Butterworth de 5ª ordem com banda passante entre 8-30 Hz) e em sequência selecionada uma janela de 2s (época) do sinal para construção da matriz de informação. Dessa forma, os resultados obtidos não são idênticos aos apresentados em [6].

### C. Medidas de desempenho

O desempenho dos classificadores foi avaliado pela acurácia de classificação. Esse critério utiliza os termos da matriz de confusão, sendo calculado para duas classes: mão direita e mão esquerda. A acurácia é definida como:

$$Ac = 100 \frac{V_N + V_P}{V_N + V_P + F_N + F_P}, \quad (24)$$

em que  $V_N$  representa os verdadeiros negativos,  $V_P$  os verdadeiros positivos,  $F_N$  falsos negativos e  $F_P$  os falsos positivos. De acordo com [5], uma acurácia maior que 70% é adequada para comunicação em sistemas BCI.

### D. Análise Estatística

Foram aplicados testes estatísticos para a verificação dos resultados obtidos. Utilizaram-se as acurácias obtidas em 100 realizações do processo de separação aleatória do banco de dados, em conjuntos de treinamento (50%) e validação (50%), garantindo o mínimo de 20% de diferença nas 1296 épocas de cada conjunto e mesmo número de sinais de cada sujeito.

Dois métodos são aplicados: (1) comparações entre múltiplos espaços amostrais (Tabelas I e III); e (2) entre dois espaços amostrais (Tabela II). A hipótese nula é denotada como  $H_0$ .

Para o primeiro caso, foi utilizado o teste de Shapiro Wilk (SW) nos resíduos do espaço amostral ( $H_0$ : o espaço amostral possui distribuição Gaussiana, nível de significância  $\alpha = 0,01$ ): (a) Em caso de gaussianidade, a esfericidade das distribuições foi avaliada pelo teste de Mauchly ( $\xi < 0,05$ ). Em sequência, foi aplicado o teste de ANOVA ( $H_0$ : todos espaços amostrais possuem mesma média,  $\alpha = 0,01$ ) com medidas repetidas nas amostras cruas em caso de esfericidade, ou nas amostras corrigidas pelos métodos de Greenhouse-Geisser ou Huynh-Feldt, em caso contrário. Comparações múltiplas foram realizadas através do teste de Bonferroni ( $H_0$ : espaços amostrais possuem mesma média,  $\alpha = 0,05$ ). (b) Para amostras não gaussianas, foi aplicada a transformação de boxcox e reaplicado o teste SW. Em caso de normalidade das amostras transformadas foi aplicado o teste ANOVA de medidas repetidas nos dados crus, em caso de esfericidade, ou nas amostras sujeitas à correção de Greenhouse-Geisser ou Huynh-

Feldt, em caso contrário. Caso a normalidade das amostras tenha sido rejeitada foi aplicado o teste de Friedman e em sequência realizadas comparações múltiplas através do teste de Dunn-Bonferroni.

No caso de comparações entre pares, foi aplicado o teste SW e em caso de normalidade foi utilizado o teste T bilateral ( $H_0$ : espaços amostrais possuem mesma média,  $\alpha = 0,05$ ). Caso contrário, foi realizada a transformação de boxcox. Caso obtenha-se normalidade das amostras transformadas, então é aplicado o teste T bilateral ou, em caso contrário, o teste bilateral de Wilcoxon de postos sinalizados ( $H_0$ : espaços amostrais possuem mesma mediana,  $\alpha = 0,05$ ).

## V. RESULTADOS

Nesse trabalho, o método CSP-FLDA, originalmente apresentado em [7], é chamado de CSP clássico ou abordagem clássica, correspondendo ao caso  $L = 0$  na matriz  $\tilde{\mathbf{X}}_n$ . A abordagem proposta consiste no método CSP-FDLA utilizando a matriz de informação estendida  $\tilde{\mathbf{X}}_n$  para  $L \geq 1$ .

Os maiores desempenhos obtidos são apresentados em negrito nas tabelas fornecidas. Na existência de mais de um valor em negrito assume-se que não há diferença estatística significativa entre eles.

### A. Informação Temporal

Inicialmente foi realizada uma comparação entre o método CSP-FDLA clássico e o proposto. Foram calculados resultados da acurácia para  $L = \{1, 2, \dots, 5\}$  na matriz  $\tilde{\mathbf{X}}_n$ . Foi utilizado um *offset* de 0,5s e 3 pares de filtros espaciais para a extração de características, conforme recomendado em [6].

A Tabela 1 apresenta as médias e desvios padrões obtidos para a distribuição de acurácias. Note-se que para  $L = 3$  há uma melhora global de desempenho de aproximadamente 4% (assumindo todos os sujeitos) em relação ao método clássico. De forma individual, para o sujeito  $S_5$ , a utilização de  $L = 5$  aumenta a acurácia média em aproximadamente 32%.

TABELA I. ACURÁCIA DO MÉTODO CSP-LDA PARA IMAGÉTICA MOTORA DE MÃO DIREITA E ESQUERDA. EM NEGRITO AS MAIORES ACURÁCIAS.

	$L = 0$	$L = 1$	$L = 2$	$L = 3$	$L = 4$	$L = 5$
$S_1$	88,7±2,4	93,6±2,0	93,1±1,8	<b>93,8±1,8</b>	93,2±1,9	92,8±2,2
$S_2$	<b>58,1±4,3</b>	<b>58,9±4,2</b>	<b>57,2±4,5</b>	<b>57,7±5,1</b>	<b>57,2±4,9</b>	56,4±4,6
$S_3$	97,1±1,1	97,1±1,1	97,6±1,0	97,6±1,0	<b>97,8±0,9</b>	97,6±1,1
$S_4$	<b>68,7±4,0</b>	<b>69,0±3,7</b>	<b>68,4±4,5</b>	66,5±4,2	66,6±4,7	65,5±4,8
$S_5$	58,7±4,0	66,8±3,6	83,6±2,7	89,5±2,2	90,2±2,2	<b>90,4±2,4</b>
$S_6$	67,1±3,1	<b>71,1±3,5</b>	70,0±4,7	68,6±4,9	66,6±4,5	65,3±4,8
$S_7$	80,1±3,0	83,5±3,5	<b>83,6±4,3</b>	80,8±4,5	81,9±4,9	80,9±5,0
$S_8$	<b>96,9±1,3</b>	<b>97,0±1,5</b>	96,4±1,5	<b>96,6±1,4</b>	<b>96,8±1,3</b>	<b>97,2±1,2</b>
$S_9$	<b>93,8±1,4</b>	<b>93,1±1,6</b>	<b>93,3±1,6</b>	<b>93,3±1,6</b>	<b>93,1±1,5</b>	<b>93,0±1,6</b>
$\mu \pm \sigma$	78,8±15	81,1±14	82,6±14	<b>82,7±14</b>	82,6±15	82,1±15

### B. Número de Canais

De forma a verificar o impacto do número de canais no desempenho da estratégia proposta foi realizado um experimento utilizando apenas sete canais ( $C_1, C_2, C_3, C_4, C_5, C_6, C_7$ , sistema 10-20). Foi considerado o seguinte espaço de busca para os parâmetros requeridos: de 1 a 6 pares de filtros espaciais; *offset* de 0,3s a 0,7s em passos de 0,1s; e  $L = \{1, 2, \dots, 5\}$ . A acurácia (média e desvio padrão) de cada sujeito é apresentada para sua configuração ótima dentro do

espaço de busca (configurações distintas para cada sujeito). A Tabela II apresenta os resultados obtidos para os nove sujeitos. Os resultados obtidos para  $S_2$  e  $S_4$  não apresentam diferença estatística. Apenas para  $S_9$  o método clássico apresenta desempenho superior ao proposto. O aumento global de desempenho de classificação obtido com o método proposto é de 4,5%. No caso do sujeito  $S_5$ , esse aumento é de 26,6%.

TABELA II. COMPARAÇÃO ENTRE O MÉTODO CSP-FLDA PROPOSTO E O CLÁSSICO, USANDO 7 CANAIS DE EEG. EM NEGRITO AS MAIORES ACURÁCIAS.

	CSP clássico	CSP proposto	$\xi$
$S_1$	87,7±2,3	<b>88,9±2,6</b>	$4,1 \times 10^{-7}$
$S_2$	<b>54,2±3,4</b>	<b>54,6±3,4</b>	$3,2 \times 10^{-1}$
$S_3$	95,7±1,1	<b>96,3±1,4</b>	$8,4 \times 10^{-5}$
$S_4$	<b>65,8±3,6</b>	<b>66,1±3,2</b>	$3,9 \times 10^{-1}$
$S_5$	60,8±3,3	<b>87,4±2,5</b>	$5,7 \times 10^{-84}$
$S_6$	64,9±3,4	<b>67,5±3,2</b>	$4,1 \times 10^{-11}$
$S_7$	63,7±3,6	<b>71,2±3,7</b>	$2,2 \times 10^{-36}$
$S_8$	90,2±2,1	<b>91,8±2,0</b>	$6,4 \times 10^{-10}$
$S_9$	<b>93,8±1,4</b>	93,3±1,4	$9,8 \times 10^{-6}$
$\mu \pm \sigma$	75,2±15,6	<b>79,7±14,3</b>	$5,0 \times 10^{-54}$

### C. Comparação entre Técnicas

A Tabela III apresenta os resultados da comparação entre o método proposto e os nove classificadores analisados em [6], incluindo o método clássico. Os resultados indicam que em 7 dos 9 sujeitos é obtida uma acurácia média igual ou maior as dos outros métodos. Verifica-se também que em 3 dos 9 participantes a acurácia obtida é significativamente maior que a dos demais métodos. Por outro lado, os sujeitos  $S_2$ ,  $S_6$  e  $S_8$  apresentam desempenho de classificação similar, independentemente do método utilizado. O método proposto apresenta uma média global de classificação pelo menos 3,3% maior que todos os outros métodos.

## VI. CONCLUSÃO

Esse trabalho apresentou uma nova proposta para a formação da matriz de informações do método CSP-FLDA em aplicações de imagética motora para interfaces cérebro-máquina. Comparações com outros métodos previamente apresentados na literatura indicam um aumento de pelo menos 3,3% na acurácia de classificação global, podendo atingir 32% de aumento em um determinado indivíduo. Testes estatísticos suportam a premissa que a informação temporal incluída na matriz de informações aumenta o desempenho do classificador CSP-FLDA resultando, em média, em resultados mais acurados em comparação a um conjunto de classificadores previamente propostos.

TABELA III. COMPARAÇÃO ENTRE DIVERSOS CLASSIFICADORES E A TÉCNICA PROPOSTA. EM NEGRITO AS MAIORES ACURÁCIAS. EM VERMELHO, DISTRIBUIÇÕES IGUAIS, PORÉM INFERIORES À MAIOR ACURÁCIA. AS DISTRIBUIÇÕES SÃO COMPARADAS SOMENTE COM O MÉTODO PROPOSTO.

	$S_1$	$S_2$	$S_3$	$S_4$	$S_5$	$S_6$	$S_7$	$S_8$	$S_9$	$\mu \pm \sigma$
CSP proposto	<b>93,8±1,8</b>	<b>57,7±5,1</b>	<b>97,6±1,0</b>	66,5±4,1	<b>89,5±2,2</b>	<b>68,6±4,9</b>	<b>80,8±4,5</b>	<b>96,6±1,4</b>	<b>93,3±1,6</b>	<b>82,7±14,5</b>
CSP clássico	88,7±2,4	<b>58,1±4,3</b>	97,1±1,1	68,7±4,0	58,7±4,0	<b>67,1±3,1</b>	<b>80,1±3,0</b>	<b>96,9±1,3</b>	93,8±1,4	78,8±15,3
GLRCSP	88,1±2,8	<b>57,4±4,2</b>	97,0±1,1	70,0±3,3	57,8±4,0	<b>68,3±3,4</b>	78,9±4,2	<b>96,6±1,4</b>	<b>93,4±1,6</b>	78,6±15,4
CCSP1	88,2±2,7	<b>57,0±4,0</b>	96,9±1,2	70,0±3,4	57,1±4,7	<b>68,5±3,6</b>	79,1±4,0	<b>96,7±1,4</b>	<b>93,6±1,5</b>	78,6±15,5
CCSP2	88,5±2,7	<b>58,0±4,2</b>	97,1±1,0	<b>70,6±3,2</b>	60,4±4,2	<b>69,7±3,3</b>	<b>80,3±2,9</b>	<b>96,8±1,3</b>	<b>93,6±1,6</b>	79,4±14,8
DLCSPauto	88,9±2,4	<b>58,1±4,4</b>	97,1±1,1	68,7±3,9	58,7±4,1	<b>67,0±3,2</b>	<b>80,0±3,0</b>	<b>96,9±1,2</b>	93,9±1,4	78,8±15,4
DLCSPcv	88,2±2,9	<b>58,2±4,0</b>	96,9±1,2	68,1±3,5	57,3±4,2	<b>67,4±3,7</b>	<b>79,9±3,2</b>	<b>96,7±1,3</b>	93,7±1,5	78,5±15,6
DLCSPcvdiff	87,9±3,0	<b>56,6±4,6</b>	96,5±1,6	67,1±4,1	57,0±4,6	<b>66,7±4,4</b>	<b>79,2±4,1</b>	<b>96,3±1,7</b>	<b>93,5±1,6</b>	77,9±15,9
WTRCSP	89,1±2,6	<b>59,4±4,3</b>	96,9±1,3	68,4±3,5	58,0±3,9	<b>67,7±3,9</b>	<b>79,8±3,6</b>	<b>96,8±1,4</b>	93,9±1,6	78,9±15,3
SRSCP	88,8±2,7	<b>58,3±3,7</b>	97,0±1,1	68,2±3,6	58,4±4,4	<b>67,4±3,7</b>	<b>79,3±3,8</b>	<b>96,8±1,2</b>	<b>94,0±1,6</b>	78,7±15,5

## AGRADECIMENTOS

Agradeço a CAPES e ao CNPQ pelo apoio financeiro e a Universidade Federal de Santa Catarina pelos materiais utilizados e espaço cedido para elaboração do artigo.

## REFERÊNCIAS

- [1] T. Ebrahimi, J. M. Vesin, G. Garcia, "Brain-computer interface in multimedia communication", *IEEE Signal Processing Magazine*, v. 20, n. 1, pp. 14-24, 2003.
- [2] S. A. Belhadj, N. Benmoussat, M. D. Krachai, "CSP features extraction and FLDA classification of EEG-based motor imagery for brain-computer interaction", *International Conference on Electrical Engineering*, pp. 1-6, 2015.
- [3] J. Annett, "On knowing how to do things: a theory of motor imagery", *Cognitive Brain Research*, v. 3, n. 2, pp. 65-69, 1996.
- [4] B. Blanjertz et al, "Optimizing spatial filters for robust EEG single-trial analysis", *IEEE Signal Processing Magazine*, v. 25, n. 1, pp. 41-56, 2008.
- [5] J. Wolpaw, E. W. Wolpaw, *Brain-computer interfaces: principles and practice*, OUP USA, 2012.
- [6] F. Lotte, C. Guan, "Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms", *IEEE Transactions on Biomedical Engineering*, v. 58, n. 2, pp. 355-362, 2011.
- [7] S. Ge, R. Wang, D. Yu, "Classification of four-class motor imagery employing single-channel electroencephalography", *Plos One*, v. 9, n. 6, pp. 1-7, 2014.
- [8] E. B. Sadeghian, M. H. Moradi, "Fractal dimension for detection of ERD/ERS patterns in asynchronous brain computer interface", *International Conference on Bioinformatics and Biomedical Engineering*, pp. 560-563, 2008.
- [9] C. Yaacoub, C. Mhanna, S. Rihana, "A Genetic-based feature selection approach in the identification of left/right hand motor imagery for a brain-computer interface", *Brain sciences*, v. 7, n. 1, pp. 1-15, 2017.
- [10] A. Mahmood et al, "Classification of multi-class motor imagery EEG using four band common spatial pattern. *International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1034-1037, 2017.
- [11] C. Silva et al, "Towards a LMI approach to feature extraction improvements and classification by riemann distance", *International Conference on IEEE Control and Automation*, pp. 990-995, 2016.
- [12] C. Silva, R. Duarte, A. Trofino, "Feature extraction improvements using an LMI approach and Riemannian geometry tools: an application to BCI", *IEEE Conference on Control Applications*, pp. 966-971, 2016.
- [13] Y. Li, K. M. Wong, "Riemannian distances for signal classification by power spectral density", *IEEE Journal of Selected Topics in Signal Processing*, v. 7, n. 4, pp. 655-669, 2013.
- [14] H. Ramoser, J. Muller-Gerking, G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement", *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 4, pp. 441-446, 2000.
- [15] F. Lotte et al, "A review of classification algorithms for EEG-based brain-computer interfaces", *Journal of Neural Engineering*, v. 4, n. 2, pp. 1-28, 2007.
- [16] C. Brunner et al, "BCI Competition 2008 – Graz data set A". Disponível em: [http://www.bbci.de/competition/iv/desc\\_2a.pdf](http://www.bbci.de/competition/iv/desc_2a.pdf).