

Análise da otimização de sistemas BCI baseados em Imagética Motora através do Algoritmo Colônia Artificial de Abelhas

Danilo de Sousa Lopes¹, Demison Rolins de Souza Alves¹, Cleison Daniel Silva¹

¹Universidade Federal do Pará (UFPA)
Rodovia BR 422 km 13 – Canteiro de Obras UHE
Caixa Postal 68464-000 Tucuruí – PA – Brazil

danilo.sousa.lopes@tucuruui.ufpa.br, demison.alves@itec.ufpa.br, cleison@ufpa.br

Resumo. Neste artigo, são apresentadas novas contribuições quanto a otimização de sistemas de Interface Cérebro-Máquina baseados em Imagética Motora, através do uso das informações espectrais dos sinais de eletroencefalografia, para ponderar as matrizes de covariância e evidenciar as características discriminantes. Sendo necessário a utilização de uma matriz de pesos, parametrizada por duas funções de pertinência gaussianas, onde os melhores parâmetros são definidos através do Algoritmo Colônia de Abelhas Artificiais. Os sinais são classificados por meio do algoritmo Distância Mínima à Média Riemanniana e os experimentos utilizam o conjunto de dados IIa da IV Competição Internacional de Interface Cérebro-Máquina. Os resultados são satisfatórios em relação a abordagem do estado da arte, com ganhos de precisão consideráveis e as novas inferências mostram que o aumento do mapeamento das regiões do espectro do sinal, contribuem para uma maior assertividade da classificação dos padrões de imagética motora de diferentes sujeitos.

1. Introdução

A compreensão do funcionamento do cérebro e de como são estabelecidas as conexões neuronais com as outras partes do corpo, desperta grande interesse nas comunidades científicas [Silverthorn 2017]. O constante avanço em pesquisas nas áreas de neurociência comprovam que a integração com tecnologias computacionais intensificou descobertas e apresentou diversas possibilidades científicas em relação a aplicações de controle cognitivo [Abiri et al. 2019].

Esses fatores, tornaram possível o desenvolvimento de sistemas artificiais capazes de inferir, a partir do registro da atividade cerebral, o desejo motor ou de comunicação de pessoas com comprometimentos no sistema nervoso periférico (SNP), onde mais tarde ficaram conhecidos como Interfaces Cérebro-Máquina, do inglês *Brain-Computer Interface* - BCI.

Em [Silva et al. 2016] é proposto uma técnica que busca melhorar os estágios de extração e classificação de características em sistemas BCI que utilizam os biosinais de eletroencefalografia (EEG), como fontes de informação. A técnica consiste na representação dos sinais através de uma base senoidal em uma determinada faixa de frequência, gerando uma transformação no sinal e possibilitando a parametrização da matriz de covariância do sinal transformado, através de uma matriz de pesos relacionada à transformação.

Porém, definir os parâmetros de forma otimizada para garantir benefícios à performance do sistema BCI é o principal desafio. O trabalho de [Alves et al. 2022] apresenta uma solução utilizando o Algoritmo de Colônia de Abelhas Artificiais, do inglês *Artificial Bee Colony* - ABC, em conjunto a duas funções de pertinência gaussianas para destacar características discriminantes no domínio da frequência dos sinais de EEG e posteriormente classificá-los através do algoritmo Distância Mínima à Média Riemanniana, do inglês *Minimum Distance to Riemannian Mean* - MDRM, proposto por [Barachant et al. 2011]. Neste artigo, os resultados numéricos encontrados por [Alves et al. 2022], são analisados sob perspectivas frequências, sendo possível realizar novas inferências relacionadas à dinâmica de sistemas BCI baseados em IM.

2. Metodologia

A metodologia adotada neste trabalho se concentra na cadeia de processos fundamentais para o funcionamento de um sistema BCI, sendo eles: pré-processamento, extração de características e classificação.

A princípio, normalmente, os sinais brutos de EEG são pré-processados para a redução dos níveis de ruídos através da aplicação de técnicas computacionais específicas, por exemplo, técnicas de filtro. A abordagem proposta por [Silva et al. 2016], garante uma alternativa para os filtros temporais clássicos, onde os sinais de EEG são projetados em uma base de sinais ortogonais formados por senoides.

A extração de características de sinais de EEG para fins de classificação, de modo geral, busca fornecer uma representação compacta dos sinais e também com as propriedades que evidenciam as diferenças entre as classes de interesse. Em sistemas BCI, frequentemente, os algoritmos de classificação não utilizam-se das matrizes de covariância explicitamente como *feature*, contudo, nas abordagens via classificadores baseados na Geometria Riemanniana as informações do espaço geométrico das matrizes são utilizadas diretamente como *feature*.

Isso se faz possível, pois as matrizes de covariância são por construção, matrizes simétricas e positivas semi-definidas. Em [Silva et al. 2016] as matrizes de covariância do sinal EEG são parametrizadas no domínio da frequência através da matriz pesos, usada para ponderar as informações frequenciais contidas nos sinais e realçar as características discriminantes. A matriz de pesos tem como restrição, ser simétrica positiva semidefinida, uma maneira eficiente para defini-la dessa forma, é usá-la como uma matriz diagonal positiva, porém, ainda será necessário um alto custo computacional sendo mais suscetível a sobre-ajustes. Em [Alves et al. 2022] é adotado o uso de duas funções de pertinência gaussianas para prover ao problema os elementos da matriz diagonal, a clássica na Equação (1) e a modificada pela Equação (2):

$$y(x, c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (1)$$

onde x é a frequência que desejamos ponderar; c é a média e σ o desvio padrão.

$$z(x, c_1, c_2, \sigma_1, \sigma_2) = \max\left(e^{-\frac{(x-c_1)^2}{2\sigma_1^2}}, e^{-\frac{(x-c_2)^2}{2\sigma_2^2}}\right) \quad (2)$$

em que x é a frequência que desejamos ponderar; c_1 e c_2 são as médias 1 e 2, respectivamente; σ_1 e σ_2 são os desvios padrão 1 e 2, respectivamente. As variáveis, média e desvio padrão, para construção das funções são definidas e otimizadas através do algoritmo ABC.

Por fim, a classificação é feita por meio do algoritmo MDRM, que usa as matrizes de covariância dos sinais de EEG como *feature* para classificação e a geometria de Riemann. Nota-se a importância de destacar que o algoritmo é determinístico e apresenta ausência de parâmetros para ajuste, logo a proposta apresentada [Silva et al. 2016] e em seguida modificada por [Alves et al. 2022] torna a abordagem via MDRM mais flexível, pois há a introdução de graus de liberdade observados na construção das matrizes de covariância.

3. Experimento

Nesta seção iremos analisar os resultados obtidos através da metodologia proposta por [Alves et al. 2022] e apresentar as novas inferências, quanto a dinâmica de sistemas BCI baseados em IM. Os resultados para as duas estratégias gaussianas (Equações 1 e 2) são representados, respectivamente, por $W \leftarrow ABC_{2d}$ e $W \leftarrow ABC_{4d}$, onde d faz referência ao número de parâmetros otimizados.

O *dataset* utilizado está disponível no repositório público da IV Competição Internacional de Sistemas BCI ¹, em que o conjunto de dados IIa é utilizado, contendo os sinais de EEG de 9 sujeitos fragmentados em quatro classes: a imagética motora da mão esquerda (classe 1), da mão direita (classe 2), dos pés (classe 3) e da língua (classe 4), contudo, os experimentos realizados foram conduzidos por uma classificação binária apenas entre os dados da classe 1 e 2.

3.1. Resultados

A primeira vista nota-se que a partir dos resultados gráficos obtidos apresentados na Figura 1, para os sujeitos 3 e 8 com a abordagem ABC_{2d} , as funções gaussianas selecionam os dois principais ritmos sensoriais motores, μ_r entre $7Hz$ e $12Hz$ e β_r entre $13Hz$ e $30Hz$. Para os respectivos sujeitos uma abordagem com mais funções gaussianas poderia mapear outras bandas do espectro do sinal de EEG e proporcionar maiores taxas de acerto para o sistema BCI ao introduzir graus de liberdade adicionais.

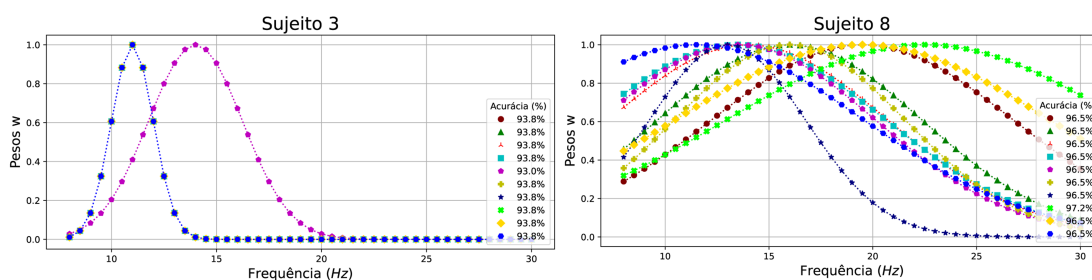


Figura 1. As dez melhores funções gaussianas e seus resultados em termos de acurácia para os sujeitos 3 e 8, obtidas pelo Algoritmo ABC usando a abordagem ABC_{2d}

A abordagem ABC_{4d} por sua vez, adicionou graus liberdade para o sistema BCI, o que permitiu às funções gaussianas apresentarem uma melhor distribuição nas bandas de frequências e contribuiu para o aumento do mapeamento das regiões do espectro do sinal

¹<https://www.bbc.de/competition/iv/>

de EEG. Em termos de acurácia, para os sujeitos 5, 7 e 9 obteve-se melhores resultados, enquanto para os sujeitos 6 e 8 a abordagem ABC_{2d} apresentou resultados superiores. Na Tabela 1 é apresentado o comparativo entre as duas abordagens e o método de referência.

Tabela 1. A média do resultado em termos de acurácia das dez melhores funções gaussianas dos 9 sujeitos para as abordagens $W \leftarrow ABC_{2d}$, $W \leftarrow ABC_{4d}$ em contraste ao método de Referência [Congedo et al. 2013].

Sujeitos	1	2	3	4	5	6	7	8	9
$W \leftarrow ABC_{2d}$	88.96	57.57	93.68	70.07	66.67	73.47	82.43	96.60	90.28
$W \leftarrow ABC_{4d}$	90.00	59.17	92.85	68.82	67.85	72.99	83.33	96.53	92.15
Referência	93.75	63.19	94.44	75.00	63.19	71.53	72.92	96.53	91.67

4. Conclusão

Aprimorar a eficiência dos sistemas BCI baseados em IM, ainda é um grande desafio apresentado na literatura, sendo motivo de interesse por muitos pesquisadores. Neste artigo, foram realizadas novas inferências quanto a otimização de tais sistemas através do uso do Algoritmo ABC, que garantiu adicionar graus de liberdade para melhorar as etapas de extração e classificação de características dos sinais de EEG.

Os resultados sugerem que o aumento do mapeamento das regiões do espectro do sinal de EEG é um caminho promissor para garantir mais robustez aos sistemas, devido à alta variabilidade dos padrões de IM observados entre os sujeitos. As duas abordagens analisadas, $W \leftarrow ABC_{2d}$ e $W \leftarrow ABC_{4d}$, apresentaram resultados satisfatórios em relação ao método de referência, com ganhos de precisão em alguns casos, aumentando a assertividade da classificação dos padrões de IM de diferentes sujeitos, através do modelo MDRM.

Referências

- Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., and Zhao, X. (2019). A comprehensive review of eeg-based brain-computer interface paradigms. *Journal of neural engineering*, 16(1):011001.
- Alves, D. R., Teixeira, O. N., and Silva, C. D. (2022). Feature weighting on eeg signal by artificial bee colony for classification of motor imaginary tasks. In *International Conference on Sensing and Imaging*, pages 301–310. Springer.
- Barachant, A., Bonnet, S., Congedo, M., and Jutten, C. (2011). Multiclass brain-computer interface classification by riemannian geometry. *IEEE Transactions on Biomedical Engineering*, 59(4):920–928.
- Congedo, M., Barachant, A., and Andreev, A. (2013). A new generation of brain-computer interface based on riemannian geometry. *arXiv preprint arXiv:1310.8115*.
- Silva, C., Duarte, R., Goulart, R., and Trofino, A. (2016). Towards a lmi approach to feature extraction improvements and classification by riemann distance. In *2016 12th IEEE International Conference on Control and Automation (ICCA)*, pages 990–995. IEEE.
- Silverthorn, D. U. (2017). *Fisiologia humana: uma abordagem integrada*. Artmed editora.