

CLASSIFICANDO MOTOR IMAGERY USANDO REDES ORDINAIS

Angelo A. Flores (PIBIC/CNPq/UEM), Haroldo V. Ribeiro (Orientador).
E-mail: ra129251@uem.br

Universidade Estadual de Maringá, Centro de Ciências Exatas, Maringá, PR

Área e subárea do conhecimento: Física, Física Geral/ Física Estatística

Palavras-chave: Métodos Ordinais, *Motor Imagery*, Análise de Dados

RESUMO

Um dos grandes desafios da neurociência é a correta classificação das chamadas *motor imagery* - a prática de mentalmente simular um movimento sem realmente executá-lo - na construção de interfaces cérebro-máquina (ICM). No presente trabalho, apresentamos uma abordagem para a classificação de estados mentais simples utilizando o espectro de frequências de eletroencefalográficos e a entropia temporal de primeiros vizinhos.

INTRODUÇÃO

O uso de *motor imagery* (MI) tem despertado interesse de pesquisadores desde os primórdios da aplicação de métodos computacionais à análise de sinais cerebrais. Esse interesse se justifica pelas diversas aplicações potenciais, como em interfaces cérebro-máquina (ICM) e na reabilitação de pessoas com paralisia, vítimas de acidente vascular cerebral, entre outras condições clínicas. Tradicionalmente, grande parte das análises de sinais eletroencefalográficos (EEG) se baseia em métodos espectrais, sendo a transformada de Fourier uma ferramenta fundamental. No entanto, com o surgimento e consolidação de métodos ordinais, especialmente aqueles voltados à análise de padrões temporais e à construção de redes [1], assim como a expansão da entropia de permutação para dados não estruturados [2], um novo horizonte de possibilidades de análises a respeito do tema se abriu. Com isso, neste trabalho, investigamos a classificação de tarefas de *motor imagery* a partir de sinais de EEG utilizando abordagens matemáticas para a decomposição do sinal em suas componentes de frequência, usaremos também abordagens ordinais combinadas com técnicas de aprendizado de máquina. A seguir, apresentamos a metodologia adotada, os dados utilizados e os resultados obtidos.

MATERIAIS E MÉTODOS

O presente trabalho se baseia nos dados obtidos por Kaya *et al.* [3] e por Scalk *et al.* [4]. A primeira base de dados é composta por 13 triagens referentes a medidas feitas por um EEG no sistema 10/20 composto por 19 eletrodos. Na segunda base de dados, foi utilizado um EEG composto por 64 eletrodos, tendo assim uma resolução espacial maior, em 109 indivíduos. Nos dois casos os participantes foram instruídos a imaginar momentos bem determinados: a movimentação da mão

esquerda, da mão direita, e nenhum movimento. Esses momentos de imaginação do movimento (*motor imagery*) foram gravados com os devidos rótulos. Cada um durava entre 1,5 e 2,0 segundos; tais momentos são chamados de épocas. Os sinais foram submetidos a um filtro de frequência *high pass/low pass* de 0,1-60 Hz. E a uma filtragem utilizando o algoritmo *independent component analysis* (ICA). Analisamos as séries temporais dos EEG de cada época; como temos n medições simultâneas, fizemos a avaliação separadamente de cada série temporal. Inicialmente, aplicamos a transformada de Fourier discreta (o algoritmo é conhecido como FFT) em cada uma das séries temporais e utilizamos o espectro obtido, conforme exemplificado na Figura 1. Nos baseamos na hipótese que diferentes processos cognitivos são processados simultaneamente, porém em frequências diferentes. Dessa forma, a FFT permite separar os diferentes processos, conforme discutido por She *et al.*[5]. Com a FFT aplicado a cada série temporal de cada sensor, obtemos uma matriz de dimensão $n \times f$ sendo n a quantidade de eletrodos do EEG, e f a faixa de frequências em que estamos analisando (por exemplo, se estamos analisando de 2 a 32Hz, então $f = 30$ Hz). Cada elemento da matriz é um número complexo, onde a parte real é a intensidade da frequência na composição do sinal e a parte imaginária é a fase da componente. Utilizamos as componentes imaginárias da matriz para treinar o algoritmo de *machine learning* XGBoost com o número de estimadores fixo em 100. Novamente, a Figura 1 ilustra esse processo.




Figura 1 - Ilustração resumida do método utilizado para classificação de *motor imagery*.

Em uma segunda análise, utilizamos os dados apresentados por Scalk *et al.* [4], onde foram analisadas diferenças da dinâmica cerebral quando o indivíduo está submetido a estímulos visuais ou não. Cada uma das triagens contém um minuto com o indivíduo com os olhos fechados, seguido de um minuto com os olhos abertos. Para analisar tais seguimentos de dados, nos baseamos na premissa que quando submetido a estímulos visuais, a complexidade do cérebro deveria aumentar. Com isso, utilizamos de uma generalização derivada do formalismo de entropia de permutação de Brandt e Pompe [6] para dados não estruturados que evoluíram no tempo [2]. Temos como objetivo medir a entropia do EEG nos dois estados citados e comparar os valores para verificar se existe diferença significativa.

RESULTADOS E DISCUSSÃO

A Figura 2 mostra os resultados obtidos para a primeira base de dados, na qual uma acurácia média de 79% foi obtida classificando somente duas classes (mão esquerda ou mão direita) e de 70% o incluir o pensamento vazio. Na mesma figura temos o resultado para a segunda base de dados. Nessa, para reduzir o custo computacional, usamos o algoritmo ICA para eliminar artefatos, conduzindo a uma acurácia média de 57% na classificação das três classes. Já na classificação de mão esquerda e mão direita, o valor médio foi de 71%. Os resultados indicam a robustez do método e confirmam que mesmo com menor resolução espacial, conseguimos obter um alto índice de acerto na classificação. O método também tem boa capacidade de generalização para diferentes indivíduos.




Figura 2 - Resultado da classificação das *motor imagery* utilizando *XGBoost*. (a,b) Resultados da classificação para o primeiro conjunto de dados composto por 13 triagens. (c,d) Resultados para o segundo conjunto de dados composto por 109 triagens. Painéis a e c referem-se somente ao pensamento de mão direita ou esquerda e b e d incluem o pensamento vazio/

A Figura 3 mostra os resultados referentes à medição da complexidade em diferentes estímulos visuais (olhos abertos ou fechados). Realizamos a medida da entropia nos dois estados e verificamos a diferença nos valores em cada triagem. A distribuição dos valores obtidos é exibida na Figura 3. A fim de entender a influência da disposição espacial dos sensores, embaralhamos suas posições, e realizamos as mesmas medidas, o resultado também é exibido na mesma figura. Conforme podemos observar, a distribuição com as posições embaralhadas está centrada em zero, mostrando que a disposição espacial tem grande influência no comportamento da dinâmica cerebral, de forma que não podemos descartar a independência entre as regiões cerebrais.




Figura 3 - Diferença de entropia entre os estados de olhos abertos e fechados. A primeira distribuição mostra a distribuição obtida ao embaralhar as posições dos eletrodos; a segunda mostra a mesma distribuição para os eletrodos organizados em suas posições.

CONCLUSÕES

Mostramos que a decomposição espectral do EEG, combinada ao XGBoost, classifica *motor imagery* com desempenho consistente (79% para mão esquerda/direita e 70% incluindo o repouso; na base de 64 canais encontramos 71 e 57%, respectivamente), com boa generalização entre indivíduos. A análise de complexidade via entropia de permutação generalizada diferenciou olhos abertos/fechados e ressaltou a importância da organização espacial dos eletrodos; ao embaralhá-la, o efeito se anula, indicando que não se pode assumir independência entre regiões cerebrais.

AGRADECIMENTOS

Agradeço ao CNPq pelo financiamento e a Universidade Estadual de Maringá (UEM) pelo apoio à pesquisa e à ciência.

REFERÊNCIAS

- [1] Pessa, A. A. B. & Ribeiro, H. V. Characterizing stochastic time series with ordinal networks. *Physical Review E* 100, 042304 (2019).
- [2] Voltarelli, L. G. J. M. *et al.* Characterizing unstructured data with the nearest neighbor permutation entropy. *Chaos* 34, 053130 (2024).
- [3] Kaya, M., Binli, M. K., Ozbay, E., Yanar, H. & Mishchenko, Y. A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. *Scientific Data* 5, 180211 (2018)..
- [4] Schalk, G., McFarland, D. J., Hinterberger, T., Birbaumer, N. & Wolpaw, J. R. Bci2000: a general-purpose brain-computer interface (BCI) system. *IEEE Transactions on biomedical engineering* 51, 1034 (2004).
- [5] She, H.-C. *et al.* Eeg dynamics reflect the distinct cognitive process of optic problem solving. *PLOS ONE* 7, e40731 (2012).
- [6] Bandt, C. & Pompe, B. Permutation entropy: A natural complexity measure for time series. *Physical Review Letters* 88, 174102 (2002).