

# CLASSIFICAÇÃO DE SINAIS DE EEG PRODUZIDOS POR IMAGINAÇÃO DE DISCURSO PARA APLICAÇÃO EM BCIs

Palavras-Chave: EEG, BCI, RECONHECIMENTO-DE-DISCURSO-INTERNO

Autores(as):

EDUARDO ABREU, IFGW – UNICAMP

Prof<sup>ª</sup>. Dr<sup>ª</sup>. GABRIELA CASTELLANO, IFGW – UNICAMP

## INTRODUÇÃO:

Neste trabalho, investiga-se a possibilidade de utilizar sinais obtidos por eletroencefalografia (EEG) durante a tarefa de imaginação da fala de quatro comandos ("Arriba", "Abajo", "Derecha" e "Izquierda", espanhol para "Em cima", "Embaixo", "Direita" e "Esquerda" respectivamente) para aplicação em interfaces cérebro-computador (BCI, de *Brain-Computer Interface*). O banco de dados público intitulado "*Thinking out loud, an open-access EEG-based BCI dataset for inner speech recognition*" (Nieto et al., 2020) foi empregado para este propósito. Um método foi desenvolvido, envolvendo a filtragem dos sinais em diferentes faixas de frequências, o cálculo de conectividade funcional por sincronização de motifs e métricas de grafos. Essas etapas possibilitaram a extração de características que permitiram a classificação dos sinais relacionados a cada um dos quatro comandos, alcançando acurácia média de 85,6% para os 10 participantes do estudo, utilizando-se uma Máquina de Vetor de Suporte (SVM, de *support-vector machine*) para a classificação. Os resultados obtidos superam significativamente os de outros pesquisadores que utilizaram o mesmo banco de dados, demonstrando a eficácia dos métodos empregados neste estudo.

## METODOLOGIA:

### Banco de dados:

Toda análise realizada neste trabalho utiliza o banco de dados "*Thinking out loud, an open-access EEG-based BCI dataset for inner speech recognition*" (Nieto et al, 2020).

O conjunto de dados inclui registros de dez participantes destros e saudáveis (quatro mulheres) com uma idade média de 34 anos, todos sem deficiências auditivas ou de fala, ou experiência prévia com BCIs. Durante o experimento, os participantes foram submetidos a três condições distintas: discurso interno, discurso pronunciado e visualização. Na condição de discurso interno (usada nesta pesquisa), os participantes foram instruídos a mentalmente pronunciar a palavra correspondente a cada estímulo visual que aparecia em uma tela em sua frente. Os dados foram adquiridos através de um sistema de medição bioelétrica de alta resolução, registrando dados de EEG (128 eletrodos), eletro-oculografia (EOG) e eletromiografia (EMG). Os dados de EEG foram registrados a uma taxa de 1024 Hz. O paradigma de aquisição de dados seguiu o esquema mostrado na Figura 1. Os dados foram pré-processados com filtragem de banda, remoção de artefatos de piscar os olhos e *downsampling* para 254 Hz.




Figura 1 - Fluxo de trabalho Thinking Out Loud: Estímulos visuais eram apresentados aos indivíduos durante meio segundo para que nos dois segundos e meio subsequentes estes imaginassem a fala do comando referente à imagem observada. Intervalos de concentração, relaxamento e descanso também foram utilizados. Imagem extraída de (Niето et al, 2020).

## Processamento dos dados:

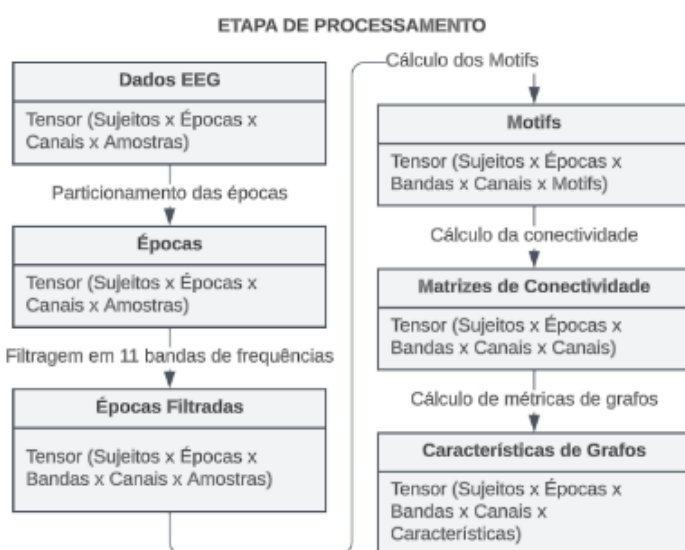


Figura 2 - Etapas do processamento dos dados.

Com o intuito de extrair características das amostras que permitissem uma melhor classificação dos dados, algumas etapas de processamento foram realizadas (Figura 2). Primeiramente, com o intuito de aumentar o número de amostras referente a cada classe, cada época de duração 2,5 s referente à ação de imaginação de fala dos comandos foi particionada em 4 épocas de 1 s (com sobreposição de 0,5 s). Em seguida, cada época foi filtrada em 11 bandas de frequências diferentes (12Hz-15Hz, 15Hz-18Hz, ..., 45Hz-48Hz) para que os sinais

pudessem ser analisados nessas faixas específicas.

Após a filtragem em diferentes bandas de frequências, cada série temporal foi transformada em uma sequência de motivos de grau 3 (Rosário et al., 2015), ou seja, cada sequência de 3 pontos consecutivos das amostras temporais foi etiquetada com seu respectivo motivo, como esquematizado na Figura 3.




Figura 3 - A) Possíveis variações entre 3 pontos consecutivos. B) Sequência de motivos obtida da série temporal. Figura extraída e editada da tese de mestrado de Carlos Stefano Filho (2016).

A partir das sequências de motivos obtidas para cada eletrodo, foi possível determinar uma medida de conectividade entre esses canais a partir do método de sincronização de motivos (Rosário et al., 2015). A conectividade é determinada como o maior número de coincidências ao se comparar duas sequências de motivos, deslocando a segunda sequência em uma, duas, e três unidades em relação à primeira. Esse atraso é utilizado pois espera-se obter relações de causalidade entre os sinais obtidos de diferentes áreas do cérebro e essas requerem intervalos de tempo para que informação se propague de uma área para outra. Dessa forma, foram construídas matrizes de conectividade representando as conectividades entre todos os pares de eletrodos.

A partir das matrizes de conectividade constroem-se grafos ponderados que podem ser caracterizados por métricas de grafos. Para cada nó, foram calculadas três métricas: a força do nó (soma das conexões que partem do nó), o grau de centralidade (soma das conexões que partem e que chegam ao nó) e a centralidade de autovetor, que mede a influência do nó na rede, ou seja, quão conectado um nó está a outros nós de alta conectividade. Assim, obtivemos, como produto final da etapa de processamento, 4224 características (3 para cada um dos 128 eletrodos para cada uma das 11 bandas de frequência) para cada amostra que será utilizada na etapa seguinte, de classificação.

### **Etapa de classificação:**

A classificação das amostras foi conduzida em duas etapas distintas. Inicialmente, avaliamos o poder discriminativo de cada característica individualmente utilizando o algoritmo SVM para classificação. O objetivo era ranquear essas características com base nas acurácias obtidas durante o processo. Na segunda etapa, investigamos o poder discriminativo ao combinar progressivamente conjuntos maiores das características que apresentaram as melhores acurácias na etapa inicial. Buscamos alcançar a melhor acurácia possível ao combinar essas características. Para medir as acurácias, dividimos os dados em 80% para treinar o modelo e 20% para testar o modelo.

## RESULTADOS E DISCUSSÃO:

A Tabela 1 mostra as acurácias obtidas por cada um dos 10 participantes na classificação das quatro classes, tanto quando utilizando apenas a característica que individualmente resulta na maior acurácia, quanto quando as características são utilizadas em conjunto

Participante	Acurácia (Característica individual)	Acurácia (Características Combinadas)	Número de Características Usadas
01	36,3%	88,1%	3995
02	35,3%	86,5%	3843
03	36,1%	82,6%	2875
04	34,9%	89,6%	3843
05	35,4%	83,9%	1923
06	35,8%	82,7%	3459
07	36,5%	84,9%	2883
08	40,0%	91,3%	4003
09	37,5%	83,3%	3835
10	34,4%	82,8%	3835
Média	36,2%	85,6%	3449,4

*Tabela 1 – Acurácias obtidas na classificação, com a característica mais discriminante, e com o conjunto de características que resultou na melhor acurácia possível.*

Os resultados mostram uma alta acurácia média, demonstrando a viabilidade do método proposto, baseado em conectividade funcional por sincronização de motifs, para discriminar sinais de EEG associados à imaginação de discurso. Além disso, esses resultados são notáveis ao serem comparados com outros estudos da literatura, como o de Gasparini e colegas (Gasparini et al., 2022), cuja acurácia máxima alcançada foi de 40,2%. Embora os resultados obtidos até agora sejam encorajadores, é importante ressaltar que novos estudos são necessários para avaliar a eficácia do método proposto em condições "em tempo real". A aplicação "em tempo real" envolve a análise de sinais de EEG em tempo imediato, o que pode ser afetado por fatores como variações no estado mental do indivíduo, interferências externas e

outros desafios presentes no mundo real.

## CONCLUSÕES:

Neste estudo, investigamos sinais de EEG gerados durante a imaginação de discurso com o objetivo de aplicá-los em BCIs. Para obter características relevantes dos sinais, empregamos a técnica de conectividade funcional por sincronização de motifs. Em seguida, utilizamos o classificador SVM para categorizar os sinais em quatro classes distintas: cima, baixo, direita e esquerda.

Os resultados alcançados demonstraram uma alta acurácia na classificação das quatro classes. Essa acurácia destacada sugere que o método proposto se apresenta como uma abordagem promissora na discriminação dos sinais de EEG relacionados à imaginação de discurso. Esses resultados são especialmente significativos quando comparados com estudos anteriores da literatura, nos quais as taxas de acurácia alcançadas não ultrapassaram 40,2%. A obtenção de uma acurácia superior reforça

a relevância e o potencial de aplicação do método proposto em BCIs, fornecendo uma base sólida para o desenvolvimento de BCIs mais eficazes e precisas.

No entanto, é importante destacar que nosso estudo se concentrou em uma avaliação offline dos sinais de EEG e sua classificação. Para validar plenamente a aplicabilidade do método proposto, futuras pesquisas devem ser conduzidas em condições "em tempo real", considerando a variabilidade do mundo real e a implementação prática em ambientes mais complexos. Diante dos resultados positivos obtidos e das perspectivas abertas por este estudo, acreditamos que a abordagem de conectividade funcional por sincronização de motifs associada ao classificador SVM oferece um caminho promissor para o aprimoramento contínuo das BCIs. Com esforços adicionais, nossa pesquisa pode contribuir significativamente para a melhoria da qualidade de vida de indivíduos com limitações motoras e abrir novas possibilidades para a interação humano-computador.

---

## BIBLIOGRAFIA

N. Nieto, V. Peterson, H. L. Rufiner, J. E. Kamienkowski, and R. Spies, **“Thinking out loud, an open-access EEG-based BCI dataset for inner speech recognition”**, *Sci. Data*, vol. 9, no. 1, p. 52, Feb. 2022.

C. A. Stefano Filho, R. Attux, and G. Castellano, **“EEG sensorimotor rhythms’ variation and functional connectivity measures during motor imagery: Linear relations and classification approaches”**, *PeerJ*, vol. 2017, no. 11, pp. 1–15, 2017.

R. S. Rosário, P. T. Cardoso, M. A. Muñoz, P. Montoya, and J. G. V. Miranda, **“Motif-Synchronization: A new method for analysis of dynamic brain networks with EEG,”** *Phys. A Stat. Mech. its Appl.*, vol. 439, pp. 7–19, Dec. 2015.

Gasparini, F., Cazzaniga, E., & Saibene, A. **“Inner speech recognition through electroencephalographic signals.”** Italian Workshop on Artificial Intelligence for Human Machine Interaction (AIxHMI 2022), Udine, Italy, December 02, 2022.