

ESTUDO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA APLICADAS NA CONSTRUÇÃO DE INTERFACES CÉREBRO-COMPUTADOR BASEADAS EM POTENCIAIS EVOCADOS VISUALMENTE EM RITMO ESTACIONÁRIO

Palavras-Chave: interface cérebro-computador, aprendizado de máquina, potenciais evocados visualmente em ritmo estacionário

Autores:

Manoel Ribeiro Caetano Junior, FEEC, UNICAMP

Prof. Dr. Rafael Ferrari, FEEC, UNICAMP

INTRODUÇÃO:

Uma interface cérebro-computador (BCI, do inglês *Brain-Computer Interface*) é um sistema que mapeia sinais cerebrais em comandos para dispositivos externos, oferecendo um canal de comunicação alternativo para usuários em diversos contextos, como jogos de computador e tecnologias assistivas [1]. Uma abordagem comum em BCI utiliza potenciais evocados visualmente em ritmo estacionário (SSVEP, do inglês *Steady State Visually Evoked Potentials*), que é o foco deste estudo. Nesta abordagem, estímulos cintilantes de diferentes frequências são apresentados ao indivíduo enquanto seu eletroencefalograma (EEG) é registrado [1,3]. A frequência do estímulo corresponde ao comando gerado, e a cintilação luminosa altera a amplitude e a fase do sinal cerebral na frequência do estímulo e em suas harmônicas [2], permitindo identificar o estímulo no qual o indivíduo está concentrado.

O desenvolvimento de sistemas SSVEP-BCI envolve três etapas principais. Primeiro, sinais de EEG são adquiridos com um sistema de estimulação visual, como LEDs ou um monitor, enquanto o usuário foca em um estímulo. Eletrodos na região occipital capturam a resposta cerebral, que é amplificada e digitalizada. Em seguida, os sinais são processados para remover artefatos e ruídos, e características importantes são extraídas através de técnicas de filtragem e análise espectral. A seleção das características mais relevantes melhora o desempenho do sistema, simplifica o modelo e reduz o tempo e espaço de armazenamento [3]. Finalmente, um classificador analisa essas características para identificar a intenção do usuário, distinguindo as frequências de estimulação visual associadas a comandos específicos. A eficácia do classificador é medida pela taxa de acerto na seleção correta dos comandos, que são então executados pela interface de controle.

Os dados de EEG apresentam alta variabilidade entre sessões e indivíduos, tornando o projeto de sistemas BCI desafiador. Fatores como idade, fisiologia cerebral e capacidade de concentração influenciam essa variabilidade [3], e a escassez de dados em bases públicas limita o uso de técnicas de aprendizado de máquina. Este trabalho tem como objetivo desenvolver um sistema BCI, empregando técnicas de aprendizado de máquina. Dois métodos de extração de características foram utilizados: banco de filtros e correlações canônicas entre os sinais de EEG e os de estimulação. Propomos um método de seleção de características baseado em *wrappers*. A partir das características extraídas, foram empregados três classificadores para classificar os estímulos: KNN, máquina de vetor de suporte (SVM, do inglês *Support Vector Machine*) e *perceptron* de múltiplas camadas (MLP, do inglês *Multilayer Perceptron*). Para avaliar as técnicas, os resultados foram comparados com a taxa de acerto da análise de correlação canônica, uma técnica que é amplamente usada como referência de desempenho em sistemas SSVEP-BCI [5].

METODOLOGIA:

1) Base de dados

Para testar as técnicas, foi utilizada a base de dados pública da Universidade de Tsinghua [5] composta por registros de EEGs provenientes de 64 canais, coletados de 35 participantes. Os registros foram feitos enquanto os participantes executavam uma tarefa de seleção de estímulo cintilante. O sistema de estimulação consistia em um teclado virtual com

40 estímulos, variando de 8 Hz a 15,8 Hz com incrementos de 0,2 Hz. Cada participante foi instruído a fixar o olhar em cada estímulo por 5 segundos enquanto seu sinal de EEG era registrado. O experimento foi conduzido em seis blocos de 40 sessões cada. Neste trabalho, foi utilizado um subconjunto dessas frequências, 10 Hz, 11 Hz, 12 Hz, 13 Hz, 14 Hz e 15 Hz. Foram selecionados 12 voluntários da base de dados para o estudo, incluindo tanto homens quanto mulheres, sendo metade com experiência prévia em sistemas SSVEP-BCI e a outra metade inexperiente.

2) Pré-Processamento

Durante a coleta de EEG, artefatos podem ocorrer, classificados como fisiológicos (relacionados ao indivíduo) e do sistema (relacionados ao equipamento). Artefatos fisiológicos incluem movimentos corporais, batimentos cardíacos e respiração. Artefatos do sistema envolvem interferências elétricas e ruídos de equipamentos [3,4]. Neste trabalho, inicialmente aplicou-se um filtro passa-banda digital Butterworth (de 6 a 50 Hz) nos dados de EEG, para preservar a banda de interesse. Em seguida, utilizou-se o método de referência média comum (CAR, do inglês *Common Average Reference*) para reduzir artefatos comuns presentes em vários eletrodos, calculando a média dos valores de todos os eletrodos e subtraindo essa média de cada eletrodo individualmente [3]. O método é definido conforme a Eq (1). Os potenciais dos eletrodos são representados por V_{ER_i} , onde i varia de 1 a n , sendo n , o número total de eletrodos. A soma dos potenciais de todos os eletrodos é igual a $\sum_{j=1}^n V_{ER_j}$.

$$V_{CAR_i} = V_{ER_i} - \frac{1}{n} \sum_{j=1}^n V_{ER_j} \quad (1)$$

3) Extração de características

O processo de extração de características dos sinais de EEG permite simplificar e compactar a representação dos dados, facilitando a discriminação dos estímulos e aprimorando o desempenho da classificação. Neste estudo, foram empregadas duas estratégias de extração: banco de filtros e correlações canônicas.

3.1) Banco de Filtros

O banco de filtros é um conjunto organizado de filtros usados para dividir o sinal de entrada em diferentes partes de forma eficiente [3]. Essa técnica é útil para identificar e separar características específicas do sinal. Em SSVEP, um conjunto de filtros passa-banda pode ser usado para capturar as diferentes bandas de frequência de interesse. Isso permite isolar e analisar o conteúdo espectral próximo das frequências específicas associadas aos estímulos visuais. Neste trabalho, foram projetados filtros Butterworth de quarta ordem, centrados nas componentes fundamentais dos estímulos, bem como filtros centrados na componente harmônica secundária. Todos os filtros têm uma largura de banda de 1 Hz. As janelas de estimulação de 5 segundos foram segmentadas em janelas de 1 segundo, com uma sobreposição de 0,7 segundos. As janelas dos blocos de 1 a 5 foram utilizadas para treinamento, enquanto as janelas do bloco 6 foram reservadas para teste. Para cada janela de estimulação, o banco de filtros foi aplicado a 8 eletrodos: O1, O2, Oz, PO3, PO5, PO4, PO6 e

POZ, que são um subconjunto dos eletrodos utilizados pelos desenvolvedores da base para classificar os estímulos [5]. Portanto, para cada janela de estimulação, foi criado um vetor contendo 96 atributos.

3.2) Análise de correlação canônica

A técnica de Análise de Correlação Canônica (CCA, do inglês *Canonical Correlation Analysis*) [5], mede a correlação subjacente entre dois vetores de variáveis aleatórias X e Y . Considerando as projeções lineares $x = X^T W_x$ e $y = Y^T W_y$, o CCA encontra os vetores de peso W_x e W_y que maximizam a correlação entre x e y , resolvendo o problema da Eq (2):

$$\max_{W_x, W_y} \rho(x, y) = \frac{E[W_x^T X Y^T W_y]}{\sqrt{E[W_x^T X X^T W_x] E[W_y^T Y Y^T W_y]}} \quad (2)$$

A correlação canônica máxima ρ em relação a W_x e W_y é usada na detecção de frequências de estimulação, onde X são os sinais de EEG e Y são sinais de referência, sintéticos, modelados com senos e cossenos, que representam as frequências fundamental e harmônicas do estímulo [5]. Neste trabalho, foram utilizadas três harmônicas para o cálculo das correlações canônicas, totalizando 6 atributos para cada uma das janelas de estimulação de 1 segundo. Para a extração das características, foi utilizado o mesmo conjunto de eletrodos, assim como o mesmo método de sobreposição, conforme descrito na Seção 3.1.

A taxa de acerto da análise de correlação canônica, consiste na implementação de um mecanismo de inferência baseado na máxima correlação canônica [5].

4) Seleção de características: Wrappers

Os métodos de seleção de variáveis conhecidos como "*wrappers*" usam o desempenho do modelo como critério para avaliar a qualidade das combinações das características [3,8]. Ou seja, cada grupo de características é usado para treinar o modelo, e o erro médio do modelo no conjunto de validação mostra o quão útil é aquele conjunto de características na tarefa de classificação. Neste trabalho, foi empregada a estratégia de (*Forward Selection*), uma abordagem gulosa para construir um subconjunto de variáveis [8].

5) Classificação

O sistema de classificação associa cada vetor de características a um rótulo de um conjunto de classes definido, transformando as características em uma decisão categórica com base em dados anteriores. Neste trabalho, foram utilizados três classificadores: KNN, MLP e SVM, implementados com a biblioteca *scikit-learn* em *Python*, e para cada um, foi realizada uma busca pela melhor combinação de hiperparâmetros para otimizar o desempenho.

5.1) *K-nearest neighbors*

O classificador KNN [6] determina a classe de um novo dado com base nas classes dos seus k vizinhos mais próximos. A métrica de distância, como a euclidiana ou a Manhattan, deve ser adequada para as características dos dados. A distância de Minkowski, Eq (3), generaliza essas métricas e pode ser ajustada com o parâmetro p .

$$d(x^{(i)}, x^{(j)}) = \left(\sum_k |x_k^{(i)} - x_k^{(j)}|^p \right)^{\frac{1}{p}} \quad (3)$$

5.2) *Multilayer perceptron*

Uma MLP [7] é uma rede neural artificial que consiste em *perceptrons* totalmente conectados, ou seja, cada *perceptron* em qualquer camada da rede está conectado a todos os *perceptrons* da camada anterior. Um sinal aplicado na entrada da rede se propaga ao longo dela, da entrada para a saída, de camada para camada. Neste trabalho, foi utilizada uma MLP, com apenas uma camada intermediária.

5.3) *Support Vector Machine*

O classificador baseado em SVM [3] busca encontrar uma fronteira de decisão que melhor separa as diferentes classes de dados. A fronteira tem máxima margem, ou seja, a maior distância possível entre ela e os pontos de dados mais próximos de cada classe. Esses pontos são chamados de vetores de suporte. A estrutura do classificador pode ser linear ou não linear e é definida por uma função kernel, que pode ser linear, quadrática, polinomial ou gaussiana (RBF) [3,6].

RESULTADOS E DISCUSSÃO:

A Figura 1 mostra que os classificadores com características extraídas pelo banco de filtros não alcançaram desempenho comparável à técnica de referência CCA, embora a seleção de características tenha melhorado ligeiramente os resultados. A Figura 2 demonstra que o uso de correlações canônicas como características resultou em um desempenho ligeiramente superior ao CCA. No entanto, a técnica de *wrappers* foi ineficiente devido ao número limitado de características, priorizando variáveis com bom desempenho individual, mas não

contribuindo para o subconjunto ótimo.

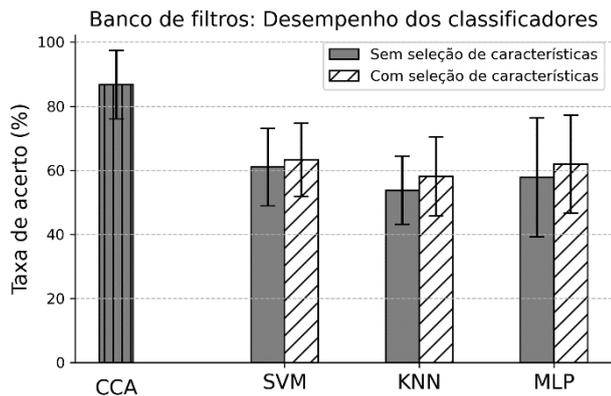


Figura 1: Desempenho médio dos classificadores, empregando a estratégia de banco de filtros para extrair as características.

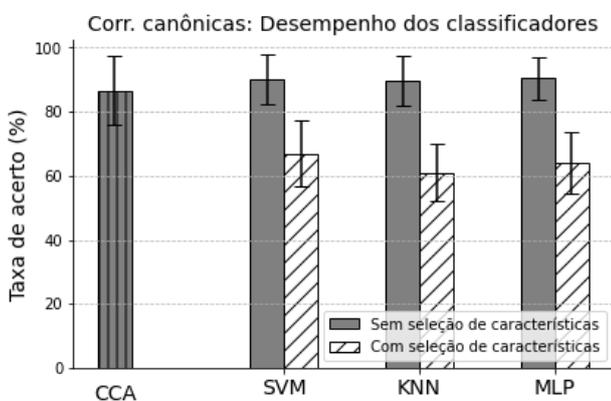


Figura 2: Desempenho médio dos classificadores, extraindo as correlações canônicas como características.

A estratégia de correlação canônica mostrou-se mais eficiente que a estratégia de banco de filtros, que pode permitir a passagem de ruído [3] e impactar o desempenho. As correlações canônicas combinam informações dos eletrodos de forma mais eficiente, atuando como um filtro espacial [5] e produzindo um vetor de 6 atributos, enquanto o banco de filtros gera 96, dificultando a classificação devido à maldição da dimensionalidade [6] e à quantidade limitada de dados disponíveis.

CONCLUSÕES:

Neste trabalho, foi desenvolvida uma interface BCI completa, abrangendo desde o processamento até a aplicação de técnicas de aprendizado de máquina para seleção e

classificação dos estímulos. Os resultados indicam que a estratégia de inferência baseada na correlação canônica máxima é bastante robusta, superando ou igualando técnicas de aprendizado de máquina em alguns contextos, apesar de sua simplicidade.

BIBLIOGRAFIA

- [1] WOLPAW, Jonathan R. et al. Brain-computer interfaces for communication and control. **Clinical neurophysiology**, v. 113, n. 6, p. 767-791, 2002.
- [2] WITTEVRONGEL, Benjamin; VAN HULLE, Marc M. Frequency-and phase encoded SSVEP using spatiotemporal beamforming. **PloS one**, v. 11, n. 8, p. e0159988, 2016.
- [3] CARVALHO, Sarah N. et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. **Biomedical Signal Processing and Control**, v. 21, p. 34-42, 2015.
- [4] SANEI, Saeid; CHAMBERS, Jonathon A. **EEG signal processing**. John Wiley & Sons, 2013.
- [5] WANG, Yijun et al. A benchmark dataset for SSVEP-based brain-computer interfaces. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 25, n. 10, p. 1746-1752, 2016.
- [6] BISHOP, Christopher M.; NASRABADI, Nasser M. **Pattern recognition and machine learning**. New York: springer, 2006.
- [7] HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2001.
- [8] KUHN, Max; JOHNSON, Kjell. **Feature engineering and selection: A practical approach for predictive models**. Chapman and Hall/CRC, 2019.