



RESUMO DE PROJETO DE INICIAÇÃO CIENTÍFICA PELO PROGRAMA INSTITUCIONAL DE BOLSAS DE INICIAÇÃO CIENTÍFICA E TECNOLÓGICA

Projeto: Comparação entre Interfaces Cérebro-Computador Baseadas em Estímulos Visuais de Baixa, Média e Alta Frequência

Bolsista: Gustavo Nascimento Soares **RA:** 217530

Orientador: Prof. Dr. Romis Ribeiro de Faissol Attux

Co-orientador: Dr. Thiago Bulhões da Silva Costa

Local de Execução: Laboratório de Processamento de Sinais para Comunicações

Vigência: 08/2019 - 08/2020

1 Introdução

Uma interface cérebro-computador, ou *Brain-Computer Interface* (BCI), é um sistema computacional que permite interpretar sinais obtidos do cérebro e transformá-los em respostas que são, geralmente, usadas para auxiliar no cotidiano de pessoas com dificuldades motoras ou doenças debilitadoras. Existem diversas implementações de BCIs, entre as mais comuns estão a imaginação de movimento, o P300 e os potenciais evocados visuais em regime estacionário (SSVEP).

O foco desse trabalho está nas BCIs baseadas em potenciais evocados visuais em regime estacionário. Os potenciais evocados visuais refletem um mecanismo cerebral de processamento de estímulos visuais. Quando o estímulo visual é de natureza repetitiva com um certo período de tempo fixo, esses potenciais são caracterizados por ficar em regime estacionário. Sendo assim, é necessária a aplicação de estímulos visuais repetitivos (EVR) e precisos no emprego de BCIs de SSVEP. Na prática, os estímulos normalmente utilizados são figuras piscando em uma frequência constante, para gerar a resposta cerebral na mesma frequência do estímulo e em seus harmônicos. Dessa maneira, a análise do espectro de frequência da atividade neural de um indivíduo pode carregar informações capazes de identificar o estímulo visual observado por ele.

O objetivo geral deste projeto é testar e comparar três protocolos de SSVEP-BCI: um com EVRs padronizados de baixa frequência (na faixa de 1 a 12 Hz), outro com EVRs padronizados de média frequência (na faixa de 12 a 30 Hz) e outro com EVRs padronizados de alta frequência (na faixa acima de 30 Hz).

2 Readequação do Projeto

As metas originais como definidas no projeto de iniciação científica foram as seguintes:

1. Fazer um estudo dirigido sobre o estado da arte em processamento de sinais e aprendizado de máquina para SSVEP-BCI. Parte desse estudo se dará com indicações de leitura, parte em encontros semanais com o orientador e parte em reuniões do grupo de pesquisa na área de BCI.
2. Em conjunto com mestrandos e doutorandos do mencionado grupo de pesquisa, participar de aquisições de SSVEP-BCI para compor um banco de dados com voluntários saudáveis expostos aos requeridos estímulos visuais de baixa, média e alta frequência.
3. Em linguagem computacional, programar os algoritmos necessários para a execução do bloco de processamento da SSVEP-BCI.
4. Com os algoritmos da meta anterior, processar e avaliar os sinais adquiridos nos três contextos de frequência e, a partir dos resultados obtidos e da comparação com trabalhos da literatura, escrever um relatório com as conclusões da investigação.

Em razão da pandemia, nem todas as metas puderam ser atingidas completamente. Sendo assim, foi necessária uma readequação dos estudos que seriam empregados para a realização do projeto de iniciação científica.

Sem a possibilidade de fazer as devidas aquisições de EVRs na faixas de frequência desejadas, foi decidido utilizar um banco de dados de SSVEP-BCI já utilizado em artigo científico. Apesar de não substituir perfeitamente as aquisições que seriam feitas para esse trabalho, o banco em questão abrange um intervalo interessante de frequências de EVRs que podem trazer resultados relevantes no estudo de Interfaces Cérebro-Computador.

3 Metodologia

3.1 Processamento de Sinais

Um tipo de filtragem útil para aumentar a relação sinal-ruído é a filtragem espacial aplicada nos dados adquiridos pelo equipamento de EEG. Um deles é o *common average reference* (CAR):

$$V_k = V_k - \frac{1}{N} \sum_{i=1}^N V_i \quad (1)$$

Nele, o potencial médio do vetor de eletrodos é subtraído do potencial de cada eletrodo. Com isso, elimina-se ruídos como artefatos da movimentação do usuário, ruído da rede elétrica, ruídos biológicos, entre outros que estão presentes em todos os eletrodos, e determina-se uma referência para os potenciais.

Para extrair atributos relacionados ao espectro de frequências do sinal adquirido ao longo do tempo, a técnica usada nesse trabalho é uma família de algoritmos conhecidos como Transformada Rápida de Fourier, ou *Fast Fourier Transform* (FFT), que permite calcular a Transformada Discreta de Fourier (DFT) de uma sequência, com uma complexidade assintoticamente menor, ou seja, com um tempo

bem menor do que a equação analítica. Os atributos extraídos são as amplitudes da DFT, aplicada em uma janela de curta duração do sinal, nos pontos referentes às frequências e aos seus harmônicos relevantes para o problema. As amplitudes dos mesmos pontos das DFTs são extraídos para cada sinal de cada um dos canais referentes aos eletrodos utilizados.

Dado um sinal $x[n]$ discreto composto de N pontos, a sua Transformada Discreta de Fourier $X(k)$ pode ser calculada a partir de:

$$X(k) = \sum_{n=0}^{N-1} x[n]e^{-jkn} \quad (2)$$

3.2 Fundamentos de Aprendizado de Máquina

3.2.1 Seleção de atributos

Antes de servirem à classificação, os atributos espectrais extraídos dos sinais cerebrais podem ser selecionados por meio de diversas técnicas. Uma delas é o coeficiente de correlação de Pearson. O coeficiente de correlação de Pearson é um índice que relaciona o vetor \mathbf{x}_j do j -ésimo atributo com o vetor de saída \mathbf{y} e pode ser dado por:

$$r_j = \frac{\sum (\mathbf{x}_j - \bar{\mathbf{x}}_j)(\mathbf{y} - \bar{\mathbf{y}})}{\sqrt{\sum (\mathbf{x}_j - \bar{\mathbf{x}}_j)^2 \sum (\mathbf{y} - \bar{\mathbf{y}})^2}} \quad (3)$$

em que os $\bar{\mathbf{x}}_j$ e $\bar{\mathbf{y}}$ representam os valores médios dos vetores. Em princípio, atributos com valores, em módulo, próximos de 1 são mais relevantes do que aqueles com valores próximos de zero.

3.2.2 Modelos de Classificação

O método utilizado para a classificação dos dados foi um modelo linear. Nesse sentido, dado um vetor x das variáveis de entrada e um vetor w de pesos, a saída do modelo é dada por uma combinação linear de funções fixas $\Phi(x)$ não lineares das variáveis:

$$\hat{y}(x, w) = w_0 + \sum_{j=1}^{M-1} w_j \Phi_j(x) \quad (4)$$

O vetor de pesos w define hiperplanos que separam as diferentes classes referentes ao problema. Diversos métodos podem ser usados para definir os hiperplanos a serem utilizados. Entre eles estão a minimização do erro quadrático médio (LMS) e a análise do discriminante linear de Fisher (LDA). Na minimização do erro quadrático médio, o vetor de pesos w pode ser encontrado em termos da pseudo-inversa dos dados:

$$w = \begin{cases} (\Theta^T \Theta)^{-1} \Theta^T y = \Theta^\dagger y, & \text{se } K + 1 \leq N \\ \Theta^T (\Theta \Theta^T)^{-1} y = \Theta^\dagger y, & \text{caso contrário} \end{cases} \quad (5)$$

em que $\Theta \in \mathbb{R}^{N \times K+1}$ é a matriz de atributos, Θ^\dagger é a pseudo-inversa da matriz Θ , N é o número de amostras, K é o número de atributos e $y \in \mathbb{R}^{N \times 1}$ é o vetor saída das N amostras.

Já o discriminante linear de Fisher é uma ferramenta de redução de dimensionalidade. Para evitar a perda de informação, o objetivo do método é minimizar a variância intra-classe enquanto maximiza a variância inter-classes. Assim, sejam μ_k a média e s_k^2 a variância interna da classe k , o vetor de pesos w pode ser encontrado a partir de:

$$w = S_w^{-1}(\mu_1 - \mu_2), \text{ onde } S_w = \sum_{i=1}^K \sum_{j \in C_i} (x(j) - \mu_i)(x(j) - \mu_i)^T \quad (6)$$

em que S_w é a matriz de covariância intra-classe.

Na etapa de decisão, é definido um limite w_0 em que caso $\hat{y}(x) \geq -w_0$, x pertence à classe C_1 ou pertence à classe C_2 caso contrário. O limite pode ser escolhido, por exemplo, usando $w_0 = (w^T \mu_1 + w^T \mu_2)/2$.

3.2.3 Avaliação do Modelo

Em aprendizado de máquina, uma estratégia recorrente na construção de modelos é a partição do banco de dados em conjuntos de treinamento, validação e teste. Essa divisão permite criar modelos generalizados, ou seja, capazes de prever melhor um resultado quando for aplicado em uma entrada nova. Há várias metodologias para particionar bancos de dados usados em aplicações de aprendizado de máquina. Neste trabalho, amostras aleatórias foram escolhidas para formar cada um dos conjuntos.

4 Resultados e Discussão

A partir de uma análise preliminar, foram montados modelos capazes de classificar entre sinais referentes a estímulos de 12 Hz, 15 Hz e 20 Hz. Esses modelos tiveram seus atributos selecionados a fim de obter resultados ainda mais próximos da classificação ideal.

O banco de dados utilizado contém dados de sinais cerebrais referentes a estímulos de 6, 7,5, 12, 15, 20 e 30 Hz. Apesar de o problema atacado não envolver todas essas frequências de estímulo, todos os dados foram considerados em algum momento. Com as técnicas utilizadas, é possível analisar a utilidade ou não das frequências fora do intervalo de estudo.

Os sinais dos sujeitos foram divididos em janelas de 3s sem sobreposição entre elas. Com o filtro espacial CAR e a FFT aplicados, foram extraídas as amplitudes das FFTs nas posições referentes às frequências de estímulos e em seus segundos e terceiros harmônicos.

A partir dos conjuntos de treino, foram gerados 3 classificadores binários distintos para os casos 12 Hz x 15 Hz, 12 Hz x 20 Hz e 15 Hz x 20 Hz. Dessa maneira, uma entrada de teste foi avaliada por cada classificador e a resposta final do modelo seria a que aparecesse em mais da metade dos classificadores. Porém, essa abordagem permite que hajam ambiguidades na resposta do classificador nos casos em que cada classificador tem uma saída diferente. Para solucionar esse problema, a resposta escolhida foi a do classificador que tivesse como saída o maior valor absoluto. Essa escolha foi feita porque, para esse classificador, a distância entre o ponto e o limite entre os hiperespaços de cada classe é a mais alta.

Com o particionamento do banco de dados, os modelos a partir de LMS e de LDA foram construídos usando os conjuntos de treinamento. Para cada um dos classificadores, foi feito um ranqueamento dos atributos pelo coeficiente de correlação de Pearson. Com isso, deve ser feita uma escolha de quais atributos devem ser usados na construção do modelo. Para fazer essa escolha, a acurácia de cada modelo foi avaliada a partir da média de 100 repetições com diferentes percentis do *ranking* utilizados. Foi possível observar que havia um conjunto ideal de atributos e, quando incluídos atributos adicionais, o desempenho do modelo era prejudicado. Uma explicação razoável para esse comportamento é a presença, nos dados usados para treinar e testar o modelo, de atributos não relevantes para o problema. Essa metodologia é agnóstica com relação a quais eletrodos ou pontos da DFT são os mais relevantes para o problema de classificação. Por isso, faz-se necessário uma examinação adicional de quais são os atributos que aparecem como os que carregam informações mais relevantes para os classificadores. Assim, foi escolhido o 85^o percentil de atributos e foram analisados os canais e frequências que compunham os atributos que se mostraram mais vezes nessa seleção.

Os canais mais relevantes foram os referentes aos eletrodos das posições O1, O2, Oz, POz, PO4, PO3, e PO7, o que é coerente com a literatura do sistema nervoso central humano, uma vez que todos esses eletrodos estão posicionados na região do lobo occipital do córtex cerebral, que tem como função quase exclusiva o processamento visual. Já as frequências avaliadas como mais informativas para os modelos foram de 6, 12, 15, 18, 20, 24 e 30 Hz, o que sugere que as frequências de mais relevância para o problema não se restringem a múltiplos das frequências de estímulo mas também a valores em seus arredores e que valores de frequência muito altos não trazem informação relevante.

Diante dessas informações, foram feitas novas avaliações dos modelos usando a seleção dos canais melhor avaliados pelo coeficiente de correlação de Pearson e com o conjunto de frequências: {6; 7,5; 10; 12; 15; 18; 20; 22,5; 24; 30} Hz. Cada um desses critérios foi avaliado separadamente e de maneira combinada e comparado com o resultado apresentado pelo melhor percentil de atributos de cada modelo da avaliação inicial. Cada avaliação de acurácia foi repetida com 100 diferentes conjuntos de treino e teste para que os resultados fossem estatisticamente relevantes. Os resultados foram significativos, visto que mostraram acurácia expressivamente superior à escolha de uma classe ao acaso.

5 Conclusões

As ferramentas de processamento de sinais e aprendizado de máquina são efetivas para o problema de classificação de estímulo visual de um indivíduo. Foi observado o ganho potencial que a seleção de atributos pode ter em um problema de classificação linear. Um modelo carregado de bastante informação não só é mais custoso computacionalmente como pode atrapalhar o desempenho de um modelo. Essa seleção, porém, deve ser feita com critérios objetivos e analisada criticamente por aquele que pretende fazer uso da técnica.

O valor das frequências dos EVRs certamente influi em quais atributos retirados do espectro de frequência dos sinais cerebrais devem ser processados na construção de classificadores lineares para BCIs. A observação de que frequências mais altas costumam carregar menos informação de estímulo visual está de acordo com a literatura estabelecida. Sendo assim, o design de SSVEP-BCIs que utilize EVRs de altas frequências necessitaria de técnicas bastante poderosas capazes de contornar esse problema.