



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

Análise da Etapa de Treinamento do Classificador Linear de um Sistema BCI-SSVEP

Ricardo Coelho Ferreira

João Monlevade, MG
2018

Ricardo Coelho Ferreira

Análise da Etapa de Treinamento do Classificador Linear de um Sistema BCI-SSVEP

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.

Orientadora: Prof.^a Dr.^a Sarah Negreiros de Carvalho Leite

Universidade Federal de Ouro Preto
João Monlevade
2018



**ANEXO V - AUTORIZAÇÃO DO COLEGIADO PARA LANÇAMENTO DA
NOTA ATV600 NO HISTÓRICO ESCOLAR EM SUBSTITUIÇÃO À ATA DE
DEFESA**

Autorização

O colegiado do curso de engenharia elétrica autoriza à orientadora Sarah Negreiros de Carvalho Leite o lançamento da nota do Trabalho de Conclusão de Curso - ATV 600 do aluno Ricardo Coelho Ferreira, matrícula 13.1.8042, em virtude do aproveitamento do artigo publicado em evento científico ou periódico, conforme previsto no § 3º do Art. 5º da resolução COEE nº 007/2013.

Nota atribuída pela orientadora: 9,5.

João Monlevade, 13 de junho de 2018.

Prof. Dr. Márcio Feliciano Braga

Presidente do Colegiado de Engenharia Elétrica

F383a Ferreira, Ricardo Coelho.
Análise da etapa de treinamento do classificador linear de um sistema BCI-SSVEP [manuscrito] / Ricardo Coelho Ferreira. - 2018.

35f.: il.: color; grafs; tabs.

Orientador: Profa. Dra. Sarah Negreiros de Carvalho Leite.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia Elétrica.

1. Engenharia elétrica. 2. Interface cérebro-computador. 3. Método dos mínimos quadrados. I. Leite, Sarah Negreiros de Carvalho. II. Universidade Federal de Ouro Preto. III. Título.

CDU: 621.3



ANEXO II - TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado “Análise da Etapa de Treinamento do Classificador Linear de um Sistema BCI-SSVEP” é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 10 de Julho de 2018

Nome completo do(a) aluno(a)

“Disciplina e trabalho constante são as pedras de amolar sobre as quais a faca cega do talento é trabalhada até ficar afiada o suficiente ”
– *Stephen King, em “Dança Macabra”.*

Resumo

Neste estudo foi desenvolvido o processamento digital de sinais eletroencefalográficos para implementar uma interface cérebro-computador (BCI) baseada no Potencial Evocado Visualmente em Regime Estacionário (SSVEP). As características dos estímulos visuais associados aos comandos da BCI foram extraídas usando a estimação espectral via Periodograma de Welch e a discriminação de quatro classes foi estabelecida utilizando o Método dos Mínimos Quadrados como classificador linear. Estudos adicionais foram feitos para auxiliar a escolha do tamanho da janela usada e foi analisado o desempenho da BCI mediante a redução dos dados do próprio indivíduo usados para treinar o sistema de discriminação. Os resultados mostram que o desempenho do sistema é melhor quando se emprega um maior volume de dados do próprio indivíduo para treinar o discriminante.

Palavras-chave: BCI, SSVEP, Periodograma de Welch, Método dos Mínimos Quadrados.

Abstract

In this study the digital processing of electroencephalographic signals was developed to implement a brain-computer interface (BCI) based on Steady State Visually Evoked Potential (SSVEP). The visual stimuli features associated with the BCI commands were extracted using spectral estimation via the Welch Periodogram and the four-class were discriminated employing the linear least square method. We also evaluated the impact on BCI performance by varying the size of the signal window for features extraction and the quality of the data used to train the discriminant. The results show that the performance of the system is better when using greater volume of data of the own-subject to train the system.

Keywords: *BCI, SSVEP, Welch Periodogram, Least Mean Squares.*

Lista de ilustrações

Figura 1 – Fluxograma da BCI.	3
Figura 2 – Posicionamento dos Eletrodos na Aquisição.	5
Figura 3 – Sinal de 12s.	7
Figura 4 – Primeiro Segmento de 2s do Sinal.	8
Figura 5 – FFT do Sinal de 12s.	8
Figura 6 – FFT do Primeiro Segmento de 2s.	9
Figura 7 – PSD do Sinal de 12s.	12
Figura 8 – PSD do Primeiro Segmento de 2s.	12
Figura 9 – Histograma para o Cenário I.	18
Figura 10 – Histograma para o Cenário II.	19
Figura 11 – Histograma para o Cenário III.	21
Figura 12 – Histograma para o Cenário IV.a.	24
Figura 13 – Histograma para o Cenário IV.b.	25
Figura 14 – Histograma para o Cenário IV.c.	25

Sumário

1	INTRODUÇÃO	1
2	OBJETIVOS	4
3	AQUISIÇÃO DE DADOS	5
4	PRÉ-PROCESSAMENTO	7
5	EXTRAÇÃO DE ATRIBUTOS	10
5.1	Periodograma de Welch	10
5.1.1	Cálculo do Periodograma de Welch	10
5.2	Organização dos Atributos	13
5.2.1	Matriz de Atributos	13
6	CLASSIFICAÇÃO LINEAR BASEADA NO MÉTODO DOS MÍNIMOS QUADRADOS	14
7	RESULTADOS E DISCUSSÃO	16
7.1	Cenário I	16
7.2	Cenário II	19
7.3	Cenário III	21
7.4	Cenário IV	23
7.4.1	Cenário IV.a	24
7.4.2	Cenário IV.b	24
7.4.3	Cenário IV.c	25
8	CONCLUSÃO	26
	REFERÊNCIAS	27

1 Introdução

"No fim todos os meses planejando e preparando se resumem a 5 minutos de tiroteio."
Stephen King

Interfaces Cérebro-Computador (BCI do inglês, *Brain-Computer Interfaces*) podem comunicar comandos a um computador ou microcontrolador com o intuito de controlar alguma aplicação, utilizando sinais elétricos detectados no escalpo de um indivíduo. De acordo com Graimann *et al.* (2010) uma BCI é um canal de saída artificial que faz a interface direta entre o cérebro e um computador podendo aceitar comandos voluntários diretamente do cérebro sem requerer movimento muscular. As BCI podem ser usadas para controlar aplicações que permitem readaptar pessoas com algum tipo de deficiência física na sociedade, por meio de equipamentos que permitem tanto a locomoção quanto a comunicação. Em Lebedev *et al.* (2006) é possível encontrar várias aplicações assistivas controladas por esse tipo de sistema.

Segundo Hämäläinen *et al.* (1994) atividades cerebrais produzem sinais elétricos devido à passagem de corrente elétrica. Quando uma pessoa se concentra em um estímulo visual, como uma tela com quadros alternando a cor com uma certa taxa, é possível medir sobre o escalpo respostas em termos de níveis de tensão nos pontos onde estão posicionados os eletrodos, essas respostas são devidas às variações no campo elétrico do cérebro que responde ao estímulo visual com um potencial evocado na mesma frequência do estímulo visual. Esta abordagem de BCI é conhecida como Potencial Evocado Visualmente em Regime Estacionário (SSVEP, do inglês *Steady State Visually Evoked Potentials*) e é uma das técnicas mais empregadas atualmente.

Os potenciais evocados podem ser coletados por eletrodos dispostos em uma touca que cobre boa parte do escalpo, eles são posicionados de acordo com o sistema internacional 10-10 ou o 10-20 (Jurcak *et al.* 2007), sendo os eletrodos próximos a região occipital os que trazem respostas melhores para potenciais evocados visualmente. As características metodológicas do processo de aquisição de sinal variam, sendo que os eletrodos podem ser a gel ou secos, (Searle *et al.* 2000). Existem formas invasivas e não-invasivas para a coleta dos sinais cerebrais, sendo os métodos invasivos mais eficientes em termos de relação sinal-ruído, no entanto é necessária uma cirurgia para posicionar os eletrodos no tecido cortical ou intracortical, o que torna a coleta mais perigosa e custosa. A eletroencefalografia (EEG) é uma técnica não invasiva e empregada com maior frequência em sistemas BCI.

Durante a aquisição, alguns sinais indesejados acabam sendo coletados não intencionalmente, dentre eles sinais da rede elétrica, outros sinais biológicos, como perturbações devido ao piscar dos olhos do indivíduo e movimentação muscular realizada durante a coleta. Alguns outros ruídos de natureza desconhecida também podem aparecer durante

a coleta e precisam ser removidos, pois o potencial evocado registrado pelo EEG é da ordem de microvolts, enquanto que os ruídos podem ter amplitude maior. De maneira geral os sinais EEG apresentam baixa relação sinal-ruído, assim torna-se necessário um bom pré-processamento, que pode começar com um filtro analógico e ser concluído com uma forma de processamento digital. Após filtrados, os mesmos podem ser analisados via Transformada Rápida de Fourier, e através da estimação da densidade espectral de potência.

Os SSVEPs não são a única metodologia existente para a elaboração de uma BCI, há também outras abordagens, dentre elas a imagética motora que se baseia na identificação de sinais que emergem do córtex motor do indivíduo durante a imaginação de um movimento específico, como mover os pés ou as mãos. A imagética motora requer treinamento do indivíduo para a aquisição de dados, uma vez que é preciso imaginar o movimento sem executá-lo de fato, o que pode ser uma tarefa extremamente complexa para pessoas com dificuldade de concentração, imaginação ou excessivamente inquietas. Mais detalhes sobre a classificação de sinais de EEG usando a abordagem da imagética motora podem ser encontrados em (Park, 2013).

Após o pré-processamento dos sinais são extraídos seus atributos de interesse, neste caso a amplitude do sinal nas possíveis frequências do estímulo visual usadas 6, 10, 12 e 15 Hz. Os atributos são então divididos em classes para a elaboração do classificador, a esta etapa denomina-se treinamento e é nela que se ensina o classificador a reconhecer os comandos. Após o treinamento é preciso verificar a eficácia do sistema então é realiza a etapa de validação, na qual alguns dados não usados no treinamento são empregados para verificar a taxa de acerto do sistema.

Os algoritmos que tornam possível a tradução de estímulos cerebrais em comandos não são exatos, pois baseiam-se em testes estatísticos e aprendizado de máquina. Uma boa coleta, um pré-processamento que aumente de forma eficiente a relação sinal-ruído, uma extração de atributos que consiga gerar uma boa divisão das classes de estímulos são essenciais para se obter uma BCI de alto desempenho.

Neste trabalho foram implementadas as etapas de processamento digital de sinais cerebrais necessárias para construir uma BCI-SSVEP. Na sequência, foi avaliada a possibilidade de se reduzir o número de dados usados na etapa de treinamento do sistema BCI. A possibilidade de se reduzir a quantidade de dados do indivíduo que vai operar a BCI no treinamento torna a BCI mais prática e permite que a preparação inicial do sistema seja mais rápida e menos cansativa para o usuário. Desta forma foram considerados quatro cenários levando em conta os dados do próprio indivíduo a operar a BCI e outras combinações empregando dados de outros indivíduos no treinamento do classificador.

Na Figura 1 é possível ver uma representação gráfica das etapas de uma BCI.

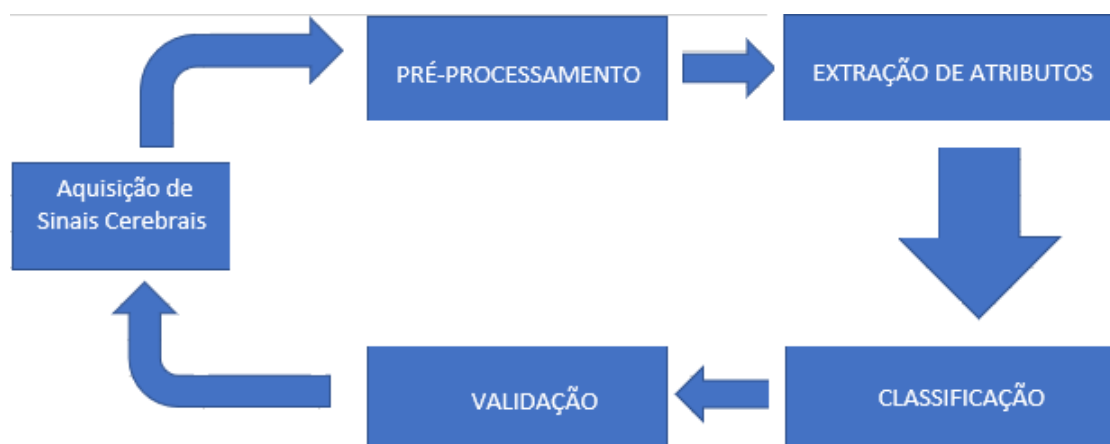


Figura 1 – Fluxograma da BCI.

A saída pode ser enviada para uma aplicação e o retorno ao usuário ocorre devido a observação que o mesmo faz do resultado da classificação da BCI, por exemplo, quando o usuário observa a cadeira de rodas se movendo na direção na qual ele escolheu se concentrar.

Os sinais foram cerebrais de 12 segundos foram pré-processados usando o método CAR (do inglês, *Common Average Reference*) para remoção do ruído de coleta dos eletrodos e foram segmentados em janelas de tempo menores (1, 2, 3, 4 s) para passarem pela etapa de extração dos atributos.

A extração de atributos é feita calculando-se o periodograma de Welch de cada janela do sinal processado em uma faixa de frequências centrada na frequência dos diferentes estímulos. Esta faixa corresponde a uma certa tolerância para as frequências adjacentes, este cálculo é feito pois o periodograma não é pontual, mas sim formado por valores médios da energia do sinal distribuídos na frequência.

Os atributos extraídos são organizados em uma Matriz de Atributos usada para alimentar o classificador do sistema, que usa estes sinais para reconhecer padrões e classificar os sinais que serão futuramente lidos em uma operação online. As classes foram criadas usando uma porção dos dados usados para treinamento do classificador por meio do método de mínimos quadrados.

2 Objetivos

Este estudo tem por objetivo a elaboração de uma BCI utilizando sinais EEG-SSVEP extraídos de uma base de dados com 32 indivíduos que foram estimulados visualmente nas frequências de 6, 10, 12 e 15 Hz. Os sinais foram coletados próximos ao escalpo e preenchem uma matriz em que cada linha corresponde a um dos eletrodos usados na aquisição e cada coluna corresponde a um instante de coleta.

Ao elaborar a BCI é pretendido simular a redução do tempo de treinamento, para que seja estudado o impacto disto na taxa de acerto do sistema e possa ser investigada a possibilidade de elaboração de um BCI que não requer treinamento.

3 Aquisição de dados

"A cada bela impressão que causamos, conquistamos um inimigo. Para ser popular é indispensável ser medíocre." – Oscar Wilde

O processo de aquisição dos sinais usados neste trabalho foi realizado de forma não invasiva empregando-se uma touca de eletrodos posicionada sobre o escalpo para a realização da Eletroencefalografia (EEG). A etapa de aquisição é crítica para o desempenho da BCI, pois uma boa coleta resulta em sinais menos ruidosos e mais fáceis de se recuperar com o pré-processamento, por outro lado uma coleta ruim compromete o desempenho do sistema.

Como sinais cerebrais são de baixa amplitude, é necessário garantir baixa impedância entre os eletrodos e o couro cabeludo. Os sinais utilizados neste trabalho pertencem ao banco de dados do projeto XTReMe(eXperiências de Tecnologias de Reabilitação em Medicina) financiado pela FINEP (Leite *et al.*, 2018).

A coleta baseia-se na visualização de quadros pretos e brancos que mudam de cor, essa mudança ocorre com diferentes frequências, assim se dá a excitação da visão na frequência desejada.

Os sinais foram amostrados a 256 Hz usando 16 eletrodos posicionados em O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz, FCz, seguindo o padrão internacional 10-10, conforme ilustra a Figura 2.




Figura 2 – Posicionamento dos Eletrodos na Aquisição.

Cada região cerebral possui respostas associadas a determinados estímulos e ações cognitivas, como atividade artística, realização de cálculos ou imaginação de movimento. Os eletrodos que proporcionam a resposta mais conveniente e até mesmo suficiente para identificar a intenção de movimento via SSVEP são o O1, O2 e Oz, na região occipital onde é possível registrar o potencial evocado visualmente.

4 Pré-processamento

"... sou um bom detetive: eu suspeito. Não há nada nem ninguém de que não suspeite, nem acredito em coisa alguma que me seja dita"– *O Mistério do Trem Azul*, Agatha Christie.

Os sinais coletados foram pré-processados inicialmente por filtros analógicos presentes no equipamento de coleta, sendo um passa-faixa entre 5 Hz e 100 Hz, onde estão as frequências de interesse e um filtro *notch* em 60 Hz, que é a frequência da rede elétrica. Na sequência empregou-se uma filtragem digital para remoção de artefatos e ruídos. A técnica empregada foi a filtragem CAR, que consiste em subtrair de cada potencial coletado a média dos potenciais de todos os N pontos amostrados naquele instante, removendo os ruídos e interferências comuns nos pontos. (Hakvoort *et al.* 2011).

$$V_i^{CAR} = V_i^{EL} - \frac{1}{N} \sum_{j=1}^N V_j^{EL} \quad (4.1)$$

V_i^{CAR} é o sinal após a remoção do potencial médio de cada ponto coletado naquele instante e V_i^{EL} é o sinal antes da filtragem.

Na Figura 3 encontram-se os três canais para os quais a resposta é mais intensa (O1, O2 e Oz) com suas respectivas respostas temporais antes e depois da filtragem, após um procedimento de normalização.




Figura 3 – Sinal de 12s.

Realizando o janelamento de dois segundos do sinal, é possível ver na Figura 4 o efeito da filtragem para o primeiro segmento de dois segundos.




Figura 4 – Primeiro Segmento de 2s do Sinal.

A Figura 5 mostra a magnitude da FFT do sinal filtrado com CAR para a resposta ao estímulo em 10 Hz, levando em conta o tempo total (12 segundos) de coleta.




Figura 5 – FFT do Sinal de 12s.

É possível perceber que na versão filtrada com CAR há uma atenuação da componente ruidosa e um melhor destaque do pico na frequência evocada em 10 Hz, assim como em sua harmônica de 20 Hz.

Para a primeira janela de dois segundos do sinal é possível observar, na Figura 6 alguns picos mais acentuados próximos a frequência do estímulo. Entretanto é possível notar comparando as Figuras 5 e 6 que a intensidade dos picos em torno da frequência evocada é mais intenso para o janelamento maior (12s), isto contribui para a aquisição de melhores atributos e, conseqüentemente um melhor desempenho do sistema. No entanto,

para tempos muito longos o indivíduo pode diminuir sua atenção ao estímulo e a qualidade do sinal também decai. A aplicação normalmente dita o tempo de análise de maneira que seja razoável e natural para o controle.




Figura 6 – FFT do Primeiro Segmento de 2s.

Embora se tenha escolhido utilizar o método CAR, existem algumas outras técnicas conhecidas na literatura. Em He *et al.* (2006) encontra-se mais informação sobre o método do laplaciano. Uma técnica similar, porém para menor quantidade de eletrodos é o *Small-laplacian*, que é descrito com mais detalhes em Srinivasan *et al.* (2006). Uma outra abordagem é a separação cega de fontes, comumente realizada por meio dos métodos ICA (do inglês, *Independent Component Analysis*), PCA (do inglês, *Principal Component Analysis*), *fast ICA*. Estas metodologias são muito robustas e largamente utilizadas na literatura, para entender melhor o funcionamento desses métodos o leitor pode consultar Li *et al.* (2004).

5 Extração de Atributos

"Este lugar desumano cria monstros humanos." – O Iluminado, Stephen King

É necessário identificar padrões que caracterizem os sinais coletados nos diferentes grupos de frequências de estímulo. Existem vários métodos no domínio do tempo e da frequência capazes de fornecer ferramentas para a caracterização dos sinais. Neste trabalho foi utilizado o Periodograma de Welch.

5.1 Periodograma de Welch

Os periodogramas são métodos de estimação espectral, que são usados para estimar a Densidade Espectral de Potência (PSD, do inglês, *Power Spectral Density*). Existem na literatura vários métodos de estimação propostos, dentre eles os Periodogramas de Daniell e de Bartlett. O Periodograma de Welch é uma modificação do Método de Bartlett (Marple, 1987).

5.1.1 Cálculo do Periodograma de Welch

A proposta da estimação espectral é computar o valor esperado para a potência ou energia do sinal distribuídos em cada componente de frequência. De acordo com Marple (1987), a PSD pode ser computada de forma alternativa assumindo-se que o processo estocástico descrito pelos sinais coletados é ergódico, ou seja, que o processo possui média e variância constantes entre as janelas e a média amostral tende a média populacional. A PSD estimada pode ser definida como:

$$\tilde{P}_{xx}(f) = \frac{T}{N} \left| \sum_{n=0}^{N-1} x[n] e^{-j2\pi f n T} \right|^2 \quad (5.1)$$

onde T é período de amostragem, N é o número de pontos, $x[n]$ é o sinal discreto coletado no domínio do tempo e $\tilde{P}_{xx}(f)$ é a PSD estimada para o sinal $x[n]$.

O Periodograma de Welch trabalha com o sinal janelado e permite que as janelas do sinal tenham sobreposição, pois desta forma é possível diminuir os efeitos do vazamento espectral gerado no processo de janelamento. O efeito da diminuição do vazamento espectral pode ser observado principalmente através da PSD estimada em amplitude logarítmica, pois sem a sobreposição aparecem lóbulos laterais mais pronunciados, que por sua vez são menores com a sobreposição das janelas.

O procedimento para o cálculo do periodograma de Welch começa com a segmentação do sinal analisado $x[n]$, de N amostras em P segmentos de D amostras, como segue:

$$x^{(p)}[n] = w[n]x[n + pS] \quad (5.2)$$

O espectro da amostra do p -ésimo segmento ponderado é dada por:

$$\tilde{P}_{xx}^{(p)}(f) = \frac{1}{UDT} X^{(p)}(f)[X^{(p)}(f)]^* = \frac{1}{UDT} |[X^{(p)}(f)]|^2 \quad (5.3)$$

Sendo $X^{(p)}(f)$ a transformada de Fourier do p -ésimo segmento:

$$X^{(p)}(f) = T \sum_{n=0}^{D-1} x^{(p)}[n]e^{-j2\pi fnT} \quad (5.4)$$

e U a janela de energia em tempo discreto:

$$U = T \sum_{n=0}^{D-1} w^2[n] \quad (5.5)$$

Então, a estimativa do Periodograma de Welch pode ser obtida por meio da média da estimação da PSD de cada um dos P segmentos:

$$\hat{P}_W(f) = \frac{1}{P} \sum_{n=0}^{P-1} \tilde{P}_{xx}^{(p)}(f) \quad (5.6)$$

Após a segmentação do sinal e a filtragem CAR é possível verificar pelo Periodograma de Welch a eficiência do método em acentuar o pico da frequência evocada e diminuir os artefatos nas demais frequências, sobretudo o pico na frequência de 16 Hz que apareceu em quase todos os canais desta coleta, mas foi removido retirando a média dos pontos amostrados no mesmo instante em todos canais.

Na Figura 7, da densidade Espectral de Potência normalizada, estimada pelo Periodograma de Welch, é possível observar a acentuação do pico de 10 Hz, no qual foi realizado o estímulo visual:




Figura 7 – PSD do Sinal de 12s.

Na Figura 8 encontra-se a PSD normalizada do primeiro segmento de 2 segundos da mesma amostra do sinal do gráfico da Figura 7, nele é possível perceber a acentuação do pico na frequência evocada em 10 Hz e a atenuação do pico de 16 Hz. Fica claro pelo sinal obtido no canal O2 que houve aumento da amplitude da primeira harmônica em 20 Hz.




Figura 8 – PSD do Primeiro Segmento de 2s.

5.2 Organização dos Atributos

Para que o sistema possa reconhecer a frequência do estímulo visual ao qual o indivíduo estava exposto é necessário criar um procedimento que permite o treinamento do sistema de classificação e a validação de seu desempenho. As amostras de dados foram divididas e segmentadas sem sobreposição, depois foram selecionados alguns trechos para serem usados no treinamento e os demais trechos foram separados para serem usados na validação da BCI.

5.2.1 Matriz de Atributos

Os atributos foram caracterizados por meio de uma matriz de Densidades Espectrais de Potência estimadas pelo Periodograma do Welch. As PSDs foram calculadas numa faixa que vai de 0,12 Hz antes das frequências do estímulo até 0,12 Hz após a mesma, para que o estímulo fosse caracterizado de forma não pontual (caso em que fosse usada a FFT).

A matriz de atributos foi construída de modo que suas colunas apresentam a PSD estimada em torno de cada frequência evocada para cada um dos 16 canais. As suas linhas apresentam as amostras segmentadas para cada uma das frequências em que de fato os sinais foram estimulados no ato da coleta.

A matriz tem o seguinte formato:

$$\begin{bmatrix} \rho x x_{6Hz}^{ch1}(trial_1^{6Hz}) & \rho x x_{10Hz}^{ch1}(trial_1^{6Hz}) & \rho x x_{12Hz}^{ch1}(trial_1^{6Hz}) & \rho x x_{15Hz}^{ch1}(trial_1^{6Hz}) & \dots & \rho x x_{15Hz}^{ch16}(trial_1^{6Hz}) \\ \vdots & \vdots & \vdots & \vdots & & \vdots \\ \rho x x_{6Hz}^{ch1}(trial_n^{6Hz}) & \rho x x_{10Hz}^{ch1}(trial_n^{6Hz}) & \rho x x_{12Hz}^{ch1}(trial_n^{6Hz}) & \rho x x_{15Hz}^{ch1}(trial_n^{6Hz}) & \dots & \rho x x_{15Hz}^{ch16}(trial_n^{6Hz}) \\ \rho x x_{6Hz}^{ch1}(trial_{n+1}^{10Hz}) & \rho x x_{10Hz}^{ch1}(trial_{n+1}^{10Hz}) & \rho x x_{12Hz}^{ch1}(trial_{n+1}^{10Hz}) & \rho x x_{15Hz}^{ch1}(trial_{n+1}^{10Hz}) & \dots & \rho x x_{15Hz}^{ch16}(trial_{n+1}^{10Hz}) \\ \vdots & \vdots & \vdots & \vdots & & \vdots \\ \rho x x_{6Hz}^{ch1}(trial_{4n}^{15Hz}) & \rho x x_{10Hz}^{ch1}(trial_{4n}^{15Hz}) & \rho x x_{12Hz}^{ch1}(trial_{4n}^{15Hz}) & \rho x x_{15Hz}^{ch1}(trial_{4n}^{15Hz}) & \dots & \rho x x_{15Hz}^{ch16}(trial_{4n}^{15Hz}) \end{bmatrix}$$

Onde, $trial_r^f$ representa o segmento de número r coletado na frequência já conhecida f e $\rho x x_F^{chL}(trial_r^f)$ representa a média dos Periodogramas de Welch computados nas frequências adjacentes a F , indo de $F - 0.12$ Hz a $F + 0.12$ Hz, para o canal L da trial r resultante do estímulo visual na frequência f .

A organização da matriz foi uma opção de construção, no entanto este formato é apenas um dos vários possíveis para se organizar os atributos.

Como foram considerados intervalos de frequência com tolerância de 0.12 Hz, o valor da PSD é quase que analisado pontualmente, no entanto foi escolhida esta abordagem pela possibilidade de se verificar o efeito na taxa de acerto da BCI ao se variar o tamanho da faixa de tolerância.

6 Classificação Linear baseada no Método dos Mínimos Quadrados

"O mundo está cheio de livros fantásticos que ninguém lê." – Umberto Eco

Sinais de EEG apresentam elevada correlação e em geral podem ser eficientemente analisados por classificadores lineares. Em Carvalho *et al.* (2015) é feita a comparação de métodos de classificação quanto ao desempenho e é possível observar que abordagens lineares por vezes são suficientes para estabelecer uma eficiente separação das classes de atributos.

O critério dos mínimos quadrados baseia-se na tentativa de diminuir o valor esperado do quadrado da norma do erro da estimação feita da classificação dos sinais de entrada da BCI.

Para uma entrada H (a matriz de atributos) obtida pela extração de atributos dos dados de treinamento, sendo a saída y (variável de decisão) que identifica a classe a qual os dados analisados na validação pertencem. É preciso encontrar os pesos w tais que seja mínimo o erro da saída do classificador por mínimos quadrados.

Escrevendo de forma matricial, seja a função de custo que minimiza o erro dada por:

$$J_{MQ}(w) = E \left[|y - H^T w|^2 \right] \quad (6.1)$$

O valor ótimo para os pesos ocorre quando:

$$\hat{w} = \min_w J(w) \quad (6.2)$$

onde \hat{w} é o valor estimado do vetor de pesos w .

Em cada uma das frequências estima-se um \hat{w} , tal que $J_{MQ}(w)$ seja mínimo, para isso deve-se encontrar o valor de w tal que:

$$\frac{\partial J_{MQ}(w)}{\partial w} = 2E \left[H(y - H^T w) \right] = 0 \quad (6.3)$$

Aplicando algumas propriedades de álgebra matricial, tem-se que:

$$(H^T H) \hat{w} = H^T y \rightarrow \hat{w} = (H^T H)^{-1} H^T y \quad (6.4)$$

A operação $(H^T H)^{-1} H^T$ é chamada de pseudo-inversa da matriz H e o produto $H^T H$ é conhecido como correlação amostral de H .

Mais detalhes da análise matemática do Método de Mínimos Quadrados podem ser encontrados em Theodoridis *et al.* (2009).

Para reconhecer a frequência do estímulo visual é necessário definir um vetor de variáveis de decisão ideal para cada frequência. Cada posição do vetor representa a característica de uma amostra excitada em uma determinada frequência inicialmente desconhecida, se a amostra foi excitada na frequência característica do vetor de decisão r então esta posição assume o valor 1 na posição da amostra, caso contrário será -1.

Para a frequência de 6 Hz, por exemplo, se houvesse somente uma amostra para cada frequência o vetor r_{6Hz} desejado seria 1 na primeira posição e -1 nas outras três, $r_{6Hz} = [1 - 1 - 1 - 1]$.

A primeira posição corresponde a frequência 6 Hz, por isso o vetor r_{6Hz} assume o valor 1, já na segunda (10 Hz), a terceira (12 Hz) e a quarta (15 Hz) posições assumem o valor -1 pois não foram geradas com a excitação em 6 Hz.

Após o treinamento, isto é, a determinação do vetor de pesos w que define o hiperplano que separa as classes, os dados podem ser classificados operando $y = wH$.

7 Resultados e Discussão

"... E o roteiro da nossa vida? Quem escreve? O destino ou o acaso?" – Stephen King, Revival

Com a finalidade de avaliar o desempenho do sistema, as análises foram divididas em quatro cenários de teste, que variam a forma de treinamento do classificador, além de terem sido usados diferentes tempos de janelamento (12 s, 4 s, 3 s, 2 s e 1 s).

A base de dados empregada continha sinais de 32 indivíduos com 8 coletas para cada uma das quatro frequências de estimulação (6 Hz, 10 Hz, 12 Hz e 15 Hz), sendo cada aquisição de 12 segundos.

- Cenário I- Treinamento com as 8 coletas de 12 segundos do indivíduo. Neste cenário 80% dos dados foram usados para treinar o classificador e 20% foram usados para validar o sistema.
- Cenário II- Treinamento utilizando quatro coletas do indivíduo e os dados dos outros 31 indivíduos disponíveis na base. A validação é feita para cada indivíduo com as outras quatro coletas.
- Cenário III- Treinamento usando os dados somente dos 31 indivíduos da base, sem dados do indivíduo em análise.
- Cenário IV- Treinamento feito com dados de indivíduos selecionados de acordo com algum critério para os sinais de 12s.

IV.a- O critério foi usar para treinamento do classificador dados dos indivíduos que no Cenário I tiveram melhor taxa de acerto (superior a 50%).

IV.b- O critério foi usar para treinamento do classificador dados dos indivíduos que no Cenário I tiveram taxa de acerto intermediária (entre 35% e 55%).

IV.c- O critério foi usar para treinamento do classificador dados dos indivíduos que no Cenário I tiveram melhor taxa de acerto (inferior a 40%).

7.1 Cenário I

Neste cenário pretende-se utilizar o método clássico, treinar e validar o classificador com os dados do mesmo indivíduo, sem utilizar os sinais dos outros indivíduos da base de dados.

Foi feita a validação com a escolha aleatória de 20% dos dados do sujeito para serem usados no treinamento e os 80% restantes foram na etapa de validação, o resultado médio é mostrado no histograma da Figura 9.

Tabela 1 – Taxa de Acerto percentual para o Cenário I

Sujeito	T= 12 s	T=4 s	T=3 s	T=2 s	T=1 s
1	97.38	77.46	69.45	72.22	53.90
2	30.25	28.46	25.95	30.05	30.29
3	28.00	51.39	46.05	49.28	47.79
4	55.63	55.86	50.20	43.55	42.37
5	33.12	32.43	24.90	33.15	28.15
6	53.63	47.75	46.35	46.35	47.30
7	33.37	36.14	38.90	38.27	41.31
8	97.38	85.39	85.35	81.40	68.35
9	43.00	40.29	36.25	35.90	34.48
10	64.50	52.50	44.50	47.35	39.14
11	65.87	71.14	65.60	66.13	61.60
12	92.13	88.79	88.25	83.60	71.61
13	37.25	39.04	41.45	44.07	42.37
14	54.00	60.43	47.55	61.30	61.63
15	24.13	43.04	44.10	47.77	51.09
16	57.13	53.50	50.35	47.87	41.76
17	42.25	46.82	38.62	45.25	40.36
18	25.12	39.54	39.70	43.83	39.46
19	30.13	41.82	38.45	40.80	38.01
20	60.75	65.96	52.50	64.18	56.27
21	25.25	35.71	36.30	41.53	38.41
22	28.63	27.21	23.85	28.37	31.23
23	18.75	35.29	32.85	37.02	35.39
24	40.63	38.46	30.25	39.92	41.76
25	27.63	25.25	23.15	29.00	29.03
26	21.00	36.96	36.10	34.12	30.58
27	89.62	58.07	62.35	60.03	52.56
28	55.37	58.93	55.95	57.53	49.97
29	70.12	66.39	69.00	61.93	59.40
30	96.63	90.93	91.75	89.58	85.86
31	42.63	43.54	40.20	48.08	40.71
32	94.13	82.75	75.70	83.05	78.38
Média	51.11	51.79	48.50	51.02	47.20
Desvio	25.37	18.62	18.71	16.94	14.57

A taxa de acerto do classificador para cada indivíduo neste cenário encontra-se na Tabela 1.

Observa-se que a taxa de acerto permanece praticamente constante para todas as segmentações. Vale ressaltar que com 12 s existem somente seis amostras para treinar e duas para validar, podendo enviesar o resultado devido a baixa quantidade de amostras.

Analisando os resultados da Tabela do Cenário I optou-se por utilizar apenas T= 4 s para as outras análises, pois em média é um tempo de segmentação adequado para aplicações de controle, por exemplo, de um braço robótico ou cadeira de rodas.

É possível avaliar o desempenho da BCI observando como a taxa de acerto do sistema se distribui para os diferentes indivíduos validados por meio de histogramas.




Figura 9 – Histograma para o Cenário I.

No histograma da Figura 9 é possível observar que o comportamento do sistema varia bastante entre os indivíduos considerando que num sistema randômico a taxa de acerto seria de 25% para 4 classes, observa-se que a BCI implementada tem a capacidade de diferenciar as classes para mais de 90% dos indivíduos, alcançando taxas de acerto superiores a 80% para três indivíduos.

7.2 Cenário II

Utilizando somente quatro coletas do próprio indivíduo e os dados dos outros voluntários os resultados foram significativamente reduzidos, como pode ser observado na Tabela 2. No histograma da Figura 10 vê-se que os resultados ainda estão acima da linha da aleatoriedade, no entanto estão bem reduzidos, sendo a maior taxa de acerto inferior a 50%.




Figura 10 – Histograma para o Cenário II.

Neste cenário o classificador se mostra muito ineficaz sem o treinamento, mas ainda é preferível do que sortear um comando aleatório entre os quatros possíveis.

Tabela 2 – Taxa de acerto percentual para o Cenário II

Sujeito	T=12 s	T=4 s	T=3 s	T=2 s	T=1 s
1	53.79	40.13	33.22	33.85	31.22
2	39.33	33.58	28.97	30.22	26.70
3	38.59	31.29	26.78	27.40	26.36
4	35.53	32.15	28.42	28.97	28.46
5	34.71	32.21	28.29	27.86	27.39
6	34.75	32.42	30.11	28.90	28.77
7	31.95	30.37	29.08	28.62	28.43
8	33.70	30.35	29.58	28.81	28.22
9	32.94	30.22	29.10	28.38	27.56
10	31.96	29.03	28.46	27.66	27.32
11	32.18	28.97	28.97	27.81	27.58
12	35.00	31.14	30.89	29.22	28.14
13	33.92	30.60	30.29	28.57	27.42
14	33.51	29.94	29.40	28.04	26.81
15	32.35	28.73	28.28	26.90	26.18
16	31.70	28.25	27.94	26.65	26.00
17	31.34	28.00	27.56	26.41	25.84
18	31.18	27.78	27.14	26.07	25.58
19	30.67	27.34	27.02	25.93	25.40
20	30.84	27.48	27.23	26.02	25.55
21	30.64	26.91	26.78	25.81	25.34
22	30.11	26.72	26.62	25.65	25.26
23	30.14	26.78	26.49	25.60	25.28
24	30.24	27.22	26.66	25.71	25.45
25	30.55	27.29	26.85	25.78	25.41
26	29.89	27.05	26.61	25.52	25.21
27	29.65	27.12	26.64	25.70	25.44
28	29.34	26.81	26.50	25.50	25.36
29	29.20	26.51	26.20	25.16	25.04
30	30.40	27.28	26.95	25.68	25.37
31	30.21	27.11	26.88	25.63	25.31
32	29.85	27.06	26.66	25.48	24.96
Média	31.88	29.18	28.02	27.17	26.51
Desvio	7.38	2.85	1.61	1.88	1.47

7.3 Cenário III

Sem ter sido realizado treinamento com os dados do indivíduo usado na validação os resultados se mostram bem aleatórios e distribuídos em torno de 25%.




Figura 11 – Histograma para o Cenário III.

A taxa de acerto para todos os indivíduos se encontra na Tabela 3.

Tabela 3 – Taxa de acerto percentual para o Cenário III

Sujeito	T=12 s	T=4 s	T=3 s	T=2 s	T=1 s
1	43.75	34.38	31.25	29.69	28.65
2	25.00	30.21	24.22	25.52	22.66
3	37.50	23.96	21.88	21.35	23.96
4	21.88	33.33	32.81	33.33	33.07
5	31.25	30.21	28.13	23.44	22.40
6	28.13	29.17	38.28	33.33	34.11
7	12.50	16.67	21.09	26.56	26.04
8	25.00	26.04	25.78	25.00	25.00
9	25.00	26.04	24.22	25.00	22.40
10	21.88	17.71	21.09	21.88	25.52
11	25.00	18.75	29.69	24.48	25.52
12	46.88	50.00	42.19	38.54	30.47
13	21.88	23.96	22.66	19.79	19.01
14	25.00	19.79	14.06	18.23	17.71
15	12.50	10.42	8.59	9.90	14.06
16	21.88	22.92	20.31	21.35	21.88
17	25.00	21.88	20.31	21.88	22.92
18	28.13	25.00	19.53	20.83	21.09
19	18.75	17.71	24.22	21.88	21.88
20	31.25	27.08	30.47	24.48	27.60
21	21.88	13.54	16.41	20.31	20.31
22	18.75	23.96	21.88	22.92	23.70
23	25.00	28.13	22.66	25.00	25.52
24	31.25	37.50	28.91	28.13	29.17
25	34.38	27.08	30.47	27.60	24.74
26	15.63	20.83	19.53	19.27	20.57
27	21.88	25.00	22.66	26.04	30.73
28	21.88	15.63	21.09	19.79	22.40
29	21.88	13.54	12.50	11.98	11.46
30	53.13	42.71	35.94	34.90	32.29
31	15.63	18.75	23.44	23.44	22.92
32	6.25	11.46	10.94	12.50	9.11
Média	25.49	24.48	23.98	23.70	23.71
Desvio	9.82	8.80	7.56	6.22	5.70

7.4 Cenário IV

Este cenário forneceu desempenho similar ao do Cenário III, com resultados pouco satisfatórios.

Tabela 4 – Taxa de acerto para o Cenário IV (T=4 s)

Sujeito	IV.a- Melhores (%)	IV.b- Medianos(%)	IV.c- Piores(%)
1	19.79	27.08	27.08
2	29.17	23.96	25.00
3	18.75	33.33	36.46
4	25.00	25.00	32.29
5	25.00	20.83	25.00
6	23.96	27.08	21.87
7	25.00	20.83	22.92
8	20.83	21.88	28.13
9	27.08	29.17	22.92
10	28.13	19.79	21.87
11	21.88	22.92	31.25
12	33.33	36.46	26.04
13	27.08	18.75	20.83
14	32.29	9.38	22.92
15	20.83	18.75	8.33
16	26.04	22.92	25.00
17	25.00	18.75	26.04
18	21.88	16.67	25.00
19	26.04	26.04	25.00
20	44.79	23.96	16.67
21	15.63	15.63	27.08
22	28.13	27.08	27.08
23	33.33	25.00	17.71
24	15.63	33.33	23.96
25	19.79	25.00	26.04
26	23.96	15.63	21.88
27	17.71	25.00	27.08
28	19.79	28.13	19.79
29	31.25	19.79	11.46
30	30.21	31.25	32.29
31	18.75	28.13	26.04
32	26.04	17.71	20.83
Média	25.07	23.60	24.12
Desvio	6.07	5.87	5.60

7.4.1 Cenário IV.a




Figura 12 – Histograma para o Cenário IV.a.

Percebe-se que usar os melhores resultados do Cenário I para treinamento não gera resultados muito bons, visto que os resultados da validação estão distribuídos em torno de 25%.

7.4.2 Cenário IV.b

Este cenário não diverge muito do anterior, os resultados também se mostram bem aleatórios e indicam que treinar com os dados dos indivíduos com desempenho mediano não contribui muito com a taxa de acerto.




Figura 13 – Histograma para o Cenário IV.b.

7.4.3 Cenário IV.c

Os resultados deste Cenário são ainda piores que os anteriores visto que há mais resultados abaixo de 25%. Os desempenho do classificador neste caso também não foi satisfatório.




Figura 14 – Histograma para o Cenário IV.c.

Valores exatos das taxas de acerto do Cenário IV encontram-se na Tabela 4.

Ao analisar os resultados dos Cenários II, III e IV foi possível constatar que a etapa de treinamento do classificador deve conter dados do próprio indivíduo para garantir uma boa performance do sistema, pois isto afeta, de forma negativa, o desempenho da BCI.

8 Conclusão

Ao analisar os resultados foi verificado que o sistema apresenta considerável confiabilidade quando o material de treinamento do indivíduo que opera o sistema não é reduzido, porém ao reduzir a base de treinamento do indivíduo e incluir dados de outros indivíduos a taxa de acerto decai. Assim para as técnicas de extração de atributos e classificação utilizadas neste trabalho não é viável flexibilizar a etapa de treinamento como foi apresentado.

No Cenário I, no qual não há redução de treinamento, a BCI apresentou funcionamento adequado para quase todos os indivíduos e boas taxas de acerto na média ou igual para todos os janelamentos, exceto apenas para alguns casos em que possivelmente o usuário não se concentrou o suficiente no estímulo ou o ambiente da coleta não foi ideal.

Trabalhos futuros podem incluir melhorias na classificação, talvez com o uso de técnicas mais eficientes, como redes neurais, algoritmos de aprendizagem de máquina etc. Talvez seja interessante investigar se para alguma técnica específica o tempo de treinamento pode ser reduzido ou um sistema genérico e robusto possa ser criado, como um produto que funcione independentemente do usuário.

Referências

- CARVALHO, S. N. et al. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control*, Elsevier, v. 21, p. 34–42, 2015.
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain–Computer Interfaces: A gentle introduction. In: *Brain-Computer Interfaces*. [S.l.]: Springer, 2010. p. 1–27.
- HAKVOORT GIDO; REUDERINK, B. O. M. Comparison of psda and cca detection methods in a ssvep-based bci-system. Centre for Telematics and Information Technology University of Twente, 2011.
- HÄMÄLÄINEN, M. S.; ILMONIEMI, R. J. Interpreting magnetic fields of the brain: minimum norm estimates. *Medical & Biological Engineering & Computing*, v. 32, n. 1, p. 35–42, Jan 1994. ISSN 1741-0444.
- HE, X.; CAI, D.; NIOYOGI, P. Laplacian score for feature selection. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2006. p. 507–514.
- JURCAK VALER; TSUZUKI, D. D. I. 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. *Neuroimage*, Elsevier, v. 34, n. 4, p. 1600–1611, 2007.
- LEBEDEV, M. A.; NICOLELIS, M. A. Brain–machine interfaces: past, present and future. *Trends in Neurosciences*, v. 29, n. 9, p. 536 – 546, 2006. ISSN 0166-2236. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0166223606001470>>.
- LEITE, H. M. d. A. et al. Analysis of user interaction with a brain-computer interface based on steady-state visually evoked potentials: Case study of a game. *Computational intelligence and neuroscience*, Hindawi, v. 2018, 2018.
- LI, Y. et al. A hybrid BCI system combining P300 and SSVEP and its application to wheelchair control. *Biomedical Engineering, IEEE Transactions on*, IEEE, v. 60, n. 11, p. 3156–3166, 2013.
- MARPLE, S. Lawrence. *Digital spectral analysis with applications*. [S.l.: s.n.], 1987.
- PARK, C. e. a. Classification of motor imagery bci using multivariate empirical mode decomposition. *IEEE Transactions on neural systems and rehabilitation engineering*, IEEE, v. 21, n. 1, p. 10–22, 2013.
- SEARLE A.; KIRKUP, L. A direct comparison of wet, dry and insulating bioelectric recording electrodes. *Physiological measurement*, IOP Publishing, v. 21, n. 2, p. 271, 2000.
- SRINIVASAN RAMESH; BIBI, F. A. N. P. L. Steady-state visual evoked potentials: distributed local sources and wave-like dynamics are sensitive to flicker frequency. *Brain topography*, Springer, v. 18, n. 3, p. 167–187, 2006.
- VALBUENA, D. et al. Brain-computer interface for high-level control of rehabilitation robotic systems. In: IEEE. *Rehabilitation Robotics, 2007. ICORR 2007. IEEE 10th International Conference on*. [S.l.], 2007. p. 619–625.

VOLOSYAK, I. et al. Brain–computer interface using water-based electrodes. *Journal of neural engineering*, IOP Publishing, v. 7, n. 6, p. 066007, 2010.

WELCH, P. D. The use of Fast Fourier Transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, v. 15, n. 2, p. 70–73, 1967.