



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



## **Trabalho de Conclusão de Curso**

# **Controle On-line de um Manipulador Robótico por Meio de um Sistema BCI-SSVEP**

**Guilherme Vettorazzi Vargas**

João Monlevade, MG  
2018

**Guilherme Vettorazzi Vargas**

**Controle On-line de um Manipulador Robótico  
por Meio 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.<sup>a</sup> Dr.<sup>a</sup> Sarah N. de Carvalho Leite

Coorientador: Prof. Romeu Yukio Takeda

**Universidade Federal de Ouro Preto  
João Monlevade, MG  
2018**

V297c

Vargas, Guilherme Vettorazzi.

Controle on-line de um manipulador robótico por meio de um sistema BCI-SSVEP [manuscrito] / Guilherme Vettorazzi Vargas. - 2018.

40f.: il.: color; grafs; tabs.

Orientadora: Prof<sup>a</sup>. MSc<sup>a</sup>. Sarah Negreiros de Carvalho Leite.

Coorientador: Prof. MSc. Romeu Yukio Takeda.

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

1. Engenharia elétrica. 2. Processamento de sinais. 3. Interface cérebro-computador. I. Leite, Sarah Negreiros de Carvalho. II. Takeda, Romeu Yukio. III. Universidade Federal de Ouro Preto. IV. Título.

CDU: 621.3

Catálogo: [ficha@sisbin.ufop.br](mailto:ficha@sisbin.ufop.br)



### ATA DE DEFESA

Aos 08 dias do mês de maio de 2018, às 10 horas, no bloco B deste instituto, foi realizada a defesa de monografia pelo formando **Guilherme Vettorazzi Vargas**, sendo a comissão examinadora constituída pelos professores: Dr. Harlei Miguel de Arruda Leite, Dr.<sup>a</sup> Gilda Aparecida de Assis, Dr. Glauco Ferreira Gazel Yared, Romeu Yukio Takeda e Dr.<sup>a</sup> Sarah Negreiros de Carvalho Leite.

O candidato apresentou a monografia intitulada: Controle online de um manipulador robótico por meio de um sistema BCI-SSVEP. A comissão examinadora deliberou, por unanimidade, pela aprovação do candidato, com a nota média 10.0, de acordo com a Tabela 1. Na forma regulamentar foi lavrada a presente ata que é assinada pelos membros da comissão examinadora e pelo formando.

Tabela 1 – Notas de avaliação da banca examinadora

Banca Examinadora	Nota
Prof. Dr. Harlei Miguel de Arruda Leite	10.0
Prof. <sup>a</sup> Dr. <sup>a</sup> Gilda Aparecida de Assis	10.0
Prof. Dr. Glauco Ferreira Gazel Yared	10.0
Prof. Romeu Yukio Takeda	10.0
Prof. <sup>a</sup> Dr. <sup>a</sup> Sarah Negreiros de Carvalho Leite	10.0
<b>Média</b>	<b>10.0</b>

João Monlevade, 08 de maio de 2018.

  
\_\_\_\_\_  
Harlei Miguel de Arruda Leite

Professor Convidado

  
\_\_\_\_\_  
Gilda Aparecida de Assis

Professora Convitada

  
\_\_\_\_\_  
Glauco Ferreira Gazel Yared

Professor Convidado

  
\_\_\_\_\_  
Romeu Yukio Takeda

Professor Coorientador

  
\_\_\_\_\_  
Sarah Negreiros de Carvalho Leite

Professora Orientadora

  
\_\_\_\_\_  
Guilherme Vettorazzi Vargas

Aluno



O texto do trabalho de conclusão de curso intitulado "Controle On-line de um Manipulador Robótico por Meio 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, 14 de Maio de 2018.

Guilherme Vettorazzi Vargas  
Nome completo do(a) aluno(a)

*Dedico este trabalho a todos aqueles que sempre torceram pelo meu sucesso.*

# Agradecimentos

Agradeço de forma especial aos meus pais, Ézio e Cida, que estão sempre me incentivando a buscar e realizar meus sonhos. Ao meu pai, principalmente por ser a grande fonte de inspiração deste trabalho devido a luta contra sua doença devastadora.

Agradeço à minha orientadora, Prof.<sup>a</sup> Dr.<sup>a</sup> Sarah Negreiros por toda a paciência, conhecimento compartilhado e por todas as oportunidades concebidas. Ao meu coorientador, Prof. Romeu Takeda, por sua disponibilidade em todos os momentos necessitados. Ao Prof. Dr. Harlei Leite, pelos inúmeros momentos no laboratório.

Agradeço também aos meus companheiros e ex-companheiros de república, Felipe, Gustavo, Lincoln, José Artur e Victor, por todo o companheirismo e paciência, e também aos meus grandes amigos de universidade, por diminuírem a dificuldade desta trajetória.

Por fim, agradeço a Deus, pois tudo isso não seria possível sem Ele.

*"However difficult life may seem, there is always something you can do and succeed at."*  
– *Stephen Hawking*

# Resumo

Um sistema BCI (*Brain Computer Interface*) é definido como uma interface que fornece ao cérebro humano um canal de comunicação e controle não-muscular. Diante desta definição, sistemas BCI vêm atuando no controle de aplicações assistivas para pacientes com algum tipo de deficiência física. No caso desta monografia, todas as principais etapas envolvidas no processo de implementação de um sistema BCI foram desenvolvidas. Tais etapas podem ser descritas como: aquisição de sinais cerebrais, pré-processamento dos dados coletados, extração de características, seleção de atributos, classificação linear e integração do sistema com uma aplicação externa. Os sinais cerebrais foram coletados por meio de eletroencefalografia, utilizando 16 eletrodos posicionados nas zonas occipital, parietal e no córtex central do cérebro humano, aplicando a técnica de estimulação visual sob o paradigma *Steady State Visually Evoked Potential* (SSVEP) nas frequências de 6, 10, 12 e 15 Hz. Duas técnicas de extração de atributos foram avaliadas: periodograma de Welch e *Short Time Fourier Transform* (STFT). Os resultados mostraram que o método da STFT fornece taxas de acerto superiores na maioria dos cenários analisados, acima de 90% para algumas frequências. O sistema BCI desenvolvido foi integrado a um manipulador robótico, e dois voluntários obtiveram êxito na execução de uma tarefa de controle, que consistia no deslocamento de um bloco de espuma. A tarefa foi executada de forma mais lenta e necessitando de mais comandos, devido as taxas de erro do sistema quando comparado ao controle do manipulador por métodos convencionais de interação, como o teclado. Entretanto, o sistema BCI-SSVEP desenvolvido foi capaz de alcançar os objetivos propostos com taxas mínimas de erro percentual médio.

**Palavras-chave:** BCI, SSVEP, processamento de sinais, Welch, STFT, manipulador robótico.

# Abstract

A Brain Computer Interface is defined as an interface that provides the human brain with a non-muscular communication and control channel. Given this definition, BCI systems have been working in the control of assistive applications for patients with some type of physical disability. In this study, all the main steps involved in the implementation process of a BCI system were developed. Such steps can be described as: brain signals acquisition, data preprocessing, feature extraction, attributes selection, linear classifier and integration of the system with an external application. The brain signals were collected by means of electroencephalography, using 16 electrodes positioned in the occipital, parietal and central zones of the human brain, applying the Steady State Visually Evoked Potential (SSVEP) paradigm in the frequencies of 6, 10, 12 and 15 Hz. Two feature extraction techniques were evaluated: Welch's method and Short Time Fourier Transform (STFT). The results showed that the STFT method provides superior rates in most of the scenarios analyzed, greater than 90% for some frequencies. The developed BCI system was integrated with a robotic manipulator, and two volunteers were successful in carrying out a control task, which consisted in the displacement of a block of foam. The task was performed more slowly and required more commands due to system error rates when compared to manipulator control by conventional interaction methods, such as the keyboard. However, the developed BCI-SSVEP system was able to reach the proposed objectives, considering the state of the art of the area, with minimum average error rates.

**Keywords:** BCI, SSVEP, signal processing, Welch, STFT, robotic manipulator.

# Lista de ilustrações

Figura 1 – Diagrama com todas as etapas de uma BCI. . . . .	3
Figura 2 – Disposição dos 16 eletrodos sobre o couro cabeludo seguindo o padrão internacional de posicionamento 10-10. . . . .	7
Figura 3 – Tela de estimulação visual utilizada no processo de coleta de dados. . .	8
Figura 4 – Representação temporal comparativa entre o sinal proveniente do eletrodo Oz com estímulo em 6 Hz, antes e depois da filtragem CAR. . . .	10
Figura 5 – Representação espectral comparativa entre o sinal proveniente do eletrodo Oz com estímulo em 6 Hz, antes e depois da filtragem CAR. . . .	10
Figura 6 – Braço robótico articulado. . . . .	16
Figura 7 – Percentual de acerto do sistema BCI utilizando janelas de 4 segundos. . .	19
Figura 8 – Percentual de acerto do sistema BCI utilizando janelas de 6 segundos. .	20
Figura 9 – Percentual de acerto do sistema considerando a disponibilidade 64 e 60 janelas para cenários de 6 e 4 segundos, respectivamente . . . . .	21
Figura 10 – Representação espectral comparativa entre o sinal proveniente do eletrodo Oz para o indivíduo 3 com estímulo em 6 Hz para janelas de 4 e 6 segundos. . . . .	25

# Lista de tabelas

Tabela 1 – Relação de frequências de estimulação, comandos executados e servomotores utilizados. . . . .	18
Tabela 2 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 1 com janelas de 4 segundos. . . . .	21
Tabela 3 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 1 com janelas de 6 segundos. . . . .	22
Tabela 4 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 2 com janelas de 4 segundos. . . . .	22
Tabela 5 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 2 com janelas de 6 segundos. . . . .	22
Tabela 6 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 3 com janelas de 4 segundos. . . . .	23
Tabela 7 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 3 com janelas de 6 segundos. . . . .	23
Tabela 8 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 4 com janelas de 4 segundos. . . . .	23
Tabela 9 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 4 com janelas de 6 segundos. . . . .	24
Tabela 10 – Resposta do classificador de acordo com a frequência de estimulação focalizada para o indivíduo 3. . . . .	26
Tabela 11 – Resposta do classificador de acordo com a frequência de estimulação focalizada para o indivíduo 4. . . . .	27

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>1.1</b>	<b>Conceitos Preliminares</b>	<b>2</b>
<b>1.2</b>	<b>Revisão Bibliográfica</b>	<b>4</b>
<b>1.3</b>	<b>Objetivos</b>	<b>5</b>
<b>1.4</b>	<b>Estrutura do Trabalho</b>	<b>6</b>
<b>2</b>	<b>METODOLOGIA</b>	<b>7</b>
<b>2.1</b>	<b>Coleta de Dados</b>	<b>7</b>
<b>2.2</b>	<b>Processamento do Sinal</b>	<b>8</b>
<b>2.3</b>	<b>Pré-Processamento Digital</b>	<b>9</b>
<b>2.4</b>	<b>Extração de Atributos</b>	<b>11</b>
2.4.1	Método de Welch	11
2.4.2	Método da STFT	13
<b>2.5</b>	<b>Seleção de Atributos</b>	<b>13</b>
<b>2.6</b>	<b>Classificador Linear</b>	<b>15</b>
<b>2.7</b>	<b>Aplicação: Braço Robótico</b>	<b>16</b>
2.7.1	Controle On-line	17
<b>3</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>19</b>
<b>3.1</b>	<b>Testes off-line</b>	<b>19</b>
<b>3.2</b>	<b>Testes on-line</b>	<b>25</b>
<b>4</b>	<b>CONCLUSÃO</b>	<b>28</b>
	<b>REFERÊNCIAS</b>	<b>29</b>

# 1 Introdução

Segundo a Organização Mundial de Saúde (OMS), a deficiência é classificada como todo e qualquer problema na estrutura e/ou funções do corpo humano, podendo este problema ser parcial ou total (SAÚDE, 2003). Em termos estatísticos, estima-se que 6,2% da população brasileira possua algum tipo de deficiência, dentre os quais estão deficiência física, auditiva, visual e intelectual. Mais especificamente sobre deficiência física, contabilizam-se neste grupo, cerca de 1,6% da população brasileira (CENSO, 2010). Diante deste cenário, vários estudos vêm sendo realizados com o intuito de desenvolver tecnologias assistivas para pacientes com algum tipo de limitação física (MÜLLER; BASTOS; FILHO, 2013).

Estas medidas assistivas podem ser exemplificadas por meio do desenvolvimento de instrumentos tecnológicos, como uma cadeira de rodas automática (MÜLLER; BASTOS; FILHO, 2013) e próteses (ORTNER et al., 2011). Para as aplicações citadas, é necessária uma interação do cérebro humano com tais equipamentos. Neste contexto surge o conceito da Interface Cérebro Computador, ou simplesmente BCI (do inglês, *Brain Computer Interface*). Um sistema BCI, segundo Wolpaw et al. (2002), é um dispositivo que fornece ao usuário um canal de comunicação e controle não-muscular. Uma outra definição, por Graimann, Allison e Pfurtscheller (2010), relaciona a BCI com a mensuração de atividades cerebrais de um determinado indivíduo e a intenção deste indivíduo de realizar determinada tarefa. Tais atividades cerebrais são convertidas em sinais de controle, que podem ser utilizados por aplicações em diversas áreas.

Várias técnicas são responsáveis por fazer esta conexão entre cérebro humano e a BCI propriamente dita (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). As técnicas de estimulação utilizadas podem se basear em diferentes estratégias, tais como: imagética motora, imaginação de tarefa, P300 e SSVEP. Mais especificamente sobre a técnica SSVEP (do inglês: *Steady State Visual Evoked Potential*), Middendorf et al. (2000) introduziu um sistema capaz de avaliar a concentração do olhar do indivíduo, por meio de análises de mudanças de amplitude resultante do potencial visualmente evocado em regime permanente medido. Para isso, uma fonte luminosa cintilante foi utilizada, gerando um potencial evocado nas frequências correspondentes.

No caso desta monografia, serão apresentados toda a metodologia adotada para a implementação de uma BCI sob o paradigma SSVEP, bem como resultados obtidos na validação do sistema implementado para o seu uso em uma aplicação em tempo real.

## 1.1 Conceitos Preliminares

Nesta seção, conceitos preliminares relacionados ao eletroencefalograma (EEG) e também às Interfaces Cérebro Computador são expostos.

Para o entendimento adequado relacionado ao eletroencefalograma, é necessário primeiro introduzir os conceitos fisiológicos. Segundo Sanei e Chambers (2013), o Sistema Nervoso Central (SNC) é constituído basicamente de células nervosas e células da glia. As células nervosas, compostas por axônios, dendritos e corpos celulares, respondem a estímulos, transmitindo informações por longas distâncias por meio dos axônios. Os dendritos, conectados aos axônios ou dendritos de outras células, recebem impulsos de outros nervos ou retransmitem sinais a outros nervos. Pelo fato de não existir continuidade celular entre um neurônio e o seguinte, é necessário a liberação de neurotransmissores que promovem a transmissão dos sinais entre células emissoras e receptoras pelo canal sináptico (KAMENETZ et al., 2003). Esta corrente que flue entre neurônios durante o processo de excitação sináptica gera um campo magnético e um campo elétrico secundário. Na mensuração do campo magnético, a técnica de fMRI (do inglês: *Functional Magnetic Resonance Imaging*) pode ser utilizada. Em relação ao campo elétrico, uma técnica bastante empregada em sistemas BCI é o eletroencefalograma, capaz de realizar a mensuração sobre o escalpo do indivíduo.

Por capturar características de funcionamento do cérebro humano, o estudo do EEG vem permitindo e auxiliando o diagnóstico de várias anomalias cerebrais, como a epilepsia (SANEI; CHAMBERS, 2013). Neste caso, sua origem pode ser descoberta, bem como o monitoramento da ação de medicamentos utilizados no tratamento. Além disso, a interpretação destes sinais pode implicar em diversas aplicações na área tecnológica e médica, principalmente nos processos de reabilitação pós-traumática.

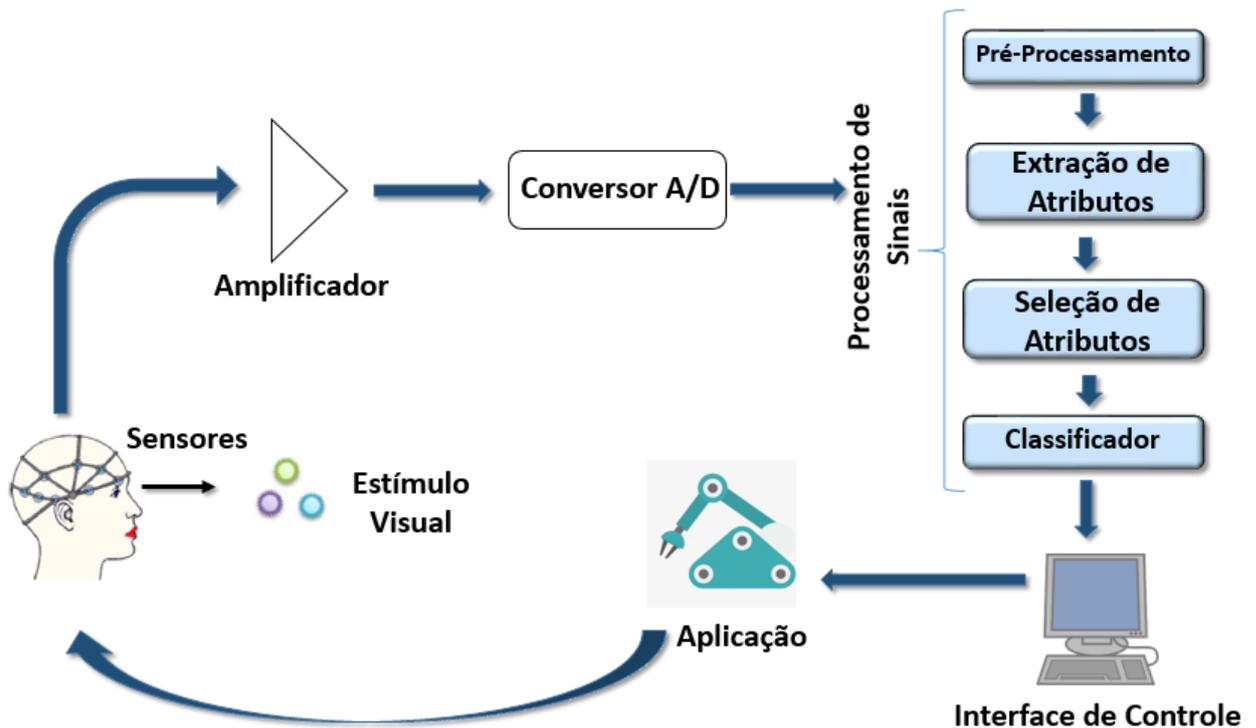
O primeiro passo para a implementação de um sistema BCI consiste na aquisição dos sinais cerebrais. Para isso, existem duas técnicas de coleta de sinais elétricos cerebrais: invasivas e não-invasivas (MILLÁN; CARMENA, 2010). No método invasivo, o indivíduo é submetido à uma cirurgia denominada craniotomia, sendo os sensores implantados diretamente sobre o córtex cerebral ou no tecido intracortical. No processo não invasivo, não há necessidade de cirurgias, sendo a coleta realizada por meio de eletrodos posicionados diretamente sobre o escalpo do indivíduo (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). Existem algumas vantagens e desvantagens de uma técnica sobre a outra, porém, a melhor escolha é determinada pelo tipo de aplicação que se deseja implementar.

Após o processo de aquisição, os sinais coletados são amplificados, filtrados e digitalizados. Na etapa subsequente é realizado o processamento digital do sinal, que consiste de vários procedimentos. O primeiro é o pré-processamento, que tem a finalidade de remover os artefatos que persistiram na base de dados após a filtragem analógica e, conseqüentemente, melhorar a relação sinal-ruído (SNR). Após o pré-processamento, ocorre a extração de atributos, que descrevem de maneira compacta as informações do sinal úteis

para identificar e discriminar dentre os possíveis comandos disponíveis. Na seleção de atributos, há uma redução do volume de dados bem como melhorias de performance em termos de acurácia preditiva. Finalmente, um sistema classificador interpreta os atributos e gera um comando para a aplicação executar a tarefa associada (GRAIMANN; ALLISON; PFURTSCHHELLER, 2010).

Por ser considerada uma interface não-muscular, a BCI vem sendo amplamente vinculada com a possibilidade de promover assistência a indivíduos com algum tipo de incapacidade física. Um grande exemplo de possibilidade de atuação da BCI está relacionado à Esclerose Lateral Amiotrófica (ELA), doença que ficou conhecida pelo físico britânico mundialmente famoso, Stephen Hawking (FERGUSON, 2011). Tal doença afeta a parte motora do paciente, fazendo com que o mesmo perca toda a capacidade de movimento no decorrer dos anos. Neste caso, a BCI pode atuar de maneira paliativa no dia-a-dia do paciente, auxiliando o movimento de uma cadeira de rodas automática, por exemplo (MÜLLER; BASTOS; FILHO, 2013). A Figura 1 ilustra todas as etapas de um sistema BCI-SSVEP

Figura 1 – Diagrama com todas as etapas de uma BCI.



## 1.2 Revisão Bibliográfica

Em meados de 1875 o cientista Richard Caton (1842–1926), natural de Liverpool (Inglaterra) promoveu o que pode ser considerado a primeira coleta de dados cerebrais da história. Utilizando-se de um galvanômetro e um par de eletrodos, coletou sinais cerebrais em forma de sinais elétricos sobre o couro cabeludo de um determinado indivíduo. Seguindo os passos de Caton, Fritsch (1838–1927) e Hitzig (1838–1907) fizeram a grande descoberta de que o cérebro humano poderia ser estimulado eletricamente. Subsequentemente, numerosos experimentos com animais foram realizados, entretanto, somente em 1920, estudos em humanos relacionados a sinais de eletroencefalograma (EEG) foram iniciados, por obra de Hans Berger (1873–1941). Berger foi um grande inspirador de trabalhos futuros, tendo em vista que nos anos 90, trabalhos relacionados ao EEG humano foram iniciados nas Universidades norte-americanas de Harvard e Iowa (SANEI; CHAMBERS, 2013).

No contexto histórico, muito se fala a respeito do primeiro sistema BCI implementado. Segundo Graimann, Allison e Pfurtscheller (2010), a primeira BCI descrita é creditada ao Dr. Grey Walter em 1964, durante um procedimento cirúrgico com um paciente. Neste procedimento, com eletrodos conectados diretamente nas áreas motoras de seu cérebro, o paciente foi solicitado a apertar um botão responsável por controlar um projetor de *slides* enquanto o Dr. Walter monitorava as atividades cerebrais relevantes. Desta maneira, a transição dos *slides* no projetor ocorria a medida que as atividades cerebrais do paciente indicavam a intenção do paciente em apertar o botão.

As descobertas dos cientistas promoveram grandes contribuições no contexto histórico que se refletem nos dias atuais, como a interpretação e tradução de sinais EEG em comandos de controle que permitem a concepção de sistemas de interface cérebro computador, principalmente na assistência de indivíduos com necessidades especiais. Entretanto, para que isso aconteça, primeiramente deve existir um estudo sobre a possibilidade de determinado indivíduo ser ou não apto a utilizar tais sistemas. Neste contexto, Guger et al. (2003) promoveu um estudo, fazendo um levantamento de quantas pessoas são capazes de operar um sistema BCI. No experimento, os indivíduos foram responsáveis por controlar uma barra horizontal na tela de um computador utilizando técnicas de imagética motora. De acordo com o procedimento conduzido, o autor constatou que aproximadamente 93% dos 99 indivíduos avaliados foram capazes de operar um sistema BCI com mais de 60% de acerto após duas sessões de treinamento.

Ainda sobre a capacidade assistiva de sistemas BCI, vários autores concentraram seus esforços na elaboração de aplicações. Por exemplo, Ortner et al. (2011) desenvolveu um sistema BCI-SSVEP para controlar uma prótese de uma mão, de maneira assistiva a pacientes com tetraplegia. No estudo, o autor utilizou um sistema assíncrono, ou seja, o indivíduo poderia mover a prótese quando desejasse, sem necessidade de esperar algum sinal externo. Outro sistema BCI-SSVEP foi proposto por Müller, Bastos e Filho (2013) para comandar uma cadeira de rodas, onde nove voluntários saudáveis foram capazes de

controlar o sistema de quatro classes com precisão de  $83 \pm 15\%$ .

Nos sistemas BCI é desejável obter a melhor acurácia possível. Para isso, muitos trabalhos se concentram em desenvolver e aprimorar técnicas de aquisição e/ou processamento do sinal cerebral que elevem o percentual de acerto do sistema. Wu e Su (2014) analisaram métodos de escolha do eletrodo de referência na etapa da coleta de dados. Utilizando um identificador da relação sinal-ruído, os autores indicam qual o melhor eletrodo a ser utilizado como referência. Além disso, Johnson et al. (2013) propuseram uma variação de tamanho de janelas utilizadas na etapa de classificação, comparando os resultados com um tamanho de janela fixa. Tavares et al. (2015) compararam diversos cenários com e sem seleção de características. Resultados obtidos indicaram um aumento de cerca de 37% em relação ao percentual de acerto do sistema quando se utilizam técnicas de seleção de atributos.

Recentemente, estudos relacionados à elaboração de sistemas BCI vêm se tornando cada vez mais frequentes. O paralelismo deste crescente interesse com a grande gama disponível para o desenvolvimento de aplicações tecnológicas é fundamental para o estabelecimento de melhores condições de vida para indivíduos que possuam algum tipo de limitação física. O desenvolvimento de interfaces híbridas que combinam os paradigmas P300 e SSVEP simultaneamente tem se tornado bastante frequente. Yin et al. (2014) desenvolveram um sistema híbrido com a finalidade de obtenção de maior velocidade de grafia de símbolos pré-determinados. O autor constatou que esta técnica pode atingir maiores velocidades que técnicas tradicionais que utilizam isoladamente P300 ou SSVEP.

Apesar da maioria dos estudos estarem associados a aplicações individuais destinadas a diversos tipos de pacientes, como cadeiras de rodas automáticas e comunicadores, pouco tem sido desenvolvido em termos de aplicações na casa destes pacientes. Holz et al. (2015) promoveram um estudo de caso, avaliando o uso de uma BCI residencial para melhorar a qualidade de vida de um paciente com síndrome de encarceramento. Neste estudo, os autores utilizam um sistema BCI sob o paradigma P300. Resultados indicaram que o uso de BCI residencial pode ser utilizado com um alto índice de satisfação do usuário final, contribuindo com melhorias em termos de qualidade de vida e inclusão social.

### 1.3 Objetivos

Baseando-se na implementação de um sistema BCI sob o paradigma SSVEP, os principais objetivos desta monografia podem ser resumidos no desenvolvimento das etapas necessárias à implementação de uma Interface Cérebro Computador. Tais etapas podem ser descritas como:

- Aquisição de sinais cerebrais por meio de EEG;
- Amplificação, filtragem e digitalização dos sinais;

- Implementação das etapas de processamento digital dos sinais cerebrais:
  - **Pré-processamento:** segmentação dos dados e filtragem CAR (“*Common Average Reference*”);
  - **Extração de atributos:** STFT (“*Short Time Fourier Transform*”) e periodograma de Welch;
  - **Seleção de atributos:** filtro de Pearson;
  - **Classificador:** classificador linear baseado no método dos mínimos quadrados.
- Comparação de métodos de extração de atributos, STFT e Periodograma de Welch, levantando resultados em relação ao percentual de acerto final do sistema;
- Integração do sistema BCI-SSVEP implementado para um braço robótico com quatro graus de liberdade em modo on-line.

## 1.4 Estrutura do Trabalho

Este trabalho está dividido em quatro capítulos. No Capítulo 1 é apresentada a introdução e são especificados alguns conceitos preliminares relacionados aos principais termos do projeto, tais como BCI, EEG e SSVEP. Além disso, é apresentada a revisão da bibliografia. Também são expostos os objetivos do trabalho.

O Capítulo 2 contém explicações detalhadas da metodologia utilizada na monografia. Descrição das atividades realizadas como coleta de dados, pré-processamento, extração e seleção de atributos e classificação linear, estão contidas separadamente em subseções.

Após o embasamento teórico necessário, são apresentados no Capítulo 3, os resultados juntamente com uma discussão crítica.

No Capítulo 4 é realizada a conclusão do projeto e são propostos trabalhos futuros.

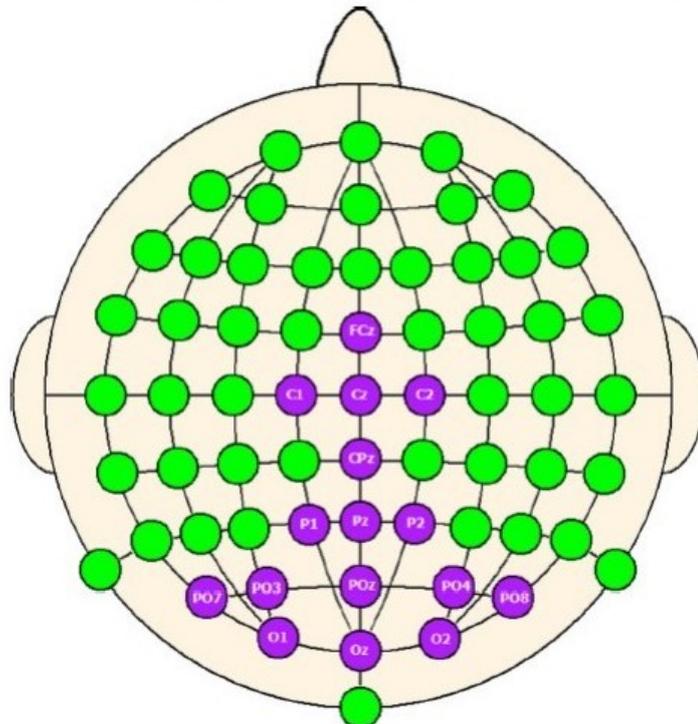
## 2 Metodologia

A metodologia adotada nesta monografia pode ser dividida em quatro partes: coleta de dados, pré-processamento, extração de atributos, seleção de atributos e classificação linear. As subseções seguintes contêm explicações detalhadas de cada parte.

### 2.1 Coleta de Dados

No processo de implementação da BCI, a primeira etapa esteve relacionada com a coleta de sinais de EEG de quatro indivíduos, todos do sexo masculino e com idades correspondentes a um valor médio de  $28 \pm 6,97$  anos. A coleta foi realizada na Universidade Estadual de Campinas (UNICAMP), seguindo estritamente as normas do Comitê de Ética referente ao processo n.791/2010 (LEITE et al., 2018). Em relação ao processo de coleta de dados, os eletrodos foram posicionados sobre o escalpo do voluntário nas posições O1, O2, Oz, POz, Pz, PO4, PO3, PO8, PO7, P2, P1, Cz, C1, C2, CPz e FCz, segundo o padrão internacional 10-10 (JURCAK; TSUZUKI; DAN, 2007). Tal escolha foi realizada de modo a cobrir os lobos occipital e parietal, bem como a linha média e a região do córtex motor. Os eletrodos de referência foram posicionados nos processos mastoideos (WU; SU, 2014). A Figura 2 ilustra como o posicionamento foi disposto.

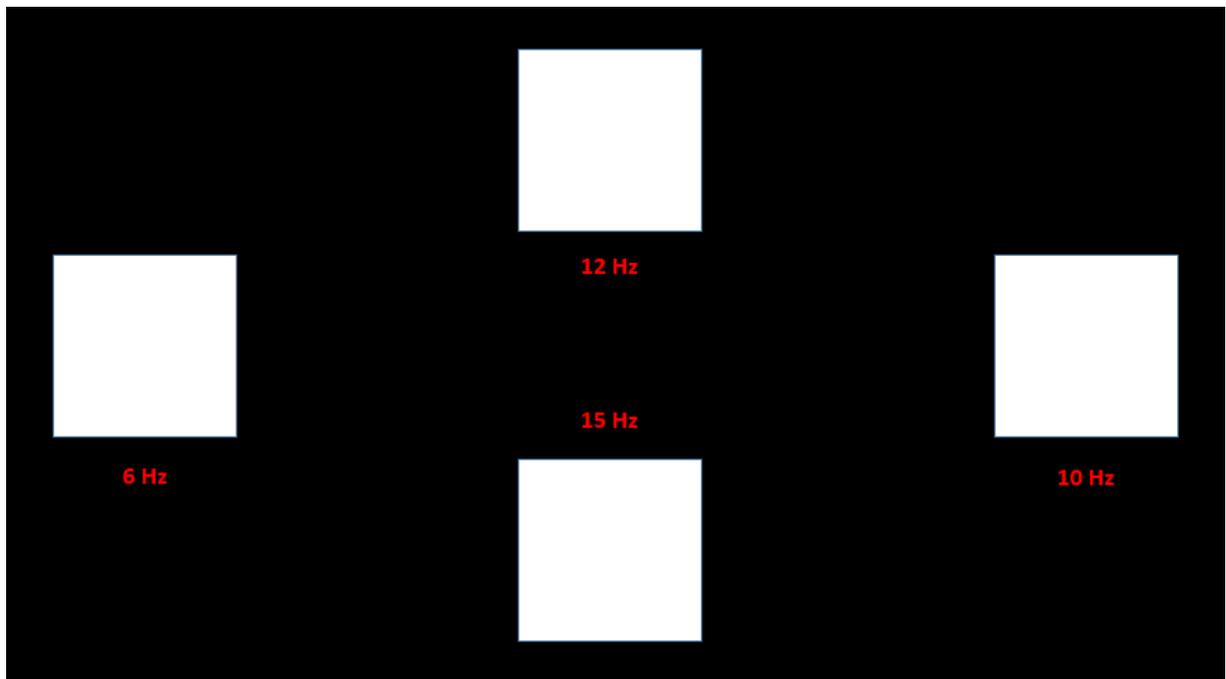
Figura 2 – Disposição dos 16 eletrodos sobre o couro cabeludo seguindo o padrão internacional de posicionamento 10-10.



Em relação ao processo de estimulação visual durante a coleta, os voluntários sentaram-se confortavelmente em frente a uma tela de LCD de 15 polegadas, a uma distância aproximada de 0,5 m. O processo de coleta se baseou nas técnicas de potencial evocado visual, e os estímulos visuais consistiram em quatro quadrados cintilantes nas frequências 6, 10, 12 e 15 Hz entre o branco e o preto, conforme ilustra a Figura 3. Durante 12 segundos, o voluntário deveria se concentrar apenas no estímulo indicado. Este procedimento foi repetido oito vezes para cada frequência, e os dados foram coletados a uma taxa de 256 Hz.

É importante salientar que na tela de estímulo, as frequências de cada quadrado não foram indicadas. Com isso, o voluntário recebia comandos orais, tais como esquerda/direita, para cima/baixo, para concentração em determinado estímulo.

Figura 3 – Tela de estimulação visual utilizada no processo de coleta de dados.



## 2.2 Processamento do Sinal

Em relação ao processamento de dados, cada sinal coletado foi filtrado analogicamente com o auxílio de um filtro *notch* em 60 Hz, para a atenuação de ruído da rede elétrica brasileira (CORREIA et al., 2010) e por um filtro passa-faixas do tipo Butterworth, na faixa de 5 a 60 Hz, e foi devidamente amplificado, tendo em vista que tais tipos de sinais são da ordem de microvolts. Tais operações foram realizadas internamente pelo equipamento de coleta gUSBamp a fim de minimizar a ação de outros potenciais elétricos provenientes de fontes externas ao cérebro (artefatos) (MARKAND, 1996).

Os dados foram digitalizados e armazenados utilizando o software MATLAB®. Ao fim da coleta, os sinais foram devidamente nomeados de acordo com a frequência de estímulo e número da sessão, “*Trial*”, para em etapas sucessivas, serem submetidos ao processamento digital.

## 2.3 Pré-Processamento Digital

O processo de coleta de sinais cerebrais é susceptível à interferência de fontes externas, como movimentos provenientes de piscamento e deglutição que são capazes de interferir na qualidade do sinal coletado. Tendo em vista esta grande presença de artefatos em sinais de EEG, além do filtro analógico, é necessário também aplicar técnicas digitais de filtragem. Neste trabalho, operou-se com uma técnica clássica de filtragem espacial denominada CAR.

O filtro CAR consiste na subtração de cada sinal da média de todos os sinais coletados (GARCIA-MOLINA; ZHU, 2011). Matematicamente, a equação base para este filtro pode ser escrita como:

$$V_i^{CAR} = V_i^{eletrodo} - \frac{1}{n} \sum_{j=1}^n V_j^{eletrodo} \quad (2.1)$$

onde  $n$  é o número de eletrodos (canais) utilizados no momento da coleta dos dados, que neste caso corresponde a 16 canais;  $V_i^{eletrodo}$  é o potencial medido no eletrodo de número  $i$ ; e  $V_i^{CAR}$  é o potencial do eletrodo  $i$  após a aplicação da filtragem espacial CAR.

Para fins de ilustração da atuação deste método de filtragem, selecionou-se aleatoriamente o eletrodo Oz com estímulo em 6 Hz. As Figuras 4 e 5 indicam uma representação temporal e espectral do sinal antes e depois da filtragem CAR, no domínio do tempo e da frequência, respectivamente.

Figura 4 – Representação temporal comparativa entre o sinal proveniente do eletrodo Oz com estímulo em 6 Hz, antes e depois da filtragem CAR.

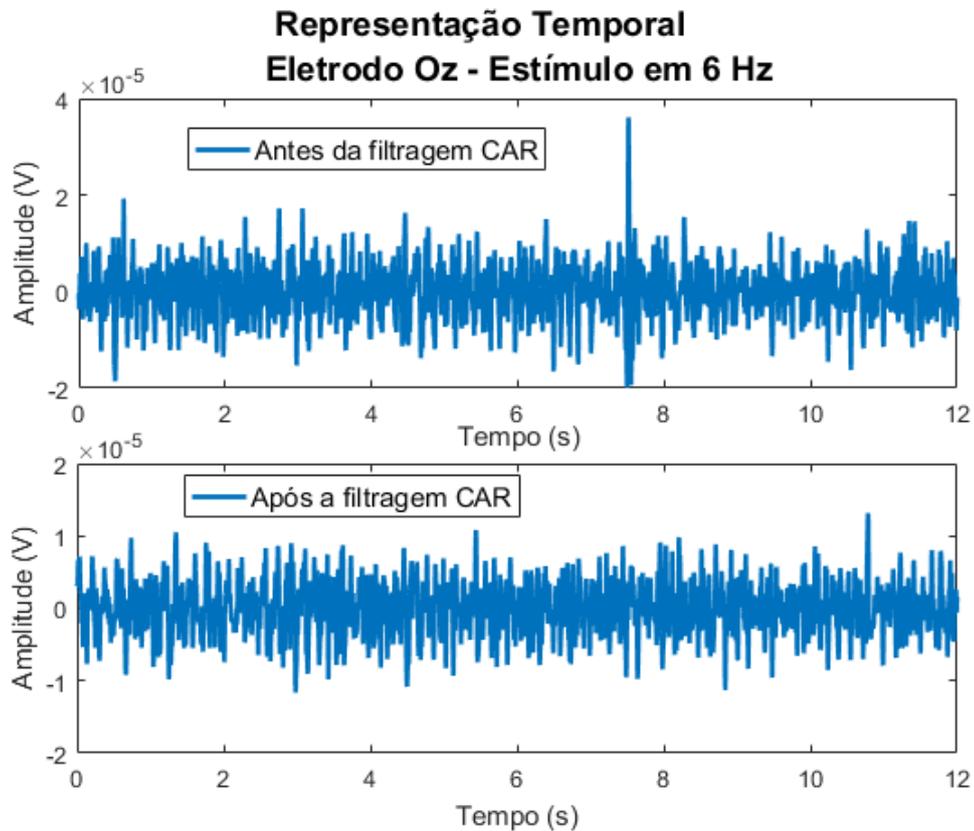
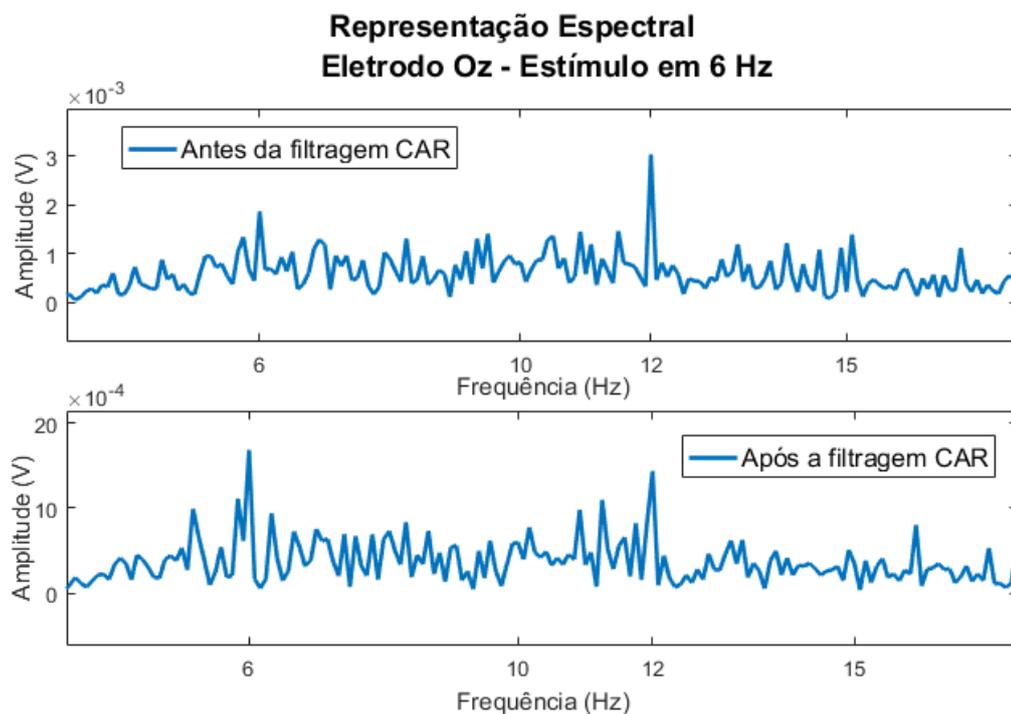


Figura 5 – Representação espectral comparativa entre o sinal proveniente do eletrodo Oz com estímulo em 6 Hz, antes e depois da filtragem CAR.



Analisando a Figura 4, pode-se perceber uma atenuação de certos picos do sinal com a filtragem, sem que houvesse perda da dinâmica do sinal. Além disso, a partir da Figura 5, conclui-se que apesar da atenuação em amplitude do sinal após a aplicação do CAR na frequência de estimulação e suas harmônicas, é possível identificar grande atenuação nas demais frequências, evidenciando a utilidade da técnica de filtragem na melhoria da SNR.

Após o processo de filtragem, o conjunto de dados foi submetido à segmentação. Nesta etapa, cada coleta de 12 segundos foi segmentada em janelas retangulares de 4 e 6 segundos, com a principal finalidade de ajuste de tempo de execução do sistema na aplicação em tempo real.

## 2.4 Extração de Atributos

De acordo com Bishop (1995), os atributos podem ser classificados como elementos de uma representação de dados eficiente e compacta. No contexto de uma BCI, é de suma importância que os atributos extraídos dos sinais cerebrais facilitem a discriminação da tarefa a ser processada na etapa de classificação.

Com os sinais devidamente pré-processados, a etapa subsequente correspondeu a extração de atributos ou características. Nesta etapa, foi possível realizar a extração dos atributos, bem como o agrupamento destas informações na forma de uma matriz de atributos, necessários para identificação de qual frequência o indivíduo está sendo estimulado, dentre as frequências de 6, 10, 12 e 15 Hz. Neste contexto, as técnicas adotadas para realizar esta extração corresponderam ao método de Welch (WELCH, 1967) e a Transformada de Fourier de Tempo Curto (HAYKIN, 2008).

### 2.4.1 Método de Welch

Este método utiliza a Transformada de Fourier Rápida (FFT, do inglês *Fast Fourier Transform*) para realizar a estimação da densidade espectral de potência do sinal. Para isso, primeiramente o sinal é dividido em segmentos menores que o sinal original, dos quais são computados periodogramas modificados seguido do cálculo de suas médias, sendo muito útil na redução do tempo computacional.

Em termos matemáticos, considera-se que o sinal coletado seja composto por um número de  $N$  amostras,  $X(j)$ , com  $j$  variando de 0 a  $N - 1$ . Deste sinal, toma-se segmentos de tamanho  $L$ , com ou sem sobreposição, com pontos iniciais dos segmentos dados por  $D$ . Sendo  $K$  o número total de segmentos adotados, a representação matemática de cada segmento pode ser escrita como:

$$X_1(j) = X(j) \quad j = 0, \dots, L - 1. \quad (2.2)$$

$$X_K(j) = X(j + (K - 1)D) \quad j = 0, \dots, L - 1. \quad (2.3)$$

Cada segmento de tamanho  $L$  é multiplicado por uma janela de dados  $W(j)$ , com  $j = 0, \dots, L - 1$ , formando uma sequência tal que:

$$X_1(j)W(j), \dots, X_K(j)W(j) \quad (2.4)$$

Subsequentemente, obtém-se o periodograma modificado de cada segmento. Para isso, calcula-se a Transformada de Fourier desta sequência, obtendo uma nova sequência  $A_1(n), \dots, A_k(n)$ , onde o  $K$ -ésimo termo é escrito como:

$$A_k(n) = \frac{1}{L} \sum_{j=0}^{L-1} X_k(j)W(j)e^{-2ikjn/L} \quad (2.5)$$

sendo  $i = (-1)^{1/2}$ . O períodograma do  $K$ -ésimo segmento será dado por:

$$I_k(f_n) = \frac{L}{U} |A_k(n)|^2 \quad k = 1, 2, \dots, K \quad (2.6)$$

com:

$$f_n = \frac{n}{L} \quad n = 0, \dots, L/2 \quad (2.7)$$

e

$$U = \frac{1}{L} \sum_{j=0}^{L-1} W^2(j) \quad (2.8)$$

Finalmente, toma-se a média dos períodogramas, obtendo assim a densidade espectral de potência na forma:

$$P(f_n) = \frac{1}{K} \sum_{k=1}^K I_k(f_n) \quad (2.9)$$

Com o auxílio do *software* MATLAB, estimou-se a densidade espectral de potência da base de dados de usando a função *pwelch*. Os seguintes parâmetros foram passados para a função: *pwelch(X;WINDOW;NOVERLAP;F;Fs)*, sendo:

- $X$ : sinal a ser estimado;
- $WINDOW$ : tamanho da janela a ser utilizada em número de pontos. Neste caso, como o sinal analisado possui 3072 pontos (12 s x 256 Hz), o parâmetro  $WINDOW$  foi configurado com 1024 (4 s) e 1536 (6 s) pontos;

- *NOVERLAP*: parâmetro relacionado à sobreposição de janelas. Optou-se por não utilizar sobreposição, devido a dinâmica de operação do sistema em regime on-line, atribuindo o valor 0 para este parâmetro;
- *F*: corresponde a um vetor contendo as frequências evocadas das quais se deseja obter a densidade espectral de potência. Neste caso, selecionou-se um intervalo de frequências próximas das frequências evocadas, com um passo de 0,01 Hz;
- *F<sub>s</sub>*: parâmetro que corresponde à frequência de amostragem da coleta de dados, ou seja,  $F_s = 256 \text{ Hz}$ .

### 2.4.2 Método da STFT

A Transformada de Fourier de Tempo Curto permite a estimação da potência espectral por meio do cálculo da Transformada de Fourier em determinados segmentos do sinal, geralmente utilizando sobreposição, a fim de reduzir a atuação de artefatos nas fronteiras dos segmentos.

Os valores complexos obtidos da transformada fornecem informações relacionadas à magnitude e fase de cada ponto no tempo e também na frequência (HAYKIN, 2008). Matematicamente, a STFT pode ser dada por:

$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (2.10)$$

onde  $x[n]$  é o sinal analisado,  $w[n]$  é a janela utilizada,  $m$  o tamanho do segmento e  $\omega$  a frequência angular.

Tomando a magnitude ao quadrado de  $X(m, \omega)$ , se obtém o espectrograma, fornecendo uma estimativa da potência espectral do sinal, ou seja:

$$\text{espectrograma} \equiv |X(m, \omega)|^2 \quad (2.11)$$

No contexto desta monografia, o espectrograma foi calculado em torno das frequências evocadas (6, 10, 12 e 15 Hz), utilizando segmentos de 4 e 6 segundos sem sobreposição.

## 2.5 Seleção de Atributos

A seleção de atributos é uma técnica muito útil quando a dimensão da matriz de atributos é alta. Por meio da seleção, este número pode ser reduzido sem perda de generalização do sistema, melhorando o desempenho do classificador (THEODORIDIS; KOUTROUMBAS, 2009).

Preliminarmente, os métodos de seleção de atributos são aplicados principalmente na escolha de atributos informativos e relevantes para o classificador. Além disso, segundo Guyon et al. (2008), a seleção possui como motivação:

1. **Redução do número de dados:** limitação de requisitos de armazenamento e aumento da velocidade do algoritmo;
2. **Redução do conjunto de atributos:** economia de recursos na próxima rodada de coleta de dados ou durante a utilização;
3. **Melhorias de performance:** ganho em acurácia preditiva;
4. **Entendimento dos dados:** ganho em conhecimento do processo gerador de dados ou simplesmente visualização dos dados.

Existem diversas técnicas de seleção de atributos. O método de *wrappers* utiliza a máquina de aprendizado como uma caixa preta para marcar subconjuntos de atributos de acordo com seus poderes preditivos. Além do método de *wrappers*, uma grande gama de métodos estatísticos podem ser utilizados, tais como o Teste-T, Teste-F e Qui-Quadrado. Também existem métodos baseados em filtros, que são altamente utilizados, sendo também identificados como métodos de ranqueamento. Filtros promovem um ranqueamento dos atributos de acordo com índices de relevância (GUYON et al., 2008). Uma técnica de filtros eficiente e bastante empregada é o método de Correlação de Pearson, sendo a técnica adotada neste trabalho.

Os métodos baseados em coeficientes de correlação são considerados simples e eficientes para a medição de relevância de atributos (GUYON et al., 2008). Em termos matemáticos, considerando um conjunto de  $m$  amostras  $\{x_k, y_k\}$  ( $k = 1, \dots, m$ ) consistindo de  $n$  variáveis de entrada  $x_{k,i}$  ( $i = 1, \dots, n$ ) e uma variável de saída  $y_k$ , se o vetor de entrada  $x$  puder ser interpretado como um modelo de um vetor aleatório retirado de uma distribuição subjacente desconhecida, denota-se por  $X_i$  a variável aleatória correspondente a  $i$ -ésima componente de  $x$ . Similarmente,  $Y$  é a variável aleatória cuja saída  $y$  é um modelo. Além disso,  $x_i$  é o vetor  $m$  dimensional contendo todos os modelos da  $i$ -ésima variável para os exemplos de treinamento, e  $y$ , o vetor  $m$  dimensional contendo todos os valores alvo.

Considerando agora a predição de um resultado contínuo  $y$ , os coeficientes de correlação de Pearson podem ser definidos como:

$$\mathcal{R}(i) = \frac{\text{cov}(X_i, Y)}{\sqrt{\text{var}(X_i)\text{var}(Y)}} \quad (2.12)$$

onde *cov* e *var* representam covariância e variância, respectivamente.

Expandindo a expressão 2.12:

$$R(i) = \frac{\sum_{k=1}^m (x_{k,i} - \bar{x}_i)(y_k - \bar{y})}{\sqrt{\sum_{k=1}^m (x_{k,i} - \bar{x}_i)^2 \sum_{k=1}^m (y_k - \bar{y})^2}} \quad (2.13)$$

onde a notação barra significa valor médio tomado no índice  $k$ .

Esta estratégia calcula primeiramente  $R(i)$  para  $i = 1, \dots, m$ , onde  $m$  é também denominado de número de atributos e, subseqüentemente, ranqueia os  $K$  atributos utilizando o critério dos máximos valores de  $R(i)$ . Como a correlação define um momento estatístico de segunda ordem, os coeficientes de Pearson são capazes de avaliar somente a dependência linear entre os atributos. Entretanto, devido a sua simplicidade computacional, este método pode ser adequadamente utilizado no entendimento do conjunto de dados espaciais (GUYON; ELISSEEFF, 2003).

## 2.6 Classificador Linear

De modo geral, um classificador pode ser caracterizado por sua capacidade de categorizar variáveis envolvidas no processo de classificação. No caso deste trabalho, o classificador torna-se muito útil na distinção das frequências evocadas de acordo com as características obtidas na etapa de extração de atributos (THEODORIDIS; KOUTROUMBAS, 2009).

Dentre as variantes disponíveis para a implementação do classificador linear, escolheu-se o Método dos Mínimos Quadrados. O método tem como objetivo minimizar o erro quadrático médio de acordo com os valores desejados e os valores obtidos na saída do classificador. A função custo pode ser escrita como:

$$J(w) = \sum_{i=1}^N (y_i - x_i^T w)^2 \equiv \sum_{i=1}^N e_i^2 \quad (2.14)$$

a minimização desta expressão, leva a:

$$\sum_{i=1}^N x_i (y_i - x_i^T \hat{w}) = 0 \Rightarrow \left( \sum_{i=1}^N x_i x_i^T \right) \hat{w} = \sum_{i=1}^N (x_i y_i) \quad (2.15)$$

Agora, seja  $X$  uma matriz denominada de matriz de atributos com dimensão  $N \times l$ , e  $y$  o vetor de respostas desejadas, também conhecido como vetor de rótulos, a equação 2.15 pode ser reescrita como:

$$(X^T X) \hat{w} = X^T y \Rightarrow \hat{w} = (X^T X)^{-1} X^T y \quad (2.16)$$

A parcela  $(X^T X)^{-1} X^T$  é denominada de pseudoinversa de  $X$ .

A saída do classificador linear é dada por:

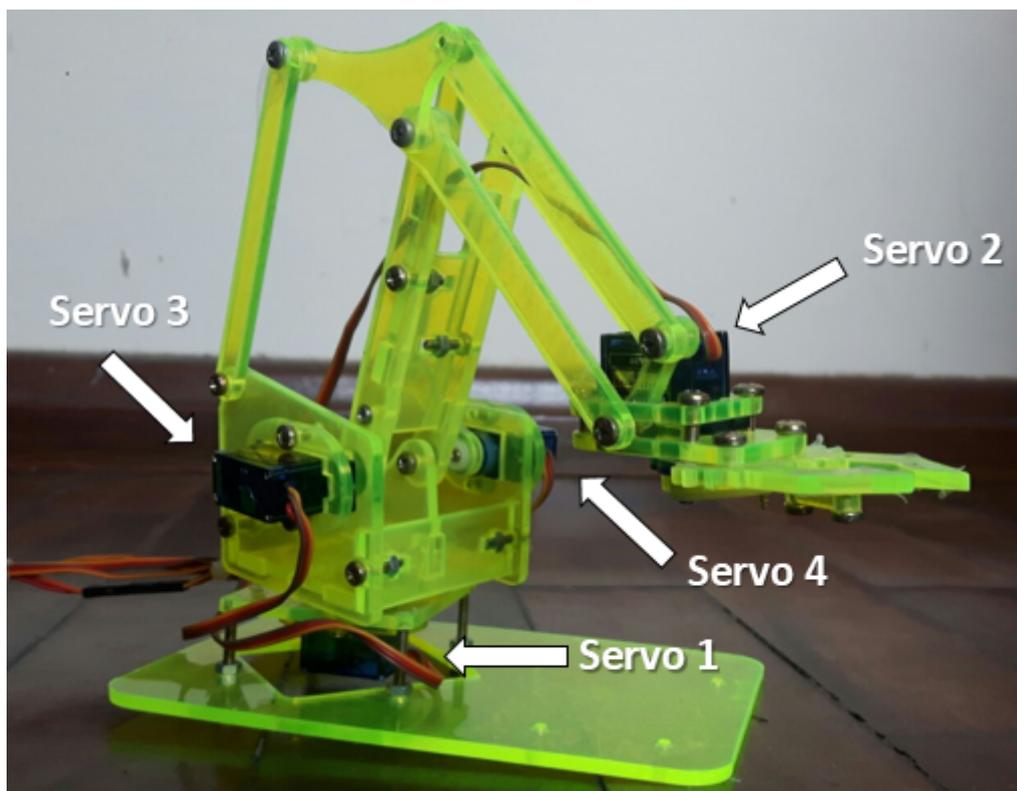
$$Y = w^T X \quad (2.17)$$

No processo de treinamento, selecionou-se aleatoriamente 80% das entradas da matriz  $X$ , enquanto para a validação, os 20% restantes. Assim, para o treinamento, resolveu-se a Equação 2.16 e ao resultado do processo citado,  $w^T$ , multiplicou-se a matriz de validação, resolvendo a equação 2.17 e, conseqüentemente, computando o percentual total de acerto do sistema BCI implementado. Para obter um resultado mais factível, o processo de validação foi realizado 100 vezes com diferentes partições.

## 2.7 Aplicação: Braço Robótico

O primeiro passo para a integração do sistema BCI desenvolvido com uma aplicação externa foi justamente a escolha do dispositivo a ser empregado. Neste trabalho, optou-se por um braço robótico de acrílico, articulado com quatro servo motores, conforme ilustra a Figura 6. Em termos de comunicação entre braço robótico e o sistema BCI, utilizou-se a *toolbox* MATLAB® *Support Package for Arduino*®, possibilitando o processo de configuração, bem como leitura/escrita da placa. Foi empregada a comunicação serial entre o sistema e o braço robótico para enviar os comandos oriundos da saída do classificador para o sistema de controle da aplicação que acionava os motores de comando em questão.

Figura 6 – Braço robótico articulado.



A cada servo motor, os seguintes comandos estão relacionados:

- **Servo 1:** Movimentos de  $\pm 90$  graus de acordo com o ponto de partida inicial;
- **Servo 2:** Movimentos de abertura e fechamento da garra;
- **Servo 3:** Movimentos de elevação e descida do braço articulado;
- **Servo 4:** Movimentos de avanço e recuo do braço articulado.

Inicialmente, os servos 1, 2 e 3 foram ajustados na angulação de 90 graus cada, de modo que o braço ficasse disposto em uma posição central em relação à base de apoio, com média elevação e garra semi-aberta.

Cada estímulo visual (6, 10, 12 e 15 Hz) foi associado a uma tarefa a ser realizada pelo braço robótico, sendo:

- **6 Hz:** rotação de 90 graus no sentido horário, ativando apenas o servo motor da base do robô - comando 1;
- **10 Hz:** rotação de 90 graus no sentido anti-horário, ativando apenas o servo motor da base do robô - comando 2;
- **12 Hz:** fechamento da garra e movimento de subida do braço, ativando os servos motores da garra e elevação/descida do braço - comando 3.
- **15 Hz:** abertura da garra e movimento de descida do braço, ativando os servos motores da garra e elevação/descida do braço - comando 4;

Apesar de existirem quatro servo motores disponíveis, apenas três deles foram utilizados, devido às possibilidades de movimentos encontrados relacionadas com o número de estímulos disponíveis no experimento.

### 2.7.1 Controle On-line

Após a configuração dos movimentos a serem realizados pelo braço robótico vinculados as frequências de estímulo, o próximo passo esteve relacionado com a validação do sistema por meio de experimentos em tempo real. As mesmas técnicas de coleta de dados mencionadas na Seção 2.1 foram utilizadas, adotando conseqüentemente, o mesmo padrão de posicionamento de eletrodos sobre o couro cabeludo do indivíduo.

Nas etapas preliminares de treinamento do sistema, o sistema foi treinado utilizando 8 sessões de 12 segundos cada, para as 4 frequências de estimulação. O código foi ajustado de maneira a processar 4 e 6 segundos do sinal, utilizando técnicas de pré-processamento como filtro CAR, extração de atributos pelo método STFT, seleção de atributos pelo método da Correlação de Pearson e o classificador linear. Após a resposta do classificador, os

comandos identificados foram transferidos para o braço robótico por meio da comunicação serial, sendo possível realizar a movimentação de um cubo composto de espuma, de acordo com as opções de movimento disponíveis.

Para a validação do sistema implementado, optou-se pela tarefa de pegar o cubo na altura do solo de acordo com a posição inicial pré-estabelecida, transferindo-o no sentido horário ou anti-horário, depositando-o novamente ao nível do solo. A Tabela 1 indica a utilização dos servo-motores e comandos de acordo com a frequência identificada pela classificador.

Tabela 1 – Relação de frequências de estimulação, comandos executados e servo-motores utilizados.

<b>Frequência</b>	<b>Comando</b>	<b>Servo 1</b>	<b>Servo 2</b>	<b>Servo 3</b>	<b>Servo 4</b>
6 Hz	1	X	-	-	-
10 Hz	2	X	-	-	-
12 Hz	3	-	X	X	-
15 Hz	4	-	X	X	-

Minimamente, para a execução da tarefa completa, são necessários 4 comandos: comandos 4, 3, 1 ou 2, e 4. O tempo total de execução depende do tamanho das janelas utilizadas pelo sistema.

## 3 Resultados e Discussão

### 3.1 Testes off-line

Após a implementação das etapas de pré-processamento, extração de atributos, seleção de atributos e classificação linear referentes ao sistema BCI, foi possível realizar testes considerando diversos cenários. O principal objetivo destes testes foi comparar o desempenho do sistema BCI em relação ao percentual de acerto médio final do sistema para a posterior escolha dos melhores parâmetros a serem utilizados no sistema on-line. Os cenários corresponderam às bases de dados coletadas de 4 indivíduos. Todas as coletas de dados realizadas seguiram os mesmos padrões indicados na seção 2.1 desta monografia.

Como parâmetro variante, duas técnicas de extração de atributos foram analisadas: Métodos de Welch e STFT. Além disso, foram consideradas janelas de 4 e 6 segundos. As Figuras 7 e 8 indicam os resultados obtidos para os 4 indivíduos, para janelas de 4 e 6 segundos, respectivamente.

Figura 7 – Percentual de acerto do sistema BCI utilizando janelas de 4 segundos.

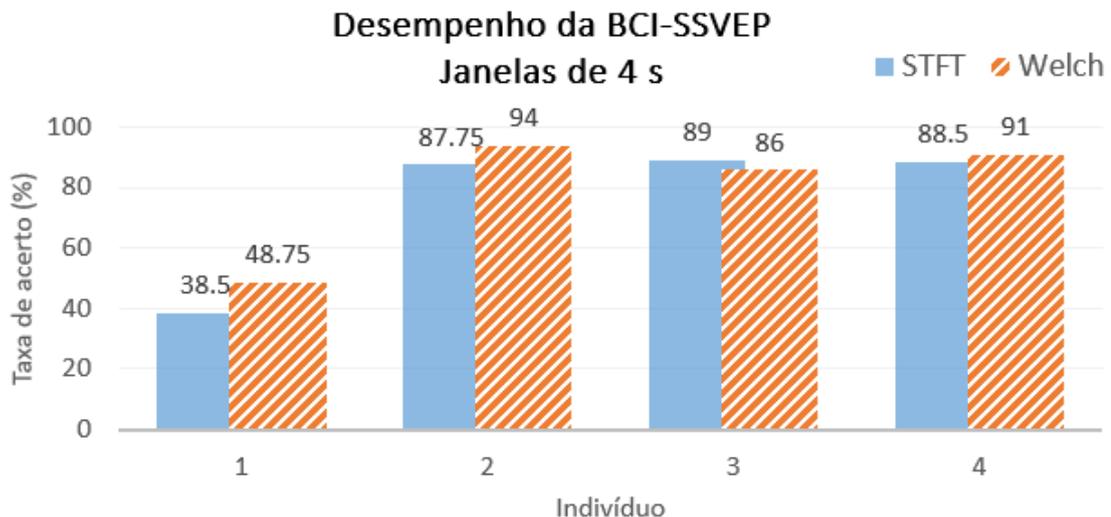
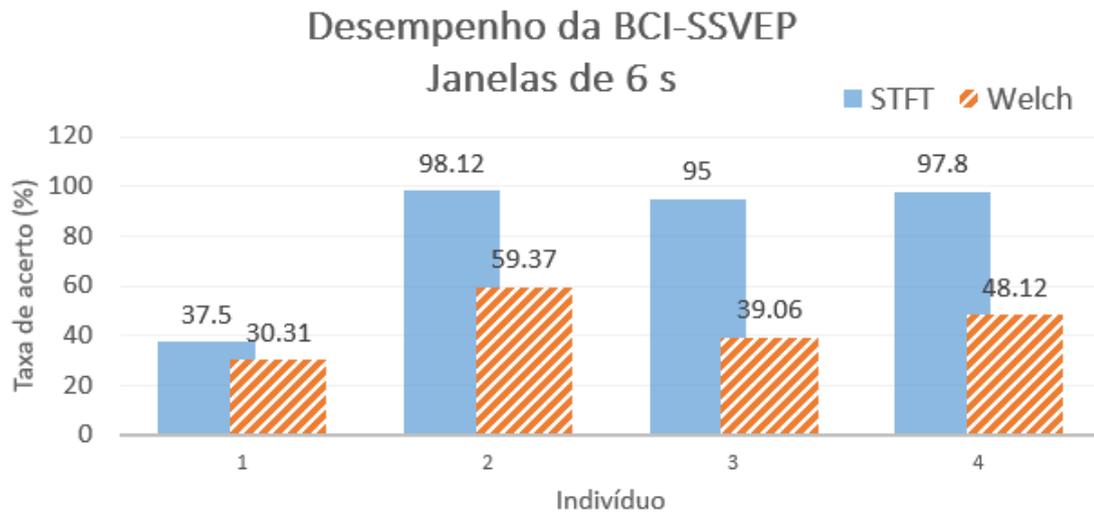


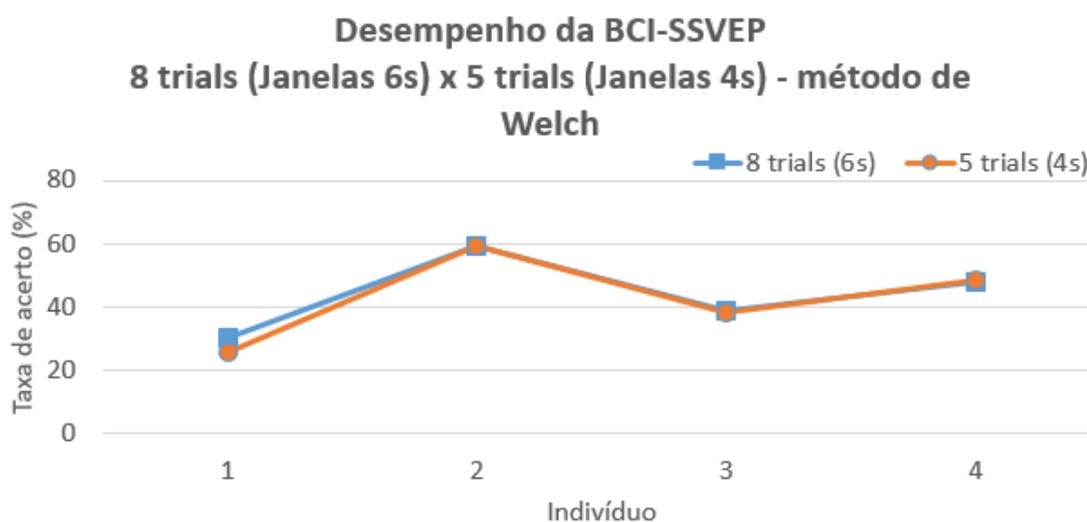
Figura 8 – Percentual de acerto do sistema BCI utilizando janelas de 6 segundos.



Analisando a Figura 7 é possível concluir que o método de Welch foi ligeiramente superior que o método da STFT para janelas de 4 segundos, exceto para o indivíduo 3. Entretanto, de acordo com a Figura 8, uma discrepância de resultados pode ser observada entre os dois métodos. Em alguns casos, o percentual de acerto do sistema utilizando o método de Welch se mostrou inferior à metade do valor obtido com o método da STFT. Explicações plausíveis sustentam tal discrepância: a primeira está relacionada com a quantidade de dados disponíveis para treinamento e validação do sistema. Com janelas de 4 segundos, o sistema possui 96 entradas, onde 70 delas são destinadas ao treinamento e 26 para a validação. No caso de janelas de 6 segundos, 64 entradas estão disponíveis, 50 para treinamento e 14 para validação. Esta diferença de material para treinamento do sistema foi um fator determinante para a redução drástica do percentual de acerto da BCI no cenário com janelas de 6 segundos. Outro fator relevante está associado com a avaliação de componentes harmônicas pelo método da STFT. Neste método, além das frequências fundamentais de estimulação, foram também contabilizadas as frequências correspondentes a 1ª harmônica evidenciando um aumento do percentual de acerto do sistema.

Para evidenciar as explicações utilizadas, um novo teste foi analisado. Para isso, a quantidade de dados disponível para o cenário com janelas de 4 segundos foi reduzida, de modo que a quantidade disponível fosse mais próxima a quantidade disponível no cenário com janelas de 6 segundos. Neste caso, apenas 5 *trials* foram utilizadas, descartando-se as 3 últimas, totalizando 60 entradas para o sistema, 12 para validação e 48 para treinamento. De acordo com a Figura 9, os resultados obtidos foram bem próximos, reforçando a explicação associada a quantidade de material para treinamento do sistema utilizada.

Figura 9 – Percentual de acerto do sistema considerando a disponibilidade 64 e 60 janelas para cenários de 6 e 4 segundos, respectivamente .



Ainda analisando a performance do sistema BCI, além do percentual de acerto médio do sistema, os percentuais de acerto e erro foram discriminados para cada frequência de estimulação. Deste modo, é possível analisar para qual frequência o erro do classificador foi destinado. As Tabelas 2 a 9 indicam os resultados percentuais para os quatro indivíduos.

Tabela 2 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 1 com janelas de 4 segundos.

Desempenho do classificador								
<i>STFT</i>	<u>Welch</u>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6	10	12	15	6	10	12	15
6	<b>40,00</b>	<b>39,00</b>	32,00	18,00	16,00	33,00	12,00	10,00
10	33,00	22,00	<b>37,00</b>	<b>55,00</b>	23,00	16,00	7,00	7,00
12	26,00	30,00	19,00	12,00	<b>39,00</b>	<b>51,00</b>	16,00	7,00
15	33,00	31,00	13,00	6,00	16,00	13,00	<b>38,00</b>	<b>50,00</b>

Tabela 3 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 1 com janelas de 6 segundos.

Desempenho do classificador								
<i>STFT</i>	<u>Welch</u>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>22,50</b>	<b>36,25</b>	26,25	6,25	27,50	37,50	23,75	20,00
10	35,00	22,50	<b>45,00</b>	<b>11,25</b>	8,75	35,00	11,25	31,25
12	35,00	31,25	20,00	8,75	<b>23,75</b>	<b>40,00</b>	21,25	20,00
15	23,75	30,00	10,00	3,75	7,5	32,50	<b>58,75</b>	<b>33,75</b>

Tabela 4 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 2 com janelas de 4 segundos.

Desempenho do classificador								
<i>STFT</i>	<u>Welch</u>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>86,00</b>	<b>94,00</b>	4,00	0,00	7,00	6,00	3,00	0,00
10	2,00	5,00	<b>92,00</b>	<b>93,00</b>	1,00	2,00	5,00	0,00
12	13,00	11,00	0,00	0,00	<b>81,00</b>	<b>89,00</b>	6,00	0,00
15	2,00	0,00	3,00	0,00	3,00	0,00	<b>92,00</b>	<b>100</b>

Tabela 5 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 2 com janelas de 6 segundos.

Desempenho do classificador								
<i>STFT</i>	<u>Welch</u>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>93,75</b>	<b>58,75</b>	0,00	2,50	6,25	26,25	0,00	12,50
10	0,00	22,50	<b>100</b>	<b>65,00</b>	0,00	7,50	0,00	5,00
12	0,00	35,00	0,00	5,00	<b>100</b>	<b>53,75</b>	0,00	6,25
15	1,25	20,00	0,00	6,25	0,00	13,75	<b>98,75</b>	<b>60,00</b>

Tabela 6 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 3 com janelas de 4 segundos.

Desempenho do classificador								
<i>STFT</i>	<i>Welch</i>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>79,00</b>	<b>87,00</b>	1,00	4,00	0,00	1,00	20,00	8,00
10	1,00	1,00	<b>93,00</b>	<b>93,00</b>	2,00	0,00	4,00	6,00
12	0,00	5,00	0,00	0,00	<b>98,00</b>	<b>87,00</b>	2,00	8,00
15	6,00	20,00	1,00	3,00	7,00	0,00	<b>86,00</b>	<b>77,00</b>

Tabela 7 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 3 com janelas de 6 segundos.

Desempenho do classificador								
<i>STFT</i>	<i>Welch</i>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>95,00</b>	<b>32,50</b>	0,00	26,25	0,00	2,50	5,00	38,75
10	0,00	23,75	<b>100</b>	<b>53,75</b>	0,00	1,25	0,00	31,25
12	0,00	18,75	0,00	33,75	<b>100</b>	<b>21,25</b>	0,00	26,25
15	13,75	21,25	0,00	27,50	1,25	2,50	<b>85,00</b>	<b>48,75</b>

Tabela 8 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 4 com janelas de 4 segundos.

Desempenho do classificador								
<i>STFT</i>	<i>Welch</i>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6		10		12		15	
6	<b>85,00</b>	<b>80,00</b>	3,00	1,00	7,00	0,00	5,00	19,00
10	4,00	4,00	<b>95,00</b>	<b>94,00</b>	0,00	0,00	1,00	2,00
12	9,00	1,00	0,00	0,00	<b>89,00</b>	<b>98,00</b>	2,00	1,00
15	8,00	8,00	5,00	0,00	2,00	0,00	<b>85,00</b>	<b>92,00</b>

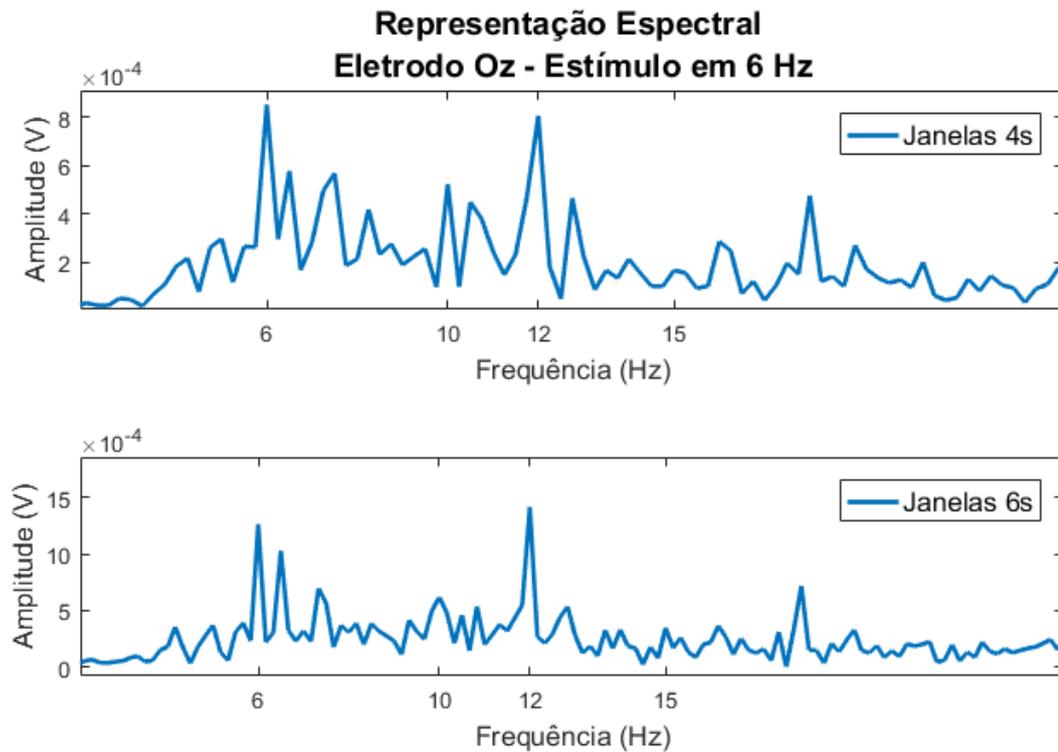
Tabela 9 – Taxas de erros e acertos do sistema BCI analisando o conjunto de dados do indivíduo 4 com janelas de 6 segundos.

Desempenho do classificador								
<i>STFT</i>	<u>Welch</u>	Resposta do classificador (Hz)						
Resposta esperada (Hz)	6	10	12	15	6	10	12	15
6	<b>97,50</b>	<b>42,50</b>	0,00	13,75	0,00	0,00	2,50	43,75
10	5,00	30,00	<b>95,00</b>	<b>50,00</b>	0,00	0,00	0,00	20,00
12	0,00	31,25	0,00	13,75	<b>100</b>	<b>37,50</b>	0,00	17,50
15	0,00	25,00	1,25	12,50	0,00	0,00	<b>98,75</b>	<b>62,50</b>

De acordo com os resultados apresentados, as taxas de acerto para a base de dados do indivíduo 1 foram relativamente baixas se comparada aos demais indivíduos. Este fato pode ser explicado por meio das diferenças neurofisiológicas de cada indivíduo e provavelmente, a resposta ao potencial evocado não estava bem clara no sinal deste indivíduo. Isso evidencializa a necessidade da utilização de técnicas de processamento de sinais mais específicas como forma de proporcionar maior ganho em acurácia preditiva do sistema e, conseqüentemente, melhorar sua performance.

Analisando os resultados dos testes off-line foi possível escolher os parâmetros e técnicas a serem utilizadas nas etapas do sistema on-line. Sendo assim, optou-se por utilizar janelas de 6 segundos juntamente com a técnica da STFT para a extração de atributos. Além dos resultados apresentados, que sustentam tal escolha, outro fator foi extremamente importante para que estes parâmetros fossem selecionados. Em janelas de 6 segundos, as respostas espectrais das frequências de estimulação utilizadas se tornam mais evidentes se comparadas às janelas de 4 segundos. Tal fator é determinante para o aumento do percentual de acerto do sistema. Analisando a Figura 10, é possível identificar que a magnitude do sinal em 6 Hz é maior para janelas de 6 segundos.

Figura 10 – Representação espectral comparativa entre o sinal proveniente do eletrodo Oz para o indivíduo 3 com estímulo em 6 Hz para janelas de 4 e 6 segundos.



## 3.2 Testes on-line

Após a determinação dos parâmetros e técnicas a serem utilizados pelo sistema, foi possível realizar testes on-line, integrando a BCI com o braço robótico. Primeiramente, determinou-se a tarefa a ser realizada pelo voluntário. Para isso, de acordo com ações programadas a serem realizadas pelo dispositivo, um cubo de isopor deveria ser movido para a esquerda ou direita e, em seguida, depositado ao nível do solo, totalizando 4 movimentos, partindo de sua posição inicial descrita na seção 2.7.

Preliminarmente à tarefa, o sistema foi submetido ao processo de treinamento, onde a coleta de dados foi realizada conforme indicado na seção 2.1. Subsequentemente, os parâmetros obtidos nos testes off-line foram ajustados e o voluntário recebeu a orientação para iniciar a atividade proposta. À medida que o classificador gerava a resposta e o braço robótico realizava a ação relacionada, o indivíduo era orientado oralmente a manter o foco visual na próxima frequência de interesse, pois o mesmo não possuía *feedback* visual do robô.

Tendo em vista que as janelas utilizadas foram de 6 segundos e desprezando tempos de processamento computacional, para a realização da tarefa completa, o sistema necessitaria de 24 segundos ou 4 comandos, considerando que nenhum erro ocorresse. No teste realizado, o indivíduo 3 foi responsável por deslocar o cubo à direita, sendo necessário

fixar o olhar nas seguintes frequências, em ordem: 15, 12, 10 e 15 Hz. A Tabela 10 indica os resultados obtidos.

Tabela 10 – Resposta do classificador de acordo com a frequência de estimulação focalizada para o indivíduo 3.

<b>Tempo (s)</b>	<b>Frequência focalizada (Hz)</b>	<b>Resposta classificador (Hz)</b>
6	15	15
12	12	15
18	12	15
24	12	15
30	12	12
36	10	10
42	15	15

Analisando a Tabela 10 é possível determinar que foram necessários cerca de 42 segundos para a realização da tarefa proposta. O sistema acertou 4 comandos dentre os 7 utilizados, confundindo o comando de 12 Hz pelo o de 15 Hz em 3 ocasiões consecutivas. Entretanto, de acordo com a Tabela 7, este resultado não era esperado, pois não houve nenhuma confusão de 12 Hz com 15 Hz no resultados off-line.

No segundo teste realizado, agora com o indivíduo 4, de acordo com a Tabela 9, esperava-se que o sistema confundisse 10 Hz com 6 Hz. Por esta razão, o comando relacionado à frequência de 6 Hz foi desconsiderado, estando disponíveis apenas os comandos de 10, 12 e 15 Hz. Com isso, apenas uma possibilidade de tarefa foi disposta. Os resultados são apresentados na Tabela 11.

Tabela 11 – Resposta do classificador de acordo com a frequência de estimulação focalizada para o indivíduo 4.

<b>Tempo (s)</b>	<b>Frequência focalizada (Hz)</b>	<b>Resposta classificador (Hz)</b>
6	15	15
12	12	15
18	12	12
24	10	12
30	10	15
36	10	12
42	10	12
48	10	15
54	10	12
60	10	12
66	10	15
72	10	12
78	10	12
84	10	15
90	10	12
96	10	10
102	12	12

De acordo com a Tabela 11, foram necessários cerca de 102 segundos para a realização da tarefa completa. Muitas confusões foram observadas, principalmente em relação as frequências 10 Hz com 15 Hz e 10 Hz com 12 Hz. Este resultado não era esperado da avaliação off-line, conforme mostra a Tabela 9. Possíveis causas desta redução na qualidade do desempenho do sistema podem ser levantadas, como o cansaço do indivíduo durante o processos de treinamento e teste e a falta de *feedback* visual para melhorar a compreensão e motivação do usuário.

## 4 Conclusão

O presente trabalho discute e implementa as principais etapas necessárias para o estabelecimento de um sistema BCI-SSVEP, desde a coleta de dados cerebrais até a integração do sistema com uma aplicação externa. São apresentados os conceitos relacionados aos sistemas BCI, em especial a abordagem baseada no método de Potencial Visualmente Evocado em Regime Permanente, na sequência é descrito o processo não-invasivo de aquisição de sinais por EEG e os procedimentos adotados na etapa de pré-processamento analógico da base de dados. Após a digitalização do sinal cerebral, foi empregado o filtro CAR, os métodos de extração de características espectrais (método de Welch e STFT), a técnica de seleção de atributos pelo filtro de correlação de Pearson e o classificador linear baseado no método dos mínimos quadrados, quegerou o comando destinado ao controle da aplicação.

Durante os testes off-line foi realizado um estudo comparativo entre as técnicas de extração de atributos, de forma a compreender qual fornecia um percentual de acerto médio maior para o sistema BCI. Os resultados mostraram que ambas as técnicas são eficientes, fornecendo um desempenho aceitável (acurácia superior a 80%) para o controle de uma aplicação real.

Nos testes on-line, optou-se por utilizar janelas de 6 segundos, adequada a dinâmica mecânica do manipulador robótico. Os atributos do sinal cerebral foram extraídos por meio da STFT e a etapa de seleção de atributos foi incluída, como uma forma de aumentar a capacidade preditiva do sistema. Apesar de o sistema BCI cometer alguns erros na etapa de identificação do comando desejado pelo voluntário, não apresentando acurácia de 100%, a integração com a aplicação sinalizou a possibilidade real de controle de sistemas por esta tecnologia emergente e avançou no sentido de desenvolvimento de aplicações assistivas, direcionadas a pacientes com algum tipo de deficiência física.

Em trabalhos futuros, almeja-se a inclusão de um *feedback* visual na tela de estimulação, de modo que o usuário seja capaz de visualizar os movimentos realizados pelo manipulador robótico. Este feedback deve melhorar a concentração e motivação do indivíduo durante o controle, aumentando a performance do sistema BCI.

# Referências

- BISHOP, C. M. *Neural networks for pattern recognition*. [S.l.]: Oxford university press, 1995. 11
- CENSO, I. Instituto brasileiro de geografia e estatística. *Fornecido em meio eletrônico:[www.ibge.gov.br/home/estatistica/populacao/censo2010/] Acessado em*, v. 20, n. 03, p. 2012, 2010. 1
- CORREIA, A. G. G. et al. Filtro notch para aplicações em eegs e eccs, com recurso a técnicas de f&h em cmos. 2010. 8
- FERGUSON, K. *Stephen Hawking: His life and work*. [S.l.]: Random House, 2011. 3
- GARCIA-MOLINA, G.; ZHU, D. Optimal Spatial Filtering for the Steady State Visual Evoked Potential : BCI application. In: *IEEE EMBS Conference on Neural Engineering*. [S.l.: s.n.], 2011. p. 156–160. ISBN 9781424441419. 9
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain–Computer Interfaces: A gentle introduction. In: *Brain-Computer Interfaces*. [S.l.]: Springer, 2010. p. 1–27. 1, 2, 3, 4
- GUGER, C. et al. How many people are able to operate an EEG-based brain-computer interface (BCI)? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 11, n. 2, p. 145–147, 2003. Disponível em: <<http://ieeexplore.ieee.org/xpls/abs/all.jsp?arnumber=1214>>. 4
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of machine learning research*, v. 3, n. Mar, p. 1157–1182, 2003. 15
- GUYON, I. et al. *Feature extraction: foundations and applications*. [S.l.]: Springer, 2008. v. 207. 14
- HAYKIN, S. S. *Adaptive filter theory*. [S.l.]: Pearson Education India, 2008. 11, 13
- HOLZ, E. M. et al. Long-term independent Brain-Computer Interface home use improves quality of life of a patient in the locked-in state: a case study. *Archives of physical medicine and rehabilitation*, Elsevier, v. 96, n. 3, p. S16–S26, 2015. 5
- JOHNSON, E. C. et al. Sequential selection of window length for improved SSVEP-based BCI classification. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*, v. 2013, p. 7060–7063, 2013. ISSN 1557170X. 5
- JURCAK, V.; TSUZUKI, D.; DAN, 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. 7
- KAMENETZ, F. et al. App processing and synaptic function. *Neuron*, Elsevier, v. 37, n. 6, p. 925–937, 2003. 2

- 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. 7
- MARKAND, O. Artifacts. In: *Annual meeting of American Academy of Neurology*. [S.l.: s.n.], 1996. v. 1, p. 363–396. 8
- MIDDENDORF, M. et al. Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE transactions on rehabilitation engineering*, IEEE, v. 8, n. 2, p. 211–214, 2000. 1
- MILLÁN, J. d. R.; CARMENA, J. Invasive or Noninvasive: understanding Brain-Machine Interface technology. *IEEE Engineering in Medicine and Biology Magazine*, Institute of Electrical and Electronics Engineers, v. 29, n. EPFL-ARTICLE-150426, p. 16–22, 2010. 2
- MÜLLER, S. M. T.; BASTOS, T. F.; FILHO, M. S. Proposal of a SSVEP-BCI to command a robotic wheelchair. *Journal of Control, Automation and Electrical Systems*, v. 24, n. 1-2, p. 97–105, 2013. ISSN 21953880. 1, 3, 4
- ORTNER, R. et al. An SSVEP BCI to control a hand orthosis for persons with tetraplegia. In: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*. [S.l.: s.n.], 2011. v. 19, n. 1, p. 1–5. 1, 4
- SANEI, S.; CHAMBERS, J. A. *EEG signal processing*. [S.l.]: John Wiley & Sons, 2013. 2, 4
- SAÚDE, O. M. da. *CIF: classificação internacional de funcionalidade, incapacidade e saúde*. [S.l.]: Editora da Universidade de São Paulo São Paulo, 2003. 1
- TAVARES, T. V. et al. Análise de técnicas de filtragem espacial em sistemas bcissvep. *Anais do Simpósio de Processamento de Sinais da Unicamp*, 2015. 5
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. [S.l.]: Elsevier, 2009. 13, 15
- 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. 11
- WOLPAW, J. R. et al. Brain-computer Interfaces for communication and control. *Clinical neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002. 1
- WU, Z.; SU, S. A dynamic selection method for reference electrode in SSVEP-based BCI. *PLoS ONE*, v. 9, n. 8, 2014. ISSN 19326203. 5, 7
- YIN, E. et al. A speedy hybrid bci spelling approach combining p300 and ssvep. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 61, n. 2, p. 473–483, 2014. 5