

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO

Andrei Damian da Silva

*Desenvolvimento de um dispositivo SSVEP rápido e confiável utilizando eletrodos a seco e
frequências acima de 25 Hz*

Goiânia

2018

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR
VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES
NA BIBLIOTECA DIGITAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: ☒ **Dissertação** ☐ **Tese**

2. Identificação da Tese ou Dissertação:


Nome completo do autor: **Andrei Damian da Silva**

Título do trabalho: **Desenvolvimento de um dispositivo SSVEP rápido e confiável utilizando eletrodos a seco e frequências acima de 25 Hz**

3. Informações de acesso ao documento:

Concorda com a liberação total do documento ☒ **SIM** ☐ **NÃO**¹

Havendo concordância com a disponibilização eletrônica, toma-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.


Assinatura do(a) autor(a)²

Ciente e de acordo.


Assinatura do(a) orientador(a)³

Data: 12 / 03 / 2018

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

² A assinatura deve ser escaneada.

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO

Andrei Damian da Silva

**Desenvolvimento de um dispositivo SSVEP rápido e confiável utilizando eletrodos a seco
e frequências acima de 25 Hz**

Dissertação defendida no Programa de Pós-Graduação da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás, como requisitos para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Área de concentração: Engenharia Elétrica

Orientador: Prof. Dr. Gelson da Cruz

Goiânia
2018

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

. Andrei Damian da Silva

Desenvolvimento de um dispositivo SSVEP rápido e confiável
utilizando eletrodos a seco e frequências acima de 25 Hz

[manuscrito] / Andrei Damian da Silva . - 2018.

XCVIII, 98 f.: il.

Orientador: Prof. Dr. Gélson da Cruz Júnior.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola
de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa
de Pós-Graduação em Engenharia Elétrica e de Computação, Cidade de
Goiás, 2018.

Bibliografia. Apêndice.

Inclui fotografias, abreviaturas, símbolos, gráfico, tabelas, lista de
figuras, lista de tabelas.

1. eeg. 2. icc. 3. potenciais evocados visuais. 4. ssvep. I. da Cruz
Júnior, Gélson, orient. II. Título.

CDU 62:61



Ata de Dissertação de Mestrado

Ata da sessão de julgamento da Dissertação de Mestrado em Engenharia Elétrica e de Computação, área de concentração Engenharia de Computação, do candidato **Andrei Damian da Silva**, realizada em 02 de março de 2018.

Aos dois dias do mês de março de dois mil e dezoito, às 17:00 horas, na sala Caryocar brasiliensis, bloco "A" da Escola de Engenharia Elétrica e de Computação (EMC), Universidade Federal de Goiás (UFG), reuniram-se os seguintes membros da Comissão Examinadora designada pela Coordenadoria do Programa de Pós-graduação em Engenharia Elétrica e de Computação: Os Doutores Gelson da Cruz Júnior - Orientador (EMC/UFG), Carlos Galvão Pinheiro Júnior - (EMC/UFG), Luiz Fernando Batista Loja - (IFG), Marcus Fraga Vieira - (FEF/UFG), para julgar a Dissertação de Mestrado de **Andrei Damian da Silva**, intitulada "**Desenvolvimento de um dispositivo SSVEP rápido e confiável utilizando eletrodos a seco e frequências acima de 25 Hz**", apresentada pelo Candidato como parte dos requisitos necessários à obtenção do grau de Mestre, em conformidade com a regulamentação em vigor. O Professor Doutor Gelson da Cruz Júnior Presidente da Comissão, abriu a sessão e apresentou o candidato que discorreu sobre seu trabalho, após o que, foi arquivado pelos membros da Comissão na seguinte ordem: Carlos Galvão Pinheiro Júnior, Luiz Fernando Batista Loja, Marcus Fraga Vieira. A parte pública da sessão foi então encerrada e a Comissão Examinadora reuniu-se em sessão reservada para deliberar. A Comissão julgou então que o candidato, tendo demonstrado conhecimento suficiente, capacidade de sistematização e argumentação sobre o tema de sua Dissertação, foi considerado **aprovado** e deve satisfazer as exigências listadas na Folha de Modificação de Dissertação de Mestrado, em anexo a esta Ata, no prazo máximo de 30 dias, ficando o professor orientador responsável por zelar o cumprimento dessas exigências. Os membros da Comissão Examinadora descreveram as justificativas para tal avaliação em suas respectivas Folhas de Avaliação, anexas a esta Ata. Nada mais havendo a tratar, o presidente da Comissão declarou encerrada a sessão. Nos termos do Regulamento Geral dos Cursos de Pós-graduação desta Universidade, a presente Ata foi lavrada, lida e, julgada conforme, segue assinada pelos membros da Comissão supracitados e pelo candidato. Goiânia, 02 de março de 2018.

Comissão Examinadora Designada:

Gelson da Cruz Júnior - Orientador (EMC/UFG) (Avaliação: Aprovado)
Luiz Fernando Batista Loja - (IFG) (Avaliação: Aprovado)
Carlos Galvão Pinheiro Júnior - (EMC/UFG) (Avaliação: Aprovado)
Marcus Fraga Vieira - (FEF/UFG) (Avaliação: _____)

Candidato:

Andrei Damian da Silva
Andrei Damian da Silva

*À minha família, pela compreensão dos momentos
ausentes, pelo incentivo, confiança, amor e paciência.*

Agradecimentos

Ao Prof. Gelson da Cruz da Escola de Engenharia Elétrica e de Computação da Universidade Federal de Goiás, pela orientação durante o desenvolvimento deste trabalho.

Ao Prof. Carlos Galvão da Escola de Engenharia Elétrica e de Computação da Universidade Federal de Goiás, pelo apoio durante o desenvolvimento deste trabalho

Ao Programa de Mestrado da Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás – UFG, pelo apoio recebido.

Aos professores e funcionários administrativos da EMC/UFG e do programa de mestrado, pela disponibilidade e colaboração.

E, finalmente, a todos àqueles que direta ou indiretamente tenham contribuído para o desenvolvimento desta dissertação de mestrado.

“Nós só podemos ver um pouco do futuro, mas o suficiente para perceber que há muito a fazer.”.

Alan Turing

Resumo

Este trabalho apresenta uma nova abordagem para o processamento e classificação de potenciais evocados visuais de estado estacionário (SSVEP). Este trabalho introduz um modelo de em aprendizagem por agrupamento de árvores de decisão que combina dados de análise da correlação canônica com métodos baseados na estimativa da densidade espectral de potência. Os estímulos foram criados utilizando LEDs, com frequência de 7.04 Hz até 38.46 Hz. Os dados foram coletados utilizando a placa ADS1299EEG-Fe da *Texas Instruments* e três eletrodos. Os testes foram realizados para diferentes distâncias e intensidades luminosas com o objetivo de avaliar o desempenho do algoritmo em condições diversas. Ao todo, 22 participantes foram recrutados e a taxa de acertos média foi de $99.1 \pm 2.27\%$ com tempo de decisão fixo em 1 segundo.

Palavras-chave: eeg, icc, potenciais evocados visuais, ssvep

Abstract

This paper presents a new approach for the processing and classification of visual evoked potentials of steady state (SSVEP). It introduces an ensemble tree model that combines canonical correlation analysis data with methods based on estimation of power spectral density. The stimuli were created using LEDs, from 7.04 Hz to 38.46 Hz. Data were collected using the *Texas Instruments* ADS1299EEG-Fe and three electrodes. The tests were performed for different distances and light intensities to evaluate the performance of the algorithm under different conditions. In all, 22 participants were recruited, and the average classification was $99.1 \pm 2.27\%$ with fixed decision time of 1 second.

Key-words: bci, eeg, visual evoked potentials, ssvep

Lista de figuras

Figura 1 - Posicionamento internacional 10-20 ¹	22
Figura 2 - Características SSVEP utilizando um estímulo em 10 Hz ¹	24
Figura 3 - Exemplo de estimulador feito em monitor ¹	26
Figura 4 - Estimulador comercial utilizando LEDs	27
Figura 5 - Campo visual e sua ligação ao córtex.	28
Figura 6 - Diagrama geral do processo de captação, filtragem e classificação do sinal	31
Figura 7 - Transformação das variáveis em seu espaço original para a das componentes principais ¹	32
Figura 8 - Diagrama demonstrando a extração das características de um sinal SSVEP ¹	33
Figura 9 - Representação simplificada da CCA aplicada a extração de características SSVEP	35
Figura 10 - A abordagem KNN ¹	38
Figura 11 - Diagrama representativo da classificação por meio de agrupamento de árvores de decisão	40
Figura 12 - Gráfico da relação entre conforto e ITR	42
Figura 13 - Placa ADS1299EEG-FE da Texas Instruments	44
Figura 14 - Eletrodos a seco TDE-200, fabricados pela <i>Florida Research Instruments</i>	44
Figura 15 - Dois aparatos plásticos utilizados ¹	45
Figura 16 – Diagrama do experimento ¹	47
Figura 17 – Relações entre intervalo de confiança, quantidade de amostras e número de indivíduos	49
Figura 18 - Resposta em frequência da amplitude dos filtros <i>notch</i> implementados.....	51
Figura 19 - Gráfico da densidade espectral de potência estimada via MUSIC ¹	52
Figura 20 - Diagrama representativo da extração tradicional da característica relativa a PSD	55
Figura 21 - Diagrama demonstrando um exemplo de característica extraída, relativo ao aumento relativo da relação Pxf ao longo do tempo	56
Figura 22 - Diagrama demonstrando a razão da interferência e redundância do sinal ¹	57
Figura 23 - Diagrama comparativo entre validação holdout e k-fold.	60
Figura 24 – Gráfico de desempenho ¹ para LEDs separados e utilizando agrupamento de árvores.	63
Figura 25 - Gráfico de desempenho para LEDs juntos e utilizando agrupamento de árvores.	64
Figura 26 - Gráfico de desempenho para LEDs separados e utilizando KNN.....	65
Figura 27 - Gráfico de desempenho para LEDs separados e utilizando KNN.....	66
Figura 28 – Desempenho com os LEDs separados, utilizando agrupamento de árvores ¹	68
Figura 29 - Desempenho com os LEDs juntos, utilizando agrupamento de árvores ¹	69
Figura 30 – Desempenho para LEDs agrupados separadamente, utilizando KNN ¹	70
Figura 31 - Desempenho para LEDs agrupados juntos, utilizando KNN ¹	71
Figura 32 – Desempenho com os LEDs agrupados separados, utilizando SVM ¹	73
Figura 33 - Desempenho com os LEDs agrupados juntos, utilizando SVM ¹	74
Figura 34 - Desempenho com os LEDs agrupados separados, utilizando árvores ¹	75
Figura 35 - Desempenho com os LEDs agrupados juntos, utilizando árvores ¹	76
Figura 36 – Desempenho por agrupamento de árvores	77
Figura 37 - Desempenho por SVM ¹	78
Figura 38 – Desempenho por árvores ¹	79
Figura 39 - Desempenho por KNN.....	80

Lista de tabelas

Tabela 1 - Comparação de desempenho de diversos algoritmos.	36
Tabela 2 – Taxa de acertos e ITR de acordo com a cor do estímulo	41
Tabela 3 - Resultados utilizando validação cruzada.....	48
Tabela 4 - Formulário de perguntas	48
Tabela 5 - Frequências utilizadas para CCA	53
Tabela 6 - Resultados utilizando validação cruzada por agrupamento de árvores	62
Tabela 7 - Resultados com 25% do banco reservado por agrupamento de árvores.....	67
Tabela 8 - Resultados da taxa de acertos por participante por agrupamento de árvores.....	67
Tabela 9 - Resultados para 4 pessoas reservadas do treinamento por agrupamento de árvores	72
Tabela 10 - Resultados para 4 pessoas reservadas do treinamento por KNN	72
Tabela 11 - Comparativo dos classificadores	73
Tabela 12 - Comparativo dos classificadores	77
Tabela 13 - Respostas dos formulários	81
Tabela 14 - Média de piscadas durante o experimento	82
Tabela 15 - Impacto da remoção de apenas 1 características do sinal	82

Lista de equações

Equação 1 - Estimação da frequência através de M.U.S.I.C.....	34
Equação 2 - Estimação da frequência através de M.U.S.I.C.....	34
Equação 3 - Cálculo da CCA.....	35
Equação 4 - Equação do sinal de referência para CCA	35
Equação 5 - Estimação da pdf condicional em KNN.....	37
Equação 6 - Erro quadrático médio	38
Equação 7 - Cálculo do ITR - BT	40
Equação 8 - Cálculo do ITR - BM	40
Equação 9 - Cálculo do valor Pxf.....	55
Equação 10 - Cálculo da regra de Twoing	55
Equação 11 - Cálculo da métrica de Jaccard	58

Lista de abreviaturas e siglas

BCI	Interface Cérebro-Computador (Brain-Computer Interface)
EEG	Eletroencefalograma
FFT	Transformada rápida de Fourier (Fast Fourier Transform)
FIR	Resposta Finita ao Impulso (Finite Impulse Response)
ICA	Análise de Componentes Independentes (Independent Component Analysis)
ICC	Interface Cérebro-Computador.
IHM	Interface Homem-Máquina
LCD	Display de Cristal Líquido (Liquid Crystal Display)
LED	Diodo Emissor de Luz (Light Emitting Diode)
PCA	Análise de Componentes Principais (Principal Component Analysis)
PEV	Potencial Evocado Visual
PSD	Densidade Espectral de Potência (Power Spectral Density)
SNR	Relação Sinal-Ruído (Signal-to-Noise Ratio)
SSVEP	Potenciais Evocados Visuais de Regime Permanente
TTI	Taxa de Transferências de Informações
KNN	K-Nearest Neighbor
MSE	Erro quadrático médio (Mean squared error)
TCLE	Termo de Consentimento Livre e Esclarecido

SUMÁRIO

Resumo	8
Abstract.....	9
Lista de figuras	10
Lista de tabelas	11
Lista de equações.....	12
Lista de abreviaturas e siglas	13
Capítulo 1: Introdução	16
1.1 Uma interfaces cérebro-máquina ideal	16
1.2 Interfaces cérebro-máquina reais.....	17
1.3 Interfaces de potenciais evocados visuais de estado estacionário (SSVEP)	17
1.4 Em busca de uma ICM ideal e o objetivo deste trabalho	19
1.5 Organização do trabalho	19
Capítulo 2: Embasamento teórico	21
2.1 Introdução	21
2.2 Sinais eletroencefalográficos (EEG)	21
2.3 Sinais de potencial evocado visual de estado estacionário (SSVEP)	22
2.4 Criação de estimuladores SSVEP.....	25
2.5 Um breve resumo do olho humano e cuidados com o experimento.....	28
2.6 Captação e processamento de sinais SSVEP.....	29
2.7 Extração de características e classificação do sinal SSVEP.....	33
2.8 Avaliando o desempenho de interfaces cérebro-máquina.....	40
2.9 Parâmetros de qualidade e conforto relativos ao estímulo SSVEP	41
Capítulo 3:	43
Materiais e Métodos	43
3.1 Introdução	43
3.2 Obtenção do sinal SSVEP	43
3.3 Construção do estimulador SSVEP	45
3.4 Metodologia do experimento.....	46
3.4.1 Análise estatística	48
3.5 Filtragem do sinal EEG	50
3.6 M.U.S.I.C.	51
3.7 Novas características e classificação	52
Capítulo 4:	61
Análise dos Resultados.....	61
4.1 Resultados.....	61
4.2 Resultados através da validação cruzada.....	61
4.3 Resultados através de <i>holdout</i>	66
4.4 Resultados treinando com somente 18 participantes	71
4.5 Comparativo com todos classificadores	72
4.6 Utilizando somente 1 classificador.....	76
4.7 Respostas dos formulários	80
4.7 Desempenho de acordo com os parâmetros do experimento	81
Capítulo 5: Conclusões.....	83
5.1 Discussão dos resultados	83
5.2 Objetivos atendidos	84

5.3 Problemas a serem resolvidos e possíveis direções.....	85
Referências	86
APÊNDICE	92

Capítulo 1: Introdução

Pessoas com limitações severas de movimento dependem de interfaces que necessitam pouca movimentação e relativamente alta taxa de acerto para poderem utilizar um computador e muitas vezes para se comunicarem. Atualmente, esse tipo de interface vem sendo desenvolvida para possibilitar a comunicação de indivíduos com necessidades especiais decorrentes do acometimento de enfermidades, tais como esclerose lateral amiotrófica e acidente vascular cerebral.

Dentre as diversas interfaces existentes, destacam-se as que utilizam movimentos faciais, oculares, do pescoço, língua e cérebro. Este trabalho utiliza um conjunto de equipamentos e técnicas conhecidas como interfaces cérebro-máquina (ICM ou BCI), caracterizadas por realizarem a interpretação de atividades cerebrais conhecidas e aplica-las na execução de comandos computacionais.

1.1 Uma interfaces cérebro-máquina ideal

Idealmente, uma interface cérebro-máquina deveria atender todos os seguintes requisitos:

- possuir uma alta taxa de acertos;
- ter capacidade de enviar diversos comandos por minuto sem atrasos;
- realizar os comandos em um tempo mínimo;
- funcionar sem necessidade de uma etapa de treinamento por parte do algoritmo e do usuário;
- ser imune a alterações biológicas naturais do usuário em uma mesma sessão ou dias diferentes;
- desempenhar sua função sem exigir uma grande concentração e empenho do usuário;
- funcionar sem ser cansativa ou possuir qualquer efeito colateral durante ou após o uso;
- executar sem ser suscetível a distrações externas;
- ter robustez, sem ser influenciada pelo clima, temperatura local, suor e contato geral com a pele;
- possuir uma interface amigável;

- ser confortável;
- ser realizável com mínimo de equipamento necessário (portátil);
- possuir um mecanismo para desligamento e suspensão do aparelho em casos de emergência;
- funcionar sem necessidade de preparação prévia, como limpeza e gel;
- possuir custo mínimo.

1.2 Interfaces cérebro-máquina reais

Atualmente, alguns dos requisitos de uma ICM ideal podem ser atingidos, todavia, não simultaneamente ou de forma consistente e facilmente replicável. Algumas das razões para isso são:

- a característica não linear do comportamento cerebral (Glanz, 1997; Kowalik, Wrobel e Rydz, 1996), geralmente necessitando que para se atingir uma maior taxa de acertos seja necessária uma janela de tempo maior de análise dos dados de entrada;
- falta de conhecimento do funcionamento do cérebro humano (Khatri, Tiwari e Rizvi, 2016; Wang e Wang, 2002), fazendo com que resultados indesejados possam surgir de acordo com o indivíduo ou sessão;
- sensibilidades dos eletrodos, cabos e contato pele-eletrodo, fazendo que ruídos indesejáveis possam surgir e ocasionalmente não serem perfeitamente tratados (Tallgren *et al.*, 2005);
- geralmente é necessário treinamento por parte do usuário e do algoritmo (Beverina *et al.*, 2003);
- Dificuldade em generalizar um algoritmo para pessoas que não participaram do treinamento devido à alta variabilidade biológica;
- necessidade de concentração e atenção do usuário para evocar respostas cerebrais fortes (Bondre, 2014; Ferreira *et al.*, 2013);

1.3 Interfaces de potenciais evocados visuais de estado estacionário (SSVEP)

Dentre as técnicas de ICM conhecidas, as que envolvem potencial evocado visual (PEV) têm apresentado melhores perspectivas por terem apresentado bons resultados e

demandarem menor tempo de treinamento dos indivíduos para sua utilização (Bondre, 2014; Lebedev e Nicolelis, 2006).

As PEV estáveis (SSVEPs) utilizam potenciais gerados pela excitação da retina em determinadas frequências. A excitação da retina pode ser realizada utilizando uma imagem oscilando entre as cores brancas e pretas, por meio de um monitor de um computador. No entanto, a frequência do monitor deve ser divisível pela frequência do estímulo gerado, além disto, os sistemas operacionais atuais não foram desenvolvidos para aplicações de tempo real, dificultando a geração de estímulos precisos. Uma alternativa é a utilização de LEDs, que não sofrem dos problemas mencionados.

Sinais SSVEP se mostraram bem-sucedidos em diversos sistemas cérebro-computador. Além disso, sinais SSVEP são detectados em grandes conjuntos populacionais (Guger *et al.*, 2012). Todavia, uma crítica comumente realizada a tais sistemas é a fadiga visual causada pelo estímulo, além de muitos participantes descreverem os estímulos como "irritantes" (Lin *et al.*, 2012; Luo e Sullivan, 2010; Wang *et al.*, 2006).

Uma forma de reduzir esta reclamação significativamente foi a adoção da utilização de frequências de estímulos acima de 25Hz e a utilização da cor de estímulo branca, azul ou verde (Luo e Sullivan, 2010). Em contrapartida, estímulos em frequências acima da região alpha (7.5 - 12.5 Hz) são consideravelmente mais difíceis de serem detectados em períodos curtos de tempo (Lin *et al.*, 2012; Molina, 2008; Nakanishi *et al.*, 2014).

Buscando-se atender esse objetivo, a análise da correlação canônica foi empregada pela primeira vez por (Nakanishi *et al.*, 2014), para detecção de sinais SSVEP. Diferentemente da abordagem tradicional utilizando a densidade espectral de potência, a CCA é capaz de detectar atividades SSVEP em janelas de tempo muito pequenas, menores do que quatro segundos (Hakvoort, Reuderink e Obbink, 2011; Lin *et al.*, 2007).

Uma abordagem recentemente publicada mostrou resultados um pouco melhores para frequências acima da região alpha, em comparação com a Análise da correlação canônica (CCA) tradicional, contudo com resultados piores para frequências baixas (Wei *et al.*, 2013). Essa técnica, chamada de dCCA, obteve uma taxa de acertos de $67,85\% \pm 13,49\%$, se mostrando superior o CCA tradicional ($61,52\% \pm 14,77\%$), para frequências altas (Wei *et al.*, 2013).

Contrastando com a CCA tradicional, existem outros grupos de métodos que empregam uma etapa de treinamento para obter um sinal de referência ótimo (Sakurada *et al.*, 2015; Zhang *et al.*, 2012, 2014a). A crítica destes métodos é que eles tendem ao sobreajuste

(*overfitting*), fazendo que quando empregados em longos períodos de tempo, ou até em sessões diferentes não apresentem um desempenho tão promissor. Além disto, se a etapa de treinamento não for bem realizada, o resultado pode ficar inferior a CCA tradicional (Zhang *et al.*, 2011).

1.4 Em busca de uma ICM ideal e o objetivo deste trabalho

O objetivo deste trabalho é contribuir para o desenvolvimento de interfaces SSVEP práticas e acessíveis. O ponto de maior colaboração ocorre na extração das características, onde são apresentadas novas características para classificação de sinais SSVEP.

Visando atingir o objetivo de uma interface de fácil utilização, empregou-se poucos eletrodos a seco, um equipamento de coleta de sinal de baixo custo, construiu-se estimuladores SSVEP baseados em LEDs, além da utilização de frequências acima de 25 Hz. Adicionalmente, verificou-se o impacto de valores de luminosidade e distância entre os estímulos.

Empregou-se etapas de filtragem do sinal cerebral e posteriormente a extração de características do sinal e classificação. Para comparar os resultados com estudos anteriores, foi considerado o tempo de execução, o tempo para classificação do sinal, a quantidade de estímulos presentes, a taxa de acertos e a taxa de transferência de informação (ITR).

1.5 Organização do trabalho

A redação deste trabalho foi dividida em cinco capítulos, expostos a seguir. O primeiro capítulo aborda a introdução ao tema. No capítulo 2, encontra-se uma introdução teórica, sobre as informações gerais que envolvem os focos de estudo desta pesquisa, que são:

- a) Captação e processamento do sinal SSVEP
- b) Extração de características e classificação do sinal SSVEP
- c) Parâmetros de qualidade e conforto do estimulador SSVEP
- d) Avaliando o desempenho de interfaces cérebro-máquina

No capítulo 3, são apresentadas as técnicas utilizadas para processamento e classificação do sinal, a metodologia dos experimentos e as novas características utilizadas para o classificador. O capítulo 4 descreve os resultados obtidos, juntamente com a análise

estatística. As conclusões finais e discussões sobre os resultados são descritos no capítulo 5. Finalmente, no Apêndice encontra-se os formulários entregues para os participantes do estudo.

Capítulo 2: Embasamento teórico

2.1 Introdução

No estudo de processamento e classificação do sinal SSVEP foram abordadas nas literaturas informações gerais sobre pesquisas correlatas, divididas, nos seguintes tópicos:

- a) Sinais eletroencefalográficos (EEG)
- b) Sinais de potencial evocado visual de estado estacionário (SSVEP)
- c) Criação de estimuladores SSVEP
- d) Captação e filtragem de sinais EEG
- e) Extração de características e classificação do sinal SSVEP
- f) Parâmetros de qualidade e conforto relativos ao estímulo SSVEP

2.2 Sinais eletroencefalográficos (EEG)


Sinais eletroencefalográficos são obtidos por meio de eletrodos conectados ao couro cabeludo de um indivíduo. Em 1875, o fisiólogo Richard Caton iniciou os primeiros estudos relacionados aos potenciais elétricos oriundos do cérebro em coelhos e cães. Em 1929, o psiquiatra Hans Berger deu início aos primeiros testes utilizando EEG em seres humanos, para estudo do sono. A eletroencefalografia é amplamente utilizada na medicina para estudos de distúrbios de sono, epilepsia, coma e morte cerebral. Atualmente é a base de diversas tecnologias assistivas.

O sinal elétrico obtido é a superposição de diversos neurônios naquela região. Possui de 10 a 100 μ Vpp e sua largura de banda é de 0 a 100 Hz (Stohr e Kraus, 2009). Para realizar a extração correta dos sinais desejados, um conjunto de práticas é necessário: a correta preparação dos eletrodos, seu posicionamento e fixação adequados e posteriormente um hardware e software capazes de remover artefatos e processar os sinais.

Os eletrodos comumente utilizados são revestidos de prata e/ou cloreto de prata e são utilizados juntamente com pasta condutora apropriada. Para sua fixação, costuma-se usar toucas especialmente projetadas para garantir a pressão adequada dos eletrodos ao couro cabeludo, sem causar desconforto ao usuário.

O posicionamento é feito tomando-se como base o sistema internacional 10-20 (Figura 1), que quando seguido garante que todos os eletrodos distam de 10 a 20% em relação aos eletrodos adjacentes.

Figura 1 - Posicionamento internacional 10-20¹



Fonte: (Malmivuo e Plonsey, 1995)

¹ O sistema utiliza 21 pontos que são marcados dividindo o crânio em proporções de 10% ou 20% do comprimento das distâncias entre os pontos de referência, nasion e inion.

2.3 Sinais de potencial evocado visual de estado estacionário (SSVEP)

Tradicionalmente, classifica-se as atividades cerebrais como transientes ou de estado estacionário (Galloway, 1990). A motivação em se dividir dessa forma decorre do fato do cérebro humano não possuir um comportamento linear, portanto a divisão em respostas de estado estacionário e transiente confere uma visão independente.

Em relação a dispositivos que utilizem estímulos visuais, existem sistemas baseados na detecção do potencial cognitivo P300 - Potencial que ocorre cerca de 300ms após a apresentação do estímulo visual - e os denominados PEV estáveis (SSVEPs) (SMT Müller, TF Bastos Filho, 2011). Em ambos os casos, o usuário fixa o olhar no símbolo de interesse cuja alteração de padrão de apresentação gera potenciais elétricos no cérebro que devem ser captados por meio de eletrodos sobre o escalpo e processados para permitir sua identificação. Apesar de serem consideradas atividades estacionárias, uma alternativa proposta em 2011 sugere que sinais SSVEP sejam a superposição de atividades transientes (Capilla *et al.*, 2011).

Ondas com padrão P300 são geradas involuntariamente quando as pessoas são apresentadas a algum estímulo que reconhecem, como uma imagem. No ano 2000, uma pesquisa realizada por Jessica Bayliss na universidade de Rochester (D. Bayliss e H. Ballard, 1998, 2000) utilizando sinais P300 demonstrou que pessoas utilizando uma interface virtual (VR) eram capazes de realizar ações equivalentes do mundo real, como ligar e desligar luzes.


Quando a retina é estimulada por uma luz piscando de forma periódica por alguns segundos, tipicamente na faixa de 3,5 a 70 Hz, um sinal SSVEP pode ser gerado e observado na região do lóbulo occipital (Suarez, 2013). O sinal observado possui maior amplitude na frequência do estímulo e em suas harmônicas (Müller-Putz *et al.*, 2005). Nota-se que em 2001, um estudo analisou as respostas SSVEP na faixa de 1 a 100 Hz, com incremento de 1 Hz a cada teste (Herrmann, 2001) e observou atividade SSVEP claramente até 90 Hz. Nas frequências de 10, 20, 40 e 80 Hz, Hermann observou um forte fenômeno de ressonância.

Os eletrodos são dispostos no córtex occipital, geralmente em Oz, O1 e O2, em relação à Fz ou A1. É necessário que o usuário esteja relaxado, porém que se concentre nos estímulos apresentados para que a resposta possa ser observada (Stohr e Kraus, 2009).

As frequências comumente utilizadas para geração do sinal estímulo SSVEP encontram-se na região *alpha* (entre 8 a 13 Hz), pois a resposta em amplitude evocada na região occipital é maior, tornando a detecção mais eficaz (Lin *et al.*, 2012; Wu e Lakany, 2012).

Na Figura 2 pode ser observado o comportamento do sinal SSVEP no tempo, na frequência e sua localização no escalpo.

Figura 2 - Características SSVEP utilizando um estímulo em 10 Hz¹



Fonte: Adaptado de (Zhang *et al.*, 2014b)

¹ (a) Forma de onda EEG no canal Oz; (b) Potência espectral em Oz; (c) Topografia do escalpo para 10 Hz e suas harmônicas.

De acordo com (Lin *et al.*, 2012), a técnica de SSVEP pode ser utilizada para detectar a intenção de um indivíduo em focar sua atenção em um estímulo específico, dentro de um grupo de estímulos. Isso ocorre devido a SSVEP ser dependente da atenção espacial, sendo que a intensidade do sinal gerado é maior quando o usuário se encontra focado no estímulo. As principais vantagens da técnica é sua excelente relação sinal-ruído (Baluch, 2012), ótima imunidade a artefatos (Hakvoort, Reuderink e Obbink, 2011) e alta taxa de informações transferidas por segundo (Volosyak, 2011).

Um estudo realizado em 53 indivíduos, obteve uma taxa de acerto médio de 95,5%, sendo que nenhum participante obteve desempenho abaixo de 60%. Além disto, na quarta tentativa de testes, 50,9% dos participantes obtiveram uma taxa de acerto de 100%. Esse estudo utilizou 8 canais EEG, com 4 estímulos (10, 11, 12 e 13 Hz), com tempo de decisão de 3 segundos. O ITR não foi informado (Guger *et al.*, 2012).

Em 2014, um estudo realizado em 13 participantes utilizando o conceito da combinação de frequência e fase para detecção de atividades SSVEP (Nakanishi, Wang e Wang, 2014), obteve uma taxa de acertos médio de 91,35%, porém com altíssimo ITR: em

média, $166,91 \pm 18,50$ bits/min. Para comparação, o ITR mais alto reportado até então era de 105 bits/min (Chen *et al.*, 2014).

No ano de 2015, um estudo realizado em 12 participantes (Sakurada *et al.*, 2015), utilizando 9 LEDs em frequências na faixa de 30 a 70Hz, obteve uma taxa de acerto média de 90%. Apenas 1 par de eletrodos foram utilizados (Oz-Cz) e o tempo de decisão foi de 5 segundos. O ITR não foi informado. O trabalho concluiu que a utilização de frequências altas diminui consideravelmente a fadiga visual.

Em 2016, um estudo realizado em 5 participantes (Chen *et al.*, 2016), realizou a detecção da atividade SSVEP por meio da estimação da densidade espectral de potência (PSD) pelo método MUSIC. O tempo de detecção foi de 2 segundos e foi obtido uma taxa de acertos médio de 92,68%, sendo que alguns participantes chegaram a 100%. O ITR não foi informado.

Recentemente, em 2017, um estudo conduzido em 7 participantes e utilizando 8 eletrodos com gel (Kwak, Mu e Lee, 2017), com tempo de decisão de 5 segundos e classificando o sinal por meio de redes neurais convolucionais obteve uma taxa de acertos médio de 99,42%. O ITR não foi informado pelo autor.

2.4 Criação de estimuladores SSVEP

Grande cuidado deve ser tomado para geração correta do estímulo SSVEP, pois o estímulo afeta o desempenho diretamente (Cecotti, Volosyak e Gräser, 2010). Para realizar a geração do estímulo, costumeiramente utilizam-se diodos emissores de luz ou monitores de LCD.

Quando é utilizado um monitor LCD, busca-se gerar o estímulo por meio da repetição de padrões. Diversos componentes afetam a qualidade do estímulo gerado no monitor, principalmente seu tamanho (Wu e Lakany, 2012). O estímulo é gerado alternando-se a cor de um quadrado ou um conjunto de quadrados entre duas cores que possuam contraste entre si, como vermelho e preto. Para esse tipo de estímulo, é dado o nome de *checkerboard*.

Ao utilizar-se de um monitor de LCD, é necessário primeiramente saber sua frequência de taxa de atualização de quadros. Dessa forma, os estímulos gerados no monitor, devem ser múltiplos da fatia mínima de tempo que um quadro é exibido na tela. O monitor utilizado possui frequência de 60 quadros/segundo, portanto os estímulos gerados devem ser

múltiplos de 1/60. Nota-se que esse monitor permite apenas ser configurado com frequência de 60 Hz, mas que muito monitores permitem configurações diferentes, como por exemplo, 40 ou 70 Hz.

A técnica utilizada para geração é a conhecida como *on-off*, na qual uma imagem é exibida durante metade do intervalo do período, enquanto outra imagem é exibida no restante do intervalo. A forma de geração do estímulo de um simples quadrado alternando as cores do estímulo por meio do *checkerboard* é diferente. Para que seja possível gerar corretamente o estímulo visual, é necessário que a relação entre a distância do usuário até a tela e o tamanho do estímulo seja suficiente para possuir intensidade de luz adequada para excitar a retina (Desain, 2010). A Figura 3 demonstra um estimulador realizado com auxílio de monitor.

Figura 3 - Exemplo de estimulador feito em monitor¹



Fonte: (Bieger, 2010)

¹Na imagem os eletrodos estão dispostos na região occipital e parietal e o usuário foca entre quatro estímulos diferentes.

Recentemente, alguns trabalhos publicados demonstraram que é possível gerar estímulos em outras frequências, além das múltiplas do monitor (Nakanishi *et al.*, 2014). Para tal, altera-se um estímulo entre duas frequências, ambas as frequências múltiplas da frequência do monitor. Por exemplo, para gerar a frequência de 11 Hz, alterna-se entre as frequências de 10 e 12 Hz. Uma característica desta técnica, é que além de serem gerados o estímulo de 11 Hz, também são gerados componentes em 10 e 12 Hz. Todavia, essas técnicas ainda estão limitadas pela metade da frequência da taxa de atualização de quadros do monitor e dos limites de utilização de um sistema operacional de propósito geral.

Devido às limitações de frequências dos monitores, o desperdício de espaço na tela para os estímulos e a necessidade de um hardware de alto desempenho, para que o estímulo seja minimamente confiável, adota-se uma alternativa a utilização de monitores: LEDs de alto brilho. Os LEDs de alto brilho, podem ter sua frequência controlada por um microcontrolador e sua intensidade luminosa através do valor da corrente elétrica do LED ou por meio da utilização de um modulador de largura de pulso (PWM). Um único LED de alto brilho é suficiente para geração de um estímulo SSVEP, além de que, um hardware composto por LED's e um microcontrolador possuem um custo consideravelmente mais acessível do que um computador de alto desempenho e/ou um monitor de 120 Hz. A Figura 4 mostra um estimulador profissional utilizando LEDs.

Figura 4 - Estimulador comercial utilizando LEDs




Fonte: (Guger *et al.*, 2012)

2.5 Um breve resumo do olho humano e cuidados com o experimento

O olho humano é o órgão responsável pela captura de uma pequena porção do espectro eletromagnético, denominada espectro visível, situada entre os comprimentos de onda de 380 nm a 780 nm (Pinto, 2011).

O campo visual é tudo que pode ser visto, sem movimento da cabeça ou dos olhos. Na Figura 5, temos a representação do campo visual no córtex. Aproximadamente 50% da área do córtex visual primário é dedicado a fóvea. A fóvea é a região da retina mais densa em fotorreceptores e fornece maior acuidade visual que as outras regiões da retina (Pinto, 2011).

Figura 5 - Campo visual e sua ligação ao córtex.



Fonte: (Pinto, 2011)

A retina contém dois tipos de fotorreceptores: os cones e os bastonetes. Eles são especializados na captação de um tipo de luz. Os cones são na captação da luz muito intensa,

enquanto os bastonetes se especializaram na captação da luz fraca. Os cones e bastonetes não disparam potencial de ação. Eles respondem a incidência de luz, com mudanças contínuas do potencial de membrana (Pinto, 2011).

Os riscos atribuídos ao uso da luz visível relacionam-se à absorção da energia destas radiações pelo corpo. Pelo fato da retina absorver a luz visível, se essa for de grande intensidade poderá ocasionar danos por meio de lesão térmica e fotoquímica (Dawson *et al.*, 2001). A lesão térmica é o aquecimento do tecido e está relacionada com a luz visível de todos os comprimentos de onda. Ela ocorre geralmente em curtos tempos de exposição (< 10 segundos) à luz muito intensa. Considerando a potência dos LEDs produzidos atualmente, há consenso de que esses LEDs não têm capacidade de produzir lesões térmicas (Altkorn *et al.*, [s.d.]).

Dentro do espectro da radiação óptica, os comprimentos de onda menores oferecem mais riscos aos olhos por serem radiações que transportam mais energia (ICNIRP, International Commission on Non-ionizing Radiation Protection, 1997). Porém, em um olho normal, a córnea é opaca à radiação UV abaixo de 300 nm. Desta forma, a córnea protege os componentes oculares internos dos danos potenciais da radiação abaixo de 300 nm por absorverem essas radiações. Na faixa de 300 a 400 nm a córnea é transparente, mas o cristalino absorve estas radiações oferecendo proteção à retina. Por isto a luz azul com os menores comprimentos de onda traz mais riscos à retina (Pinto, 2011).

Diversas normas de procedimento têm adotado a Função de Risco da Luz Azul (FRLA) para estimar o risco relativo em função do comprimento de onda da fonte de luz. Esta FRLA é baseada em dados experimentais em animais e acidentes com humanos.

No experimento deste trabalho foram utilizados LEDs de cor branca, portanto deve ser verificado o tempo de exposição total aos LEDs, entre as etapas de descanso. Para uma radiância efetiva de 0,367 W/cm²sr, o tempo máximo de exposição é de 270 segundos. Durante o experimento, o tempo total de observação dos LEDs, sem descanso é de 30 segundos. Portanto o experimento atende ao critério de segurança.

2.6 Captação e processamento de sinais SSVEP

A captação de sinais SSVEP é realizada por meio do emprego de eletrodos na região occipital, sendo os pontos O1, O2 e Oz comumente utilizados. Tipicamente, os eletrodos utilizados são de cúpula de prata, e são utilizados produtos para limpeza do couro cabeludo e

gel condutor. Cuidado especial é necessário para garantir que a impedância seja menor que 10 k Ω .


A partir de 2010, começaram a surgir estudos utilizando eletrodos secos, sem a necessidade de utilização de gel (Guger, Krausz e Edlinger, 2011; Liao *et al.*, 2012; Luo e Sullivan, 2010). Além da facilidade de preparação do equipamento, eletrodos secos tem a vantagem de oferecerem mais estabilidade na interface eletrodo-pele. Apesar da impedância desses eletrodos serem bem maiores, eles se mostraram capazes de captar sinais SSVEP.

Independentemente do tipo de eletrodo utilizado, para que as características do sinal possam ser extraídas, é necessário que seja realizado uma etapa de processamento de sinais, para remoção de ruídos indesejados, particularmente ruído branco.

Dentre as técnicas mais utilizadas, além do emprego de filtros analógicos ou digitais passa-faixa e *notch*, as técnicas que se mostraram eficazes são a análise das componentes principais (PCA) (Wallstrom *et al.*, 2004), a análise das componentes independentes (ICA) (Beverina *et al.*, 2003; Diego *et al.*, 2014) e filtragem adaptativa (Correa *et al.*, 2007; Leber, 2011).

A captação e filtragem do sinal biológico compreende, portanto, as etapas preliminares de um sistema típico cérebro-máquina. O processo geral pode ser resumido conforme a Figura 6.

Figura 6 - Diagrama geral do processo de captação, filtragem e classificação do sinal




Fonte: Próprio autor.

2.6.1 Análise das componentes principais (PCA)

A análise das componentes principais pode ser vista como uma forma de separar sinais que sejam descorrelacionados entre si. Idealmente, deseja-se separar a atividade SSVEP das atividades espontâneas EEG e demais ruídos presentes no sinal (Leber, 2011). Ou seja, presume-se que a atividade que se deseja estudar é descorrelacionada dos demais sinais presentes. A Figura 7 demonstra a transformação das variáveis do seu espaço original para componentes principais.

Nota-se que o emprego da PCA não garante a separação dos sinais originais de ruídos. Além disto, não existe garantia que será capaz de separar as fontes de sinais devidamente, por essa razão, alguns trabalhos anteriores tentaram a utilização da análise das componentes independentes (Sameni e Gouy-Pailler, 2014).

Figura 7 - Transformação das variáveis em seu espaço original para a das componentes principais¹



Fonte: (Scholz, 2006)

¹Na figura um exemplo da No gráfico, PC são as componentes principais.

2.6.2 Análise das componentes independentes (ICA)

A análise das componentes independentes busca recuperar sinais que não sejam somente decorrelacionados, mas independentes entre si (Almeida, 2013). Assume-se que um modelo de mistura linear com no máximo uma fonte gaussiana. Tendo em vista que adaptar o sistema separador de maneira que as estimativas sejam independentes garante que os sinais recuperados correspondem aos sinais das fontes.

A análise das componentes independentes pode ser considerada uma extensão da análise das componentes principais. Na PCA, busca-se obter as componentes com máxima de correlação, de acordo com estatísticas de segunda ordem.

O método fornece saídas ortogonais e normalizadas de acordo com as estatísticas de segunda ordem, minimizando o momento de segunda ordem. Todavia, as componentes principais podem ainda ser dependentes.

O problema da análise de componentes independentes da seguinte forma pode ser definido da seguinte forma:

Assume-se que um conjunto de séries temporais $\{x_i(t)\}$ ($i=1,2,\dots,m$), que é resultado de um processo de mistura definido como: $x(t) = As(t)$ com ($t=1,2,\dots,N$), onde A é uma matriz de mistura desconhecida de tamanho m por n e $s(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$ são componentes. Deseja-se estimar $s_j(t)$ usando apenas os dados observados $x(t)$. O problema é então encontrar uma matriz de separação W de tal forma que $y(t) = Wx(t)$ que estime as componentes.


2.7 Extração de características e classificação do sinal SSVEP

Tipicamente, sinais SSVEP são classificados por meio de métodos baseados na análise da densidade espectral de frequência ou da análise da correlação canônica (Hakvoort, Reuderink e Obbink, 2011). Costuma-se empregar algum tipo de algoritmo de aprendizagem de máquina, tanto para classificação dos estímulos, quanto para auxiliar na separação dos instantes no qual ocorre atividade SSVEP e os instantes de repouso.

2.7.1 Métodos baseados na densidade espectral de potência (PSD)

Os métodos de estimativa da PSD que são realizados por meio da FFT geralmente necessitam de pelo menos quatro segundos de sinal e costumam utilizar alguma técnica de janelamento (Hakvoort, Reuderink e Obbink, 2011; Huang *et al.*, 2011; Prabhu, 2013). O diagrama da Figura 8 demonstra um exemplo de como o método é empregado:

Figura 8 - Diagrama demonstrando a extração das características de um sinal SSVEP¹



¹ A FFT sendo realizadas com grupos de amostras de tamanho fixo, sofrendo sobreposição, aplicando-se a janela e calculando-se a FFT. Ao final, calcula-se a média.

Uma alternativa apresentada em 2016 utiliza a pseudo-psd “Multiple Signal Classification” (MUSIC). Ela realiza a estimação por meio dos autovalores da matriz de correlação associada aos dados observados (Chen *et al.*, 2016). Seu diferencial é assumir que o número de exponenciais complexas do qual o sinal é formado é conhecido. Um estudo

anterior utilizou esse método para classificação de sinais SSVEP com sucesso (Chen *et al.*, 2016).

Formalmente, define-se então que $x(n)$ é o sinal observado, p é o número de exponenciais complexas, v são os autovalores do subespaço, $M = p + 1$ e a função de estimação da frequência é dada por (2), utilizando (1):

$$e = [1 \ e^{jw} e^{j2w} \dots e^{j(M-1)w}]^T \quad (1)$$

Então:

$$\hat{P}_{MU}(ejw) = \frac{1}{\sum_{i=p+1}^M |e^{Hv_i}|^2} \quad (2)$$

2.7.2 Métodos baseados na análise da correlação canônica (CCA)

A análise da correção canônica é uma técnica que busca encontrar a correlação entre dois conjuntos de variáveis. Seu diferencial é aplicar transformações lineares nos conjuntos de variáveis, de tal forma a tentar maximizar sua correlação. Atualmente é a técnica mais utilizada para detecção de atividades SSVEP em curto espaço de tempo [11]. Entretanto, observou-se que essa técnica não é eficiente para detecção de frequências acima da região alpha de frequências (Wei *et al.*, 2013).

A detecção de atividade SSVEP por meio da CCA, consiste em gerar um conjunto de sinais de referências na mesma frequência dos estímulos utilizados, podendo incorporar suas harmônicas. Formalmente, define-se a CCA da seguinte forma: Considere dois conjuntos de variáveis aleatórias $X \in \mathbb{R}^{I1 \times J}$ e $Y \in \mathbb{R}^{I2 \times J}$ e a combinação linear $\tilde{x} = w^T X$ e $\tilde{y} = v^T Y$. A CCA tenta encontrar um par de combinações lineares $w \in \mathbb{R}^{I1 \times 1}$ e $v \in \mathbb{R}^{I2 \times 2}$ que maximize a correlação entre $\tilde{x}$ e $\tilde{y}$ por meio da resolução de (3), no qual o máximo ρ corresponde a correlação canônica máxima entre as variáveis $\tilde{x}$ e $\tilde{y}$.

$$\rho = \max_{w,v} \left(\frac{E[\tilde{x}\tilde{y}]}{\sqrt{E[\tilde{x}]^2 E[\tilde{y}]^2}} \right) \quad (3)$$


Assume-se então que existem M estímulos, com H harmônicas, frequência de amostragem " f_s " e J amostras; X é o sinal EEG de $I1$ canais, então de acordo com (4), " Y_m "

é um conjunto de sinais de referências, construídos para reconhecer as frequências "fm" (m=1,2,...,M).

$$Y_m = \begin{pmatrix} \sin(2\pi f_m 1/fs) & \dots & \sin(2\pi f_m J/fs) \\ \cos(2\pi f_m 1/fs) & \dots & \cos(2\pi f_m J/fs) \\ \vdots & \vdots & \vdots \\ \sin(2\pi H f_m 1/fs) & \dots & \sin(2\pi H f_m J/fs) \\ \cos(2\pi H f_m 1/fs) & \dots & \cos(2\pi H f_m J/fs) \end{pmatrix} \quad (4)$$

De tal forma que ao aplicar (3), calculando a CCA entre os sinais de entrada e "Ym", basta calcular o valor máximo de " ρ ", para obter a frequência do sinal SSVEP. A figura 9 demonstra um diagrama simplificado da utilização da CCA para extração de características SSVEP.

Figura 9 - Representação simplificada da CCA aplicada a extração de características SSVEP



2.7.3 Inteligência computacional aplicada a classificação de sinais SSVEP

Sinais SSVEP são tipicamente caracterizados por seu comportamento em relação a um aumento da densidade espectral de potência na frequência de estímulo, sua fácil observação e demonstração através de gráficos. Todavia, implementar um algoritmo que detecte automaticamente a atividade SSVEP para qualquer pessoa se mostra um pouco mais desafiador. Alguns motivos que justificam essas dificuldades:

1. A atividade natural EEG na região occipital pode gerar sinais com características similares a atividade SSVEP. Se poucas características forem consideradas, facilmente ocorrem falsos positivos;
2. A natureza dinâmica do cérebro humano acarreta em mudança de valores de atividade SSVEP e de atividade de fundo EEG de acordo com pessoa, ocasião e estimulador;
3. As características do sinal SSVEP variam nos instantes iniciais até estabilizar. Contudo, as características de EEG de fundo podem continuar variando de forma independente da atividade SSVEP;
4. Ocorrência de erros devido à falta de precisão de hardware, estimulador ou técnica utilizada.

Dessa forma é fundamental a utilização de um algoritmo de inteligência computacional, preferencialmente com o mínimo de dependência de dados obtidos a partir do usuário.

Um estudo realizado em 2016 (Oikonomou *et al.*, 2016) comparou diversos métodos de classificação de sinais SSVEP, as características extraídas são baseadas na FFT ou Wavelets, selecionando-as por meio da decomposição em valores singulares (SVD). Os resultados estão resumidos na Tabela 1. Para os métodos baseados em *ensemble* foram utilizados 100 *learners*.

Tabela 1 - Comparação de desempenho de diversos algoritmos.

Método	SVM	Árvores	Boost, Disc.	Boost, árvore	Bag, Disc.	Bag, árvore	LDA	KNN	Naive Bayes
Taxa de acertos	72,47	50,92	63,57	40,92	64,95	67,57	64,11	49,40	35,46
Tempo (ms)	5	5	11	6	11	6	5	6	6

Fonte: Adaptado de (Oikonomou *et al.*, 2016).

Um trabalho realizado em 2013 (Zhang, Yu *et al.*, 2013) havia introduzido uma nova forma de classificação por meio da análise da correlação canônica. Nesse trabalho, os autores criaram um método que incorporava as informações do sinal do paciente para criar um sinal de referência ótimo. O método utiliza validação cruzada e regularização L1 e foi testado em 10 usuários, obtendo aproximadamente uma média de 90% de taxa de acertos, com quatro

segundos de dados. Vale destacar que este trabalho não contempla a separação entre intervalos de tempo com e sem atividade SSVEP. Dessa forma, o método proposto depende de ser combinados com outros métodos de aprendizagem de máquina para que se possa estimar sua taxa de acertos real.

Em 2017, apresentou-se uma implementação por meio de redes neurais convolucionais (Kwak, Müller e Lee, 2017), obtendo 99,28% de taxa de acertos, em 4 segundos de dados. Os testes foram realizados com 7 indivíduos e utilizou estímulos com LED em frequência entre 9-17 Hz e 8 canais EEG.

2.7.4 Aprendizagem por K-Nearest Neighbor (KNN)

Teoricamente, se a função de distribuição de probabilidade (pdf) condicional de Y dado X fosse conhecida, um classificador ideal (Bayes) seria possível. Infelizmente, essa informação não é conhecida e, portanto, precisamos de uma alternativa.


Dentre diversas possibilidades para solução deste problema, os classificadores conhecidos como KNN tentam estimar a pdf condicional e então classificar os dados com base na probabilidade estimada. Dado um inteiro positivo K qualquer, e um conjunto de observações de testes x_0 , o classificador identifica os K pontos vizinhos no conjunto de treinamento que são mais próximos de x_0 , representados por N_0 .

Dessa forma esse método estima a pdf condicional da classe j como um conjunto de pontos em N_0 cuja resposta seja igual a j, conforme (5):

$$\Pr(Y = j | X = x_0) = \frac{1}{K} \sum_{i \in N_0} I(y_i = j) \quad (5)$$

O método KNN então aplica a regra Bayes e classifica os dados em x_0 para as classes com maior probabilidade. A Figura 10 demonstra a abordagem KNN.

Figura 10 - A abordagem KNN¹



Fonte: (James *et al.*, 2000).

¹ KNN utilizando K=3, é ilustrada em uma situação simples com 6 observações azuis e seis laranjas. Na esquerda, a predição pertence ao ponto com a cruz preta. Os três vizinhos são observados e como dois deles são azuis, ele é classificado também como azul. A direita, os limites de decisão são mostrados em preto. Os grids azuis e laranjas demonstram como as regiões serão classificadas.

A escolha do valor de K possui um impacto muito grande no classificador, influenciando a variância e o *bias* obtido. Variância e *bias* são conceitos matemáticos relacionados com o cálculo do erro, conforme (6):

$$MSE = Var(f(x_0)) + [Bias(f(x_0))]^2 + Var(\epsilon) \quad (6)$$

Onde MSE é o erro quadrático médio e ϵ é o termo de erro.

O *bias* pode ser visto como o problema que surge ao se tentar modelar algo complexo do mundo real em um modelo muito simples. Dessa forma, não importa a quantidade de amostras obtidas, nunca o resultado da predição mudará, pois, o modelo não é capaz de representar a realidade. A variância por sua vez impacta no quanto o algoritmo vai variar conforme o conjunto de dados usado para treinamento. Assim, pequenas modificações no conjunto de dados usados para treinar o modelo podem acabar gerando um grande impacto no desempenho. Mesmo que um conjunto de dados maior seja utilizado, se o modelo é demasiadamente flexível esse problema pode ocorrer.


No contexto dos classificadores KNN, à medida que o valor de K aumenta, ele se torna menos flexível e mais próximo de linear, possuindo baixa variância, mas com grande *bias*. Este é o cuidado que se deve tomar ao se escolher valores de K . Valores comuns de K são 5 e 10 (James *et al.*, 2000).

2.7.5 Aprendizagem por agrupamento de árvores

Um dos métodos de classificação mais antigos e conhecidos são as árvores de decisão. Sua maior limitação, é sua tendência ao sobreajuste (*overfitting*) [21]. Um agrupamento (ensemble) de árvores busca reduzir esse problema realizando uma média das predições de diferentes árvores. Um dos métodos mais populares, são agrupamento de árvores utilizando *bagging*. Todavia, em um banco de dados com muitos exemplos, existe uma tendência de que as arvores de decisão se tornem muito similares (Breiman, 2001). Em 2002, Breiman propôs as florestas randômicas com o objetivo de reduzir esse problema.

Nas florestas aleatórias, para uma k -ésima árvore, um vetor aleatório Θ_k é gerado, independentemente dos vetores anteriormente gerados, porém com mesma destruição; A árvore cresce usando um conjunto de treinamento e Θ_k , resultando num classificador $h(x, \Theta_k)$, onde x é o vetor de dados de entrada. Após diversas árvores serem geradas, cada classificador vota para obter a classe mais popular. Um diagrama pode ser visto na Figura 11 para maior clareza.

Figura 11 - Diagrama representativo da classificação por meio de agrupamento de árvores de decisão



Dentre as inúmeras aplicações, já foram utilizadas com sucesso na predição de elementos em cadeias de DNA, identificação de interações genéticas e classificação de sinais EEG (Sun, 2007; Yang *et al.*, 2010).

2.8 Avaliando o desempenho de interfaces cérebro-máquina

Tradicionalmente, interfaces cérebro máquina são avaliadas por sua acurácia, tempo de detecção e pela taxa de transferência de informação (*ITR - Information Transfer Rate*) (Bondre, 2014; Chen *et al.*, 2014; Wang *et al.*, 2006; Yuan *et al.*, 2013). A ITR reúne em uma mesma medida a taxa de acertos (p), velocidade de detecção T e quantidade de comandos disponíveis N . Calcula-se a ITR pelo produto entre a taxa de bits Bt pela quantidade de comandos por minuto Cn . Para o cálculo da taxa de bits, a fórmula mais comumente utilizada é a de Wolpaw (Yuan *et al.*, 2013), conforme (7) e (8):

$$Bt = \log_2 N + p * \log_2 p + (1 - p) \log_2 \left[\frac{1 - p}{N - 1} \right] \quad (7)$$

$$Bm = \frac{60}{T} * Cn * Bt \quad (8)$$

Em 2013, um trabalho (Yuan *et al.*, 2013) publicado discutiu as limitações do cálculo do ITR e os problemas de consistência encontrados na literatura. Destaca-se a dificuldade de comparar resultados que utilizem interfaces com a coleta de dados sincronizadas com estímulos, daquelas que o usuário pode enviar comandos quando desejar. Outro agravante é quando o tempo de detecção é variável. Além disso, alguns autores utilizam em seus trabalhos o valor T como sendo o tempo de detecção de um comando, enquanto outros o tempo para escrita de uma letra/caracter.

2.9 Parâmetros de qualidade e conforto relativos ao estímulo SSVEP

Um dos possíveis problemas decorrentes da utilização dos estímulos SSVEP é a fadiga visual. Estudos demonstraram que a fadiga visual é responsável pela diminuição na amplitude do sinal SSVEP (Makri, Farmaki e Sakkalis, 2015). Em alguns casos, foi reportado diminuição da potência no espectro (Cao *et al.*, 2014). Além disso, alguns participantes destes estudos reportaram cansaço e dificuldade para utilização.

Visando reduzir ou eliminar este problema, alguns parâmetros já foram estudados. Os que demonstraram maior influência foram: tamanho do estímulo, tipo de estímulo, cor e frequência (Hye *et al.*, 2014; Jukiewicz e Cysewska-Sobusiak, 2016). A Tabela 2 resume os resultados.

Tabela 2 – Taxa de acertos e ITR de acordo com a cor do estímulo

	Branco	Cinza	Vermelho	Verde	Azul
Tx. de Acertos	96,25±4,52	92,92±7,88	88,75±10,37	87,50±11,12	85,00±13,77
ITR	36,61±3,88	34,20±6,10	31,26±7,31	30,44±7,59	29,03±8,92


Fonte: Dados¹ adaptados de (Cao *et al.*, 2012)

¹Utilizando frequências abaixo de 15 Hz, 4 segundos de dados, classificação por CCA. Estimulador utilizando monitor LCD.

Uma tese de mestrado publicada em 2010 (Bieger, 2010), comparou diversos parâmetros de estímulos SSVEP. Neste estudo, observou-se que um estímulo criado em monitor LCD alternando entre as cores branco e preto produziu o maior ITR, com um dos menores confortos. Destaca-se que a luminância desse estímulo foi maior que dos outros. Na cor branca 175 lx, enquanto nas outras cores, entre 49,4 lx e 112 lx. Portanto, é possível que a

fadiga tenha sido causada pela diferença de luminância e não pela cor utilizada; considerando que em outro experimento neste trabalho o autor observou que uma luminância maior foi responsável por um menor conforto. A Figura 12 demonstra a relação do conforto e ITR de acordo com este estudo.

Figura 12 - Gráfico da relação entre conforto e ITR



Fonte: (Bieger, 2010)

Capítulo 3:

Materiais e Métodos

3.1 Introdução

Neste capítulo é apresentado o método utilizado para captação, processamento e classificação do sinal SSVEP. Destaca-se que os dados foram coletados com aprovação do comitê de ética em pesquisa; Processo com numeração 61336016.2.0000.5083. Este capítulo é dividido de forma a demonstrar quais os equipamentos e metodologias usados para extrair o sinal, o processamento de sinais realizado, a segmentação dos dados, a extração das características e classificador do sinal.

3.2 Obtenção do sinal SSVEP

Para aquisição do sinal EEG, foi utilizado a placa ADS1299eeg-fe da *Texas Instruments*, que pode ser vista na Figura 13, conectada a um notebook por meio de cabo USB. A placa de captura foi alimentada com baterias e o notebook foi mantido desconectado da rede de energia elétrica para evitar qualquer tipo de descarga elétrica no participante e para reduzir a contaminação do sinal EEG por meio da rede elétrica.

Figura 13 - Placa ADS1299EEG-FE da Texas Instruments



Foram utilizados somente três eletrodos secos TDE-200 (conforme a figura 14), costurados em uma faixa de tecido. A disposição dos eletrodos foi aproximadamente em O1, O2 e Oz, de acordo com o sistema de posicionamento 10-20.

Figura 14 - Eletrodos a seco TDE-200, fabricados pela *Florida Research Instruments*



Fonte: Próprio autor.

O software utilizado para coleta e processamento de sinais foi desenvolvido em ambiente LABView. A análise *offline* dos dados e criação do classificador foi realizado em ambiente MATLAB.

3.3 Construção do estimulador SSVEP

Para construção de um estimulador, optou-se por utilizar LEDs, devido a possibilidade de realizar estímulos SSVEP acima de 25Hz de forma confiável e que não exigisse um hardware complexo. Foram utilizados 6 LEDs de alto brilho, com ângulo de 30° de abertura. Os LEDs utilizados foram da cor branca, pois apresentam forte resposta SSVEP e são considerados confortáveis (Lin *et al.*, 2012). Os LEDs foram colocados em superfícies plásticas, disposto de duas formas diferentes, com distâncias entre si de 5cm e 1cm, conforme na Figura 15.

Figura 15 - Dois aparatos plásticos utilizados¹



¹O destaque do quadrado azul mostra a regulação do potenciômetro. O destaque verde, mostra um LED e o destaque vermelho os números indicando para aonde o participante deveria olhar.

A razão da criação de dois aparatos diferentes decorre das seguintes razões:

1. Verificar a influência da proximidade dos estímulos, no desempenho e conforto.
2. O aparato com LEDs mais distantes simula a disposição de estímulos realizados em monitores LCD, além de ser uma forma conveniente para utilização por parte do usuário.
3. O aparato com LEDs aproximados é indicado para pessoas que não tenham a movimentação dos olhos. O aparato é posicionado de forma que todos os estímulos fiquem no campo de visão e o usuário selecione o estímulo com base na sua concentração.

Para fazer os LEDs piscarem na frequência correta foi utilizado uma placa Arduino UNO. O *duty cycle* foi de 50% ou seja, para cada ciclo o LED fica ativo metade do tempo. As frequências utilizadas foram 7,04, 10, 15,15, 25, 35,71 e 38,46. A escolha das frequências obedeceu aos seguintes critérios:

- Possuir estímulos em frequências acima de 25Hz
- Possuir estímulos na região de frequências *alpha*
- Frequências que possam ser implementadas na menor fatia de tempo disponível no Arduino UNO de forma confiável, sem gerar atrasos de código

A frequência dos LEDs foi conferida com auxílio de um osciloscópio (TDS 1002C-EDU). O valor de corrente elétrica dos LEDs foi alterado ao longo do experimento utilizando um potenciômetro (B100K). Maiores detalhes sobre os valores de corrente elétrica e consequentemente de luminância dos LEDs, serão explicados na sessão 3.4.

3.4 Metodologia do experimento

No experimento descrito neste trabalho, vinte e dois participantes foram recrutados, adultos e idosos, homens e mulheres, sendo 16 com algum tipo de limitação motora. Os participantes da pesquisa foram convidados a participar através de divulgação por e-mail e pessoalmente. Foram elucidados quanto a natureza dos riscos e benefícios da pesquisa, bem como os direitos como participante.

No dia do experimento, os participantes foram devidamente acomodados em uma cadeira com a distância fixa de 40 cm em relação aos estímulos visuais (Uma marcação foi realizada no chão). Receberam instruções sobre os procedimentos que seriam realizados, e seus direitos como participantes e foram entregues o Termo de Consentimento Livre e Esclarecido (TCLE) para que fosse lido, tirassem dúvidas e assinassem, caso concordassem.


O local do experimento foi uma sala fechada, limpa, com a luz acesa, sem distrações, onde ficaram somente o pesquisador responsável e o participante. A sala foi devidamente preparada previamente para coleta de dados

Após a preparação adequada dos eletrodos, um dos aparatos contendo os eletrodos era colocado ao lado do monitor. Os participantes foram instruídos a quando escutassem um aviso sonoro, deveriam olhar para o monitor e ver qual número aparecia no centro da tela. Após

observar o número, deveriam olhar para o LED associado a este número. A ordem da sequência era sempre aleatória. A duração era de cinco segundos olhando para cada LED. Ao terminar, a luminosidade dos LEDs era alterada. O valor era medido com auxílio de um sensor de luminosidade (GY-302).

A montagem do experimento pode ser observada na Figura 16. Não é apresentado fotos dos experimentos, porque não foi obtido dos participantes uma autorização para divulgação das imagens.

Figura 16 – Diagrama do experimento¹



Fonte: Próprio autor.

¹No monitor é apresentado o número que o participante deve olhar. O quadrado em vermelho destaca qual o número que deveria ser observado em um momento qualquer. A placa de captação foi colocada na mesa, próximo ao participante.

A luminosidade de cada LED era alterada com auxílio de um potenciômetro. O experimento era repetido para a nova luminosidade. Ao todo foram utilizados três valores de luminosidade para cada aparato. A ordem da sequência de luminosidades e dos aparatos utilizados foram aleatórios. Mediu-se a temperatura e humidade da sala utilizando o sensor

DHT11, com o objetivo de verificar se essas variáveis não poderiam ser responsáveis pela diferença no conforto do usuário.

A Tabela 3 apresenta as luminosidades utilizadas. A luminosidade medida antes de ligar o estimulador, com o sensor apontado para o estimulador, foi em média 6 lx.

Tabela 3 - Resultados utilizando validação cruzada

Potenciômetro	Luminosidade 40cm	Luminosidade 1cm
10 k	12 lx	188 lx
50 k	11 lx	56 lx
90 k	10 lx	30 lx

Ao final do experimento, os participantes foram solicitados a preencher um formulário confidencial, respondendo questões sobre o conforto durante o experimento. As perguntas deveriam ser respondidas realizando uma marcação em uma das opções. Cada opção era um número de 1 a 5, 5 significando muito confortável e 1 sendo muito desconfortável. A tabela 4 resume o conteúdo das perguntas.

Tabela 4 - Formulário de perguntas

Pergunta	Descrição
1	Conforto geral
2	Eletrodos
3	Leds próximos
4	Leds afastados
5	Luminosidade maior
6	Luminosidade menor

3.4.1 Análise estatística


Apresentam-se quais os critérios utilizados para definição do grupo amostral, quantidade de amostras e os métodos estatísticos utilizados para verificação de significância dos resultados.

Primeiramente, o número de participantes foi escolhido como 22, para que potencialmente pudesse possuir capacidade de generalização do algoritmo para novos indivíduos, segundo o critério. Não existe consenso em qual é a quantidade ideal de participantes, mas dentre os critérios disponíveis, adotou-se um estudo de 2016 que analisou o impacto do número de amostras coletadas e número de indivíduos (Melinscak e Montesano,

2016). De acordo com o trabalho, a partir de 117 amostras por indivíduo (*trials*), pouca informação relevante é agregada, conforme pode ser visto na Figura 18.

Além disso, aumentar a quantidade de participantes tem impacto na generalização do comportamento daquele grupo de testes, todavia requer um aumento na quantidade de amostras por indivíduo, caso contrário, o preditor perde acurácia. De acordo com a Figura 18, para 22 participantes e 105 amostras por participantes os resultados obtidos deveriam ser extremamente significantes.

Figura 17 – Relações entre intervalo de confiança, quantidade de amostras e número de indivíduos



Fonte: (Melinscak e Montesano, 2016)

¹No gráfico (A) temos a dependência de 95% de intervalo de confiança de acordo com a quantidade de amostras. No gráfico (B) temos a relação entre a quantidade de amostras por indivíduo e o número de indivíduos. Quanto menor o tamanho da esfera melhor.

Em relação a quantidade de amostras (frequências e repouso), como são treinados dois classificadores distintos, totalizam-se um total de 2310 amostras, para 7 classes em cada classificador (4620 no total). Assim, para cada classificador, temos 330 amostras por classe. Em relação a intensidade luminosa, são 770 amostras para cada aparato utilizado.

Para analisar se de fatos os dados coletados eram significativos, foram usados o teste de McNemar's (duas caudas) e o teste *t de student*. Para utilizar o teste de *t de student*, o valor utilizado para média é o valor do erro e não da taxa de acertos. Da mesma forma o desvio padrão.

O teste de McNemar's é particularmente útil para os casos onde é possível ter variáveis distintas influenciando no resultado, por estarem hipoteticamente relacionadas. Por exemplo,

um conjunto de amostras, divididos entre acerto e erro da predição, relacionados com a fadiga, ou uma determinada intensidade de luz.


3.5 Filtragem do sinal EEG

Os dados foram inicialmente processados de forma a excluir todos os segmentos de sinais onde o valor medido fosse contínuo em 0V. Isso foi realizado para remover alguns segmentos obtidos nos dois primeiros experimentos quando ocorreu saturação do sinal em alguns momentos, devido ao ganho excessivo (24x) utilizado no ADS1299. Nos demais participantes, foi utilizado na coleta de dados um ganho de 2x na etapa de amplificação.

O ADS1299 foi utilizado com uma taxa de amostragem de 250 amostras por segundo, com seu conversor A/D em 24 bits com relação de rejeição em modo comum (CMRR) variando entre -122 a -118 dB para a faixa de frequências utilizadas. Para um ganho de 2x e amostragem de 250 amostras/s o fabricante garante 20 bits livres de ruído. Destaca-se que o componente não realiza qualquer tipo de filtragem analógica ou digital, permitindo inclusive a captação de sinais acima de 100 Hz. Por essa razão, é necessário lidar com a interferência da linha de energia elétrica, aproximadamente em 50-60 Hz e suas harmônicas.

Para remoção das interferências de linha, foram aplicados filtros FIR *notch* digitais em 60 e 120 Hz, com fator Q de 10. A implementação é feita no ambiente LabView. E a resposta do filtro pode ser vista na Figura 19.

Figura 18 - Resposta em frequência da amplitude dos filtros *notch* implementados



Empregou-se a análise das componentes independentes (ICA), utilizando-se o algoritmo *fastICA*. Sua eficácia para processamento de sinais EEG já foi demonstrada em trabalhos anteriores (Jukiewicz e Cysewska-Sobusiak, 2016; Nakanishi *et al.*, 2015; Shen, Hüper e Kleinsteinuber, 2011) e foi observada neste trabalho. São encontradas 3 componentes e nenhuma é removida. O impacto de utilizar a ICA é apresentado no capítulo 4.


3.6 M.U.S.I.C.

O método MUSIC para obtenção de uma PSD aproximada foi utilizado devido a resultados anteriores demonstrando sua eficiência, mas também para explorar a seguinte característica de seu método: o valor p deve ser definido previamente. O conceito foi utilizar um valor p tal que os picos encontrados sejam os relativos a atividade SSVEP. Desta forma, utilizou-se um valor p de 6. Durante os testes, observou-se que os picos surgiam em 60Hz,

120Hz e outros picos pertinentes a frequência de estímulo, suas harmônicas ou interferências de outros estímulos.

Conforme pode ser observado na Figura 20, o pico de maior destaque ocorre na frequência de estímulo, porém existe um erro associado tanto a frequência, devido a resolução espectral, quanto na potência.

Figura 19 - Gráfico da densidade espectral de potência estimada via MUSIC¹



¹ Observa-se no gráfico um pico nítido em 35.16. A frequência real do estímulo era em 35.71. Observa-se picos relativos a outras frequências de estímulo.

3.7 Novas características e classificação

Muitos métodos apresentados na literatura se mostram capazes de obter bons resultados na classificação de sinais SSVEP. Todavia, a análise da correlação canônica não se mostrou capaz de classificar corretamente sinais de alta frequência (Molina, 2008; Wei *et al.*, 2013).

O método proposto neste trabalho, utiliza classificador por agrupamento de árvores, utilizando os conceitos de *bagging* e de florestas aleatórias. O intuito é de agregar diversas técnicas de extração de atividades SSVEP em um mesmo classificador, cada qual adequada para situações distintas.

3.7.1 Modificação na CCA

Foram propostas algumas modificações em métodos conhecidos. No caso da CCA, propõe-se como uma melhoria que ao misturar estímulos de baixa e alta frequência, utilize-se somente as harmônicas dos estímulos de baixa frequência. Uma forma de realizar isso, é conforme a tabela 5. Essa pequena modificação é suficiente para viabilizar a classificação por meio da CCA com os estímulos na faixa de valores descritos.

Tabela 5 - Frequências utilizadas para CCA

Estímulo	Frequências de referência
7.04	21.12, 28.16 e 77.44
10	20, 40 e 80
15.15	30.3, 45.45, 90.9 e 106.05
25	25, 50, 75 e 100
35.71	35.71 e 71.42
38.46	38.46 e 76.92

O conceito de realizar esta modificação é que por mais que relativamente a atividade SSVEP tenha aumentando em uma dada frequência de estímulo, por exemplo, em 38,46Hz, o valor absoluto da correlação nesta frequência ainda vai ser menor do que a correlação com frequências mais baixas, como de 7 Hz. Numericamente, a correlação é maior com a atividade de fundo cerebral em região *alpha*, obtida no córtex occipital, do que com a atividade SSVEP, caso ela esteja em frequências fora do espectro *alpha*.

Nota-se que essa hipótese pode ser justificada devido o sinal captado não conter somente atividade SSVEP, mas também atividade cerebral predominantemente na região *alpha*. Como parte da metodologia para verificar se essa possibilidade é correta, o classificador posteriormente é treinado sem a inclusão dessa característica, para evidenciar seu impacto na acurácia.


3.7.2 Aplicando métodos baseados na PSD

Considera-se neste trabalho que os métodos baseados em PSD obtém melhores resultados para classificar as atividades acima de 25 Hz (Herrmann, 2001). Dentre os métodos que estimam a PSD, sabe-se que os métodos tradicionais, baseados no método de Goertzel, aumentam sua taxa de classificação conforme utiliza-se uma janela de tempo maior (Hakvoort, Reuderink e Obbink, 2011).

Sabe-se que o método MUSIC é capaz de obter alta taxa de acertos em intervalos de tempo pequenos, mas que não há clareza quando o método MUSIC é superior a CCA (Chen *et al.*, 2016).

Para detecção da atividade SSVEP por meio do método MUSIC, foi calculado o valor da PSD em relação aos seus dois vizinhos maiores e menores que o ponto de interesse, conforme já realizado previamente na literatura (Zhang, Yangsong *et al.*, 2013). Além disso, considerou-se um possível erro devido a resolução espectral insatisfatória, e por essa razão, este cálculo foi realizado também para os dois pontos mais próximos da frequência de interesse. O mesmo procedimento é realizado para duas harmônicas. Incorporou-se no classificador o valor obtido para cada frequência e suas harmônicas. A Figura 21 demonstra o procedimento e a equação final (9).

Figura 20 - Diagrama representativo da extração tradicional da característica relativa a PSD




$$P_{xf} = \frac{\text{Potência em } Fx}{(\text{Potência em } Fx - \Delta x) + (\text{Potência em } Fx + \Delta x)} \quad (9)$$

Considera-se que se for calculado o valor absoluto da potência (estimado por Goertzel) em uma dada frequência de estímulo e comparado esse valor ao obtido 1 segundo atrás, ocorre um grande aumento ou diminuição neste valor sempre que o usuário alternar seu foco

de um estímulo para outro. A Figura 22 demonstra o procedimento. Esta informação foi incorporada ao classificador, além do próprio valor absoluto no instante de tempo analisado.

Figura 21 - Diagrama demonstrando um exemplo de característica extraída, relativo ao aumento relativo da relação Pxf ao longo do tempo




Um fator de destaque são as interferências detectadas no espectro, que ocorrem principalmente decorrentes dos estímulos próximos aos que o usuário estiver olhando. Desta forma, um efeito que poderia ser negativo, torna-se uma fonte de informação importante, gerando uma redundância de informação para determinação de qual estímulo está sendo observado. Por exemplo, se o usuário estiver olhando para o estímulo de 10Hz e próximo a ele estiverem os estímulos de 15,15 Hz e 35,71 Hz, esses estímulos geralmente estarão presentes no espectro. Entretanto, ao olhar para o estímulo de 15,15 Hz, além do estímulo de 10Hz estar presente no espectro, outro estímulo estará presente, neste caso, 25 Hz. Isso decorre da forma como os estímulos estão arranajados no aparato e da intensidade de luz dos estímulos. A Figura 23 ilustra esse comportamento.

Destaca-se que essa característica somente será um elemento positivo se o algoritmo de classificação for capaz de incorporar todos esses elementos. Ou seja, se a classificação for trivial, como simplesmente aplicar a CCA e escolher o maior resultado, a interferência terá um efeito negativo, como já demonstrado em trabalhos anteriores (Ng, Bradley e Cunnington,

2011). Os classificadores e os resultados serão discutidos nas próximas sessões, mas vale frisar que o próprio desempenho obtido é uma prova de que a interferência não é necessariamente algo ruim.

Figura 22 - Diagrama demonstrando a razão da interferência e redundância do sinal¹



¹Nesse caso, um retângulo azul destaca o estímulo em 10 Hz, enquanto é esperado que no sinal também possam componentes das frequências 35.71 e 15.15 Hz.

Todavia, ao considerar todas essas variáveis, evidencia-se a necessidade de um algoritmo de classificação de padrões. Necessita-se lidar com as seguintes circunstâncias:

- Interferência oriunda dos demais estímulos SSVEP
- Separação entre estados de repouso (sem olhar para estímulos) e estados de concentração em um estímulo SSVEP
- Separação de atividades espontâneas EEG de atividades SSVEP
- Ruídos e distrações externas

3.7.3 Os classificadores por meio de árvores e agrupamento de árvores

Dentre os algoritmos testados, um dos melhores resultados foi obtido com um agrupamento de árvores de decisão, utilizando 230 preditores e permitindo no máximo 120 divisões. Foram treinados três classificadores, um para quando os LEDs estavam próximos, outro para quando estavam afastados e outro agrupando os dois conjuntos de dados.

Para cada conjunto de árvores é selecionado um grupo de amostras aleatoriamente. É permitido que a mesma amostra seja usada em grupos de árvores diferentes. Além disso, os preditores (características) que serão usadas também são aleatórias (floresta randômica).

Em relação as árvores, foram realizados testes através do índice de Gini e pela regra de Twoing sendo que a regra de Twoing obteve melhor desempenho. O índice de Gini foi proposto por Breiman em 1984, originalmente definindo uma medida de probabilidade de classificação falsa de um grupo de dados. A regra de Twoing é definida como (10):

$$ValorTwoing = \left(\frac{|TL|}{n}\right) * \left(\frac{|TR|}{n}\right) * \left(\sum_{i=1}^k \frac{|Li|}{|TL|} - \frac{Ri}{|TR|}\right)^2 \quad (10)$$

Onde $|TL|$ e $|TR|$ são o número de exemplo a esquerda e direita respectivamente de um nó T, n é o número de exemplo de um nó T e Li e Ri são os exemplo da categoria i a esquerda ou direita da divisão.

3.7.3 Os classificadores por meio de KNN e agrupamento de KNN

O algoritmo de KNN foi testado para valores de K variando de 1 a 20. O melhor resultado foi obtido com K igual a 4. A distância foi calculada de forma direta, sem nenhum tipo de peso ou manipulação. Foram testadas as seguintes métricas de distância: Euclidiana, Chebychev, cosseno, Spearman, Jaccard e Hamming, O melhor resultado foi obtido com Jacard.

A métrica de Jaccard é descrita conforme (11):

$$dj = \frac{\#[(Xsj \neq Yrj) \cap ((Xsj \neq 0) \cup (Yrj \neq 0))]}{\#[(Xsj \neq 0) \cup (Yrj \neq 0)]} \quad (11)$$

Aonde X_{sj} e Y_{rj} são duas matrizes quaisquer.

3.7.3 O classificador através Máquinas de vetores de suporte (SVM)


SVM's classificam os dados buscando o melhor hiperplano que separe todos os pontos de dados de uma classe em relação a outra. Esse espaço de separação busca maximizar a distância entre os pontos mais próximos em relação a cada uma das classes.

Dessa forma, para classificar diversas classes, uma sucessão de SVM's foram criadas com kernel linear, onde se verifica em cada uma delas se o dado de entrada pertence ao grupo em questão (por exemplo, do estímulo de 10 Hz) ou ao grupo de "não pertence". Se o dado de entrada for classificado como "não pertence", ele passa para a próxima SVM que verificará se ele pode ser classificado como outra classe (por exemplo, de 15,15 Hz). Foram testados SVM's com kernel polinomial e Gaussiano, sendo o resultado com Gaussiano superior.

3.7.3 Validação dos dados

Foram testados métodos por validação cruzada *k-fold*, com k igual a 5, 10, 15, 20, 25, 30 e 35 (sendo 14 o melhor resultado) e pelo método de *holdout*, com 25% do banco reservado para testes, selecionados aleatoriamente a partir de todos os participantes. A Figura 24 demonstra a diferença entre os métodos.

Figura 23 - Diagrama comparativo entre validação holdout e k-fold.



Adicionalmente, treinou-se um classificador com 18 participantes, excluindo-se aleatoriamente 4 pessoas do treinamento e utilizou-se esses quatro participantes separados para validação e teste. A motivação de realizar este último teste é verificar se o algoritmo tem capacidade de generalização para pessoas que não participaram da etapa de testes, algo particularmente útil quando o indivíduo não consegue se comunicar de nenhuma forma.

Capítulo 4:

Análise dos Resultados

4.1 Resultados

Neste capítulo estão apresentados os resultados de acordo com a estratégia empregada para classificação dos dados, resultado da análise dos formulários, relatos dos participantes da pesquisa e a análise estatística para demonstração da validade dos dados.

Nas tabelas, o aparato “junto” se refere ao que possui os LEDs posicionados agrupados por uma distância de 1 cm. O termo “separado” é empregado para o aparato com LEDs com distância entre si de 5 cm.

Os dois classificadores que obtiveram melhor resultado foram o baseado em agrupamento de árvores e o KNN. Dessa forma, são os mais explorados nos testes, apesar que é apresentado um comparativo com outros algoritmos que também foram testados.

4.2 Resultados através da validação cruzada

Apresentam-se na Tabela 6 os resultados de classificação utilizando a validação cruzada *k-fold*, com *k* igual a 14 e janela de tempo de 1 segundo. Dado o volume total de amostras, é o método mais indicado para avaliação do resultado, pois possui menor desperdício de informação.

Destaca-se que a coluna B presente na Tabela 6 é utilizada para o cálculo do ITR. O critério para qual método de estimativa é usado de B depende do autor. Neste caso, adotou-se o método de Wolpaw, que é aplicável a este trabalho pois todas as informações necessárias são conhecidas, além de ser o método mais utilizado na literatura (Yuan *et al.*, 2013).


Tabela 6 - Resultados utilizando validação cruzada por agrupamento de árvores

Aparato	Taxa de acertos	B (Wolpaw)	ITR (bit/min)
Junto	98,56 $\pm$ 3,10 %	2,4428	146,56
Separado	99,10 $\pm$ 2,27 %	2,4900	149,40

Os resultados por meio da KNN são extremamente similares, porém com um resultado mais curioso das classes nas quais ocorrem erro. Observando-se as Figuras 25, 26, 27 e 28, percebe-se que apesar do desempenho percentual ser bastante similar, no caso dos agrupamentos de árvores a dificuldade de classificação ocorreu na frequência 38.46 Hz (LEDs separados) e de forma diversificada com os LEDs juntos. No caso da KNN, com os LEDs separados, ocorre vários casos onde o estímulo não foi detectado, porém poucos casos onde foi erroneamente classificado. Esse é um resultado mais favorável, pois gera menor transtorno prático ao usuário.


Com os LEDs juntos, a KNN errou mais ao classificar o resultado de 10 Hz. Isso pode ser compreendido pois a atividade de 10 Hz é mais forte e comum na região occipital, ou seja, existe muita atividade espontânea em 10 Hz. Esse resultado sugere, que em futuros experimentos se evite utilizar estímulos nessa frequência, pois apesar de serem mais fortes e do fenômeno de ressonância (Herrmann, 2001; Horki, Neuper e Müller-Putz, 2011), elas podem contribuir para falsos positivos.

Figura 24 – Gráfico de desempenho¹ para LEDs separados e utilizando agrupamento de árvores.




¹Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs separados e utilizando agrupamento de árvores.

Figura 25 - Gráfico de desempenho para LEDs juntos e utilizando agrupamento de árvores.



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs juntos e utilizando agrupamento de árvores.

Figura 26 - Gráfico de desempenho para LEDs separados e utilizando KNN.



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs separados e utilizando KNN.

Figura 27 - Gráfico de desempenho para LEDs separados e utilizando KNN



¹Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs juntos e utilizando KNN.

4.3 Resultados por meio de *holdout*

O método de *holdout* é amplamente utilizado para validação dos dados. Sua desvantagem é a necessidade de reservar parte dos dados para testes, que poderiam ser usados para treinamento. Para implementar um algoritmo com capacidade de generalizar para todos os 22 participantes, 75% dos dados usados para treinamento são provenientes de todos os 22 participantes, obtidos aleatoriamente, porém de forma a balancear as classes de cada indivíduo. Ou seja, reservados para teste, tomou-se 3 amostras aleatórias da mesma frequência de cada indivíduo, para cada tipo de aparato, 1 de cada intensidade de luz diferente; totalizando 210 amostras para testes, por indivíduo. A Tabela 7 apresenta os resultados de

desempenho com o classificador treinado com 75% dos dados obtidos aleatoriamente de todos os participantes e a tabela 8 os dados de desempenho por participante.

Tabela 7 - Resultados com 25% do banco reservado por agrupamento de árvores

Aparato	Taxa de acertos (25%)	B (Wolpaw)	ITR (bit/min)
Junto	96,50 $\pm$ 2,65%	2,2848	137,01
Separado	96,90 $\pm$ 4,50 %	2,3136	138,82


Tabela 8 - Resultados da taxa de acertos por participante por agrupamento de árvores

Participante	Taxa de acertos - separado	Taxa de acertos - junto
1	100%	100%
2	100%	98,11%
3	98%	97,44%
4	92%	95,11%
5	100%	94%
6	96,44%	98,2%
7	97,85%	95,11%
8	100%	94,33%
9	94%	94,44%
10	100%	100%
11	100%	93,88%
12	100%	100%
13	89,1%	94%
14	96,44%	92,44%
15	100%	96%
16	99%	100%
17	98%	94,44%
18	100%	100%
19	87%	92,22%
20	85,7%	96,85%
21	100%	97%
22	99%	100%

Para essa forma de avaliação, apresentam-se nas Figuras 29 e 30 os gráficos de confusão dos dados que foram reservados para testes. Neles estão destacados, percentualmente, os resultados de classificação (relativo aos 25% de dados reservados) de acordo com cada classe.


Observa-se que o desempenho por frequência é afetado pelo aparato utilizado. Como o aparato está intrinsecamente ligado ao classificador (devido a disposição dos LEDs e frequências serem diferentes) a diferença em desempenho pode estar ligada a escolha das frequências e a disposição dos LEDs, principalmente ao ser considerado que tradicionalmente os melhores resultados costumam ser obtidos com estímulos na região *alpha* (7.5 – 12 Hz) de frequência.

Figura 28 – Desempenho com os LEDs separados, utilizando agrupamento de árvores¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs separados, utilizando agrupamento de árvores.


Figura 29 - Desempenho com os LEDs juntos, utilizando agrupamento de árvores¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados juntos, utilizando agrupamento de árvores.


Todavia, o mesmo não ocorre ao ser utilizado o classificador através de KNN. Apesar do erro ser similar, a forma como ocorre é bem diferente, como pode ser observado nas Figuras 31 e 32, nesses casos o erro espalhou para todas as classes, ao invés de ficar concentrado em alguns pontos específicos. Isso sugere alguma deficiência do classificador, pois não existe uma justificativa biológica óbvia.

Figura 30 – Desempenho para LEDs agrupados separadamente, utilizando KNN¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados separadamente, utilizando KNN.

Figura 31 - Desempenho para LEDs agrupados juntos, utilizando KNN¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados juntos, utilizando KNN.

4.4 Resultados treinando com somente 18 participantes

Treinou-se o classificador usando dados de 18 participantes e foram reservados os dados de 4 participantes para testes. Ou seja, aproximadamente 20% dos dados reservados, entretanto simulando um processo onde indivíduos que não participaram da pesquisa utilizassem o aparelho.

Esse processo foi repetido para 50 combinações diferentes de participantes “reservados para testes” e os resultados estão resumidos na tabela 9. Os resultados de máximo e mínimo são pertinentes as quatro pessoas e não somente de um indivíduo entre as quatro. Esses resultados demonstram a importância de incluir dados de treinamento do indivíduo, ao

mesmo tempo que apontam a possibilidade de criação de um modelo que generalize para qualquer pessoa.

Destaca-se que os resultados obtidos por meio de validação por *k-fold*, potencialmente generalizam melhor para novos participantes, do que o resultado desse experimento. Isso decorrente do fato que o algoritmo treinado por *k-fold* obteve informações oriundas de 22 participantes e não somente 18. A Tabela 9 resume os resultados referentes ao agrupamento de árvores e a Tabela 10 através do KNN.

Tabela 9 - Resultados para 4 pessoas reservadas do treinamento por agrupamento de árvores

Aparato	Média de acertos	Máximo	Mínimo
Junto	81,58 ± 15,64 %	100%	15,79%
Separado	82,22 ± 16,07 %	100%	32,78%

Tabela 10 - Resultados para 4 pessoas reservadas do treinamento por KNN

Aparato	Média de acertos	Máximo	Mínimo
Junto	83,43 ± 22,17 %	100%	11,139%
Separado	85,81 ± 21,64 %	100%	38,11%

Na média o desempenho do KNN foi melhor, apesar do desvio padrão ser maior. Os desempenhos mínimos e máximos ocorreram exatamente com as mesmas pessoas.


4.5 Comparativo com todos classificadores

Na Tabela 11, destacamos os melhores resultados obtidos com diversos classificadores, por meio da validação *holdout*. Todos os classificadores tiveram seus parâmetros ajustados iterativamente visando obter o máximo desempenho. A diferença é significativa, com $p < 0,0001$, pelo teste de *t de student*.

Tabela 11 - Comparativo dos classificadores


Preditores	Juntos	Separados
Agrupamento de árvores	96,9 %	97,3 %
KNN	94,7 %	95,2 %
Árvore de decisão	85,4 %	85,4 %
SVM (Gaussiano)	86,7 %	86,7 %

As Figuras 33, 34, 35 e 36 demonstram os desempenhos dos demais classificadores ainda não discutidos.

Figura 32 – Desempenho com os LEDs agrupados separados, utilizando SVM¹


¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados separados, utilizando SVM.

Figura 33 - Desempenho com os LEDs agrupados juntos, utilizando SVM¹




¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados juntos, utilizando SVM.

Figura 34 - Desempenho com os LEDs agrupados separados, utilizando árvores¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados separadamente, utilizando árvores simples.

Figura 35 - Desempenho com os LEDs agrupados juntos, utilizando árvores¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Relativo ao classificador com os LEDs agrupados juntos, utilizando árvores simples.


4.6 Utilizando somente 1 classificador

Experimentou-se combinar os dados obtidos dos experimentos com os aparatos separados e juntos para verificar se ocorreria ganho ou perda de desempenho. Os resultados demonstraram um ganho de desempenho de todos os classificadores. Todavia, não ocorreu mais um padrão de ocorrência do erro. Dessa forma, o erro passou a ficar espalhado para todas as classes, similarmente ao que havia ocorrido com o KNN. A Tabela 12 e as Figuras 37, 38, 39 e 40 apresentam os resultados.


Tabela 12 - Comparativo dos classificadores

Preditores	Tx. de Acertos
Agrupamento de árvores	99,2 %
KNN	98,3 %
Árvore de decisão	96,6 %
SVM (Gaussiano)	95,5 %

Figura 36 – Desempenho por agrupamento de árvores




¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Resultado com todos os dados juntos, através de agrupamento de árvores.

Figura 37 - Desempenho por SVM¹


¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Resultado com todos os dados juntos, através de SVM.

Figura 38 – Desempenho por árvores¹



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Resultado com todos os dados juntos, através de árvores simples.

Figura 39 - Desempenho por KNN



¹ Gráfico demonstrando a taxa de acertos para cada frequência, os verdadeiros positivos e falsos negativos. Resultado com todos os dados juntos, através de KNN.

Estes resultados sugerem que todos os classificadores poderiam ter originalmente obtido melhor resultado se mais dados estivessem disponíveis.

4.7 Respostas dos formulários

A Tabela 13 resume percentualmente as respostas obtidas dos formulários entregues aos participantes. Como pode ser observado, 72,73% dos participantes consideraram os estímulos afastados como confortáveis e 63,64% consideram que a diminuição da luminosidade deixa estímulo mais confortável. A nota 3 pode ser compreendida como uma resposta neutra ou indiferente. Os formulários estão disponíveis no Apêndice.

Tabela 13 - Respostas dos formulários

Pergunta	Nota 1	Nota 2	Nota 3	Nota 4	Nota 5
1	0.00%	4,55%	18,18%	31,82%	45,45%
2	0.00%	4,55%	13,64%	31,82%	50,00%
3	0.00%	22,73%	27,27%	27,27%	22,73%
4	0.00%	4,55%	22,73%	40,91%	31,82%
5	18,18%	13,64%	22,73%	22,73%	22,73%
6	0.00%	9,09%	27,27%	22,73%	40,91%

4.7 Desempenho de acordo com os parâmetros do experimento

Devido a coleta de diversos dados, mas principalmente da intensidade de luz, espera-se que possivelmente um destes fatores fosse capaz de influenciar na classificação, que fosse observado uma correlação entre o desempenho e alguma variável externa, mesmo o experimento sendo conduzido de forma aleatória controlada.

Entretanto, não foi observado correlação entre o desempenho por usuário com o número de piscadas, temperatura da sala (média de 26°), humidade (média de 68%) ou com as respostas dos formulários em relação ao conforto. Considera-se que o desconforto aumenta conforme a duração do experimento, e foi por essa razão que a ordem (frequência, intensidade de luz e aparato) sempre era aleatória; mas talvez fosse observado uma queda de desempenho conforme a duração do experimento.

Apesar do experimento ser aleatório e controlado no sentido da frequência, intensidade de luz e aparato, conclui-se que não se pode afirmar que existe ou não uma relação entre o desempenho e as variáveis secundárias, como conforto; Pois os testes estatísticos de McNemar's (duas caudas) e o teste *t de student* (utilizando o valor médio do erro) apontam que não havia significância destes resultados.

Esclarecendo, em relação as variáveis controladas ao longo do experimento, para o algoritmo utilizado, não existem impacto de desempenho em relação a quaisquer variáveis e além disto, este resultado é extremamente significativo $p < 0,00001$. Em relação as variáveis que seriam impossíveis de controlar, como o qual o conforto do participante, ou humidade e

temperatura, os resultados foram não significativos. O problema decorre que não havia quantidade de participantes suficientes para que se pudesse ter um volume de dados grande o bastante para que gerasse quantidade de amostras significativas. Pois para avaliar o algoritmo temos 220 amostras por indivíduo (Teoricamente, totalizando 4840 amostras), possibilitando uma pequena margem de erro. Entretanto, para inferior o conforto são apenas 22 amostras no total (participantes), pois o conforto é avaliado para todo o experimento e não “segundo a segundo”. Na tabela 14 estão apresentados os resultados da quantidade média de piscadas, que pode ser conveniente para outras pesquisas interessadas nestes dados.

Tabela 14 - Média de piscadas durante o experimento

Aparato	Piscadas Médias -Total	Piscadas - média por segundo
Junto	24,04 ± 27,68	0,1335 ± 0,154
Separado	25,86 ± 26,51	0,144 ± 0,147

Finalizando, apresentam-se na Tabela 15 o resumo do impacto de características utilizadas durante o treinamento. Essa tabela foi extraída removendo um grupo de características ou então alterando a forma como o processamento do sinal foi feito para verificar se essas características eram úteis ou não no desempenho do algoritmo. Para tal, utilizou-se validação *holdout* com 25% e o método por agrupamento de árvores.

Tabela 15 - Impacto da remoção de apenas 1 características do sinal

Aparato	Parâmetro	Taxa de acertos
Junto/Separado	Sem utilização da ICA	Perda de 5%
Junto/Separado	Sem utilizar CCA	Perda de 11,4%
Junto/Separado	Sem utilizar PSD relativa a $n - (n-1)$	Perda de ±2%
Junto/Separado	Sem utilizar MUSIC	Perda de 16,5%
Junto/Separado	Sem utilizar PSD tradicional	Perda de ±1,1%
Junto/Separado	Sem adicionar a potência média do espectro	Perda de ±5 % - Principalmente relativo a detecção de estados sem atividade SSVEP

Capítulo 5: Conclusões

5.1 Discussão dos resultados

O presente trabalho demonstrou que a combinação de diversas características do sinal cerebral por meio de um classificador por agrupamento de árvores, possibilita a detecção de atividades SSVEP de forma eficaz e robusta. Isso só foi possível devido a implementação de um algoritmo de reconhecimento de padrões, caso contrário, realizar um algoritmo levando em consideração todos os conjuntos de variáveis que necessitam de calibração seria impraticável.

Destaca-se que muitas dessas características já eram conhecidas de trabalhos anteriores, em particular no caso da CCA, alterou-se somente a forma de combinar as frequências. Vale notar que em trabalhos futuros poderia ser investigado uma equação para combinar as diferentes frequências de uma forma mais eficaz, simples e de mais fácil compreensão.

Os resultados obtidos demonstram que a presente técnica é capaz de ser empregada em situações reais, com equipamentos relativamente simples que utilizem o ADS1299 e ao menos três eletrodos secos na região occipital. Esperava-se que o emprego de eletrodos a seco em conjunto com frequências acima de 25Hz poderia ocasionar em uma baixa SNR, devido à alta impedância dos eletrodos e o sinal SSVEP ser mais fraco. Entretanto, o sinal SSVEP captado se mostrou visivelmente claro graficamente por meio da PSD e o algoritmo final se mostrou eficiente.

Destaca-se que foi possível a detecção de atividades acima de 25 Hz e com intensidade de luz baixa, que conforme a literatura e nossos resultados demonstraram, ambos influenciam no conforto dos usuários. Majoritariamente, os participantes consideraram os estímulos mais fracos como confortáveis, e unanimemente os estímulos em frequências mais altas como mais agradáveis.

Percebe-se que mais de um classificador foi capaz de obter bons resultados, e que com maior conjunto de dados, não somente a qualidade da predição aumenta como a variedade de classificadores capazes de produzirem bons resultados. O interessante é observar que o erro obtido com o classificador com agrupamento de árvores está ligado com a natureza do sinal. Como sugestão para propósitos de aplicação prática, coletar uma grande quantidade de sinal

do usuário em 1 treinamento e futuramente apenas reforçar com novos conjuntos de dados, conforme o usuário sinta necessidade, devido a mudanças biológicas do sinal ao longo do tempo. Além disso, evitar estímulos em frequências baixas, especialmente a de 10 Hz. Apesar de para este conjunto de dados utilizado ao longo deste trabalho o agrupamento de árvores ter tido melhor desempenho, não se descarta a possibilidade de utilização do classificador por KNN, pois essa técnica obteve desempenho muito similar e é um algoritmo com tempo de treinamento e execução muito menor.

O resultado da análise estatística dos dados mostrou que a intensidade de luz não apresentou impacto significativo na taxa de acertos. Nota-se que apesar da intensidade do sinal SSVEP ser mais forte conforme a intensidade de luz era aumentada, em termos de potência, isso não gerou impacto significativo no desempenho. Vale notar, que é esperado que a fadiga poderia ocasionar deterioramento no desempenho caso o experimento fosse mais longo e sob essa ótica, é preferível que os estímulos sejam de menor intensidade.

Devido ao estudo ter considerado as duas disposições dos eletrodos, visando aplicações finais distintas, conclui-se da análise que a distância entre os estímulos não afeta consideravelmente a taxa de detecções, porém os estímulos mais próximos foram vistos como mais cansativos por parte dos usuários. Isso é esperado, não somente pela distração visual dos demais estímulos que estão presentes no campo de visão, mas devido a maior intensidade de luz, ocasionado pela contribuição de cada LED individualmente.

Os resultados da análise da quantidade de piscadas demonstraram que o mesmo não teve relevância para o resultado final. Isso pode ser fruto do algoritmo, ou simplesmente que a rápida piscada natural não é suficiente para anular o regime estacionário da atividade SSVEP. De toda forma é um resultado relevante, pois é comum os participantes serem solicitados a não piscarem durante experimentos SSVEP.

5.2 Objetivos alcançados

Dos objetivos esperados de serem atingidos de uma BCI ideal, talvez nenhum possa ser atingido com perfeição, mas muitos destes objetivos puderam ser parcialmente atingidos:

- Alta taxa de acertos – Por meio da validação cruzada *k-fold*, 99,1%.
- Tempo mínimo de detecção dos comandos – Tempo de 1 segundo. Difícil especular qual seria o tempo mínimo visando uma aplicação prática.

- Não ser cansativa ou possuir qualquer efeito colateral durante ou após o uso. Este parâmetro pode ser difícil de mensurar. Até onde pode ser observado pelos formulários, considera-se que tenha sido atingido.
- Ser confortável. Não houve reclamações e foi considerado confortável pelos participantes, quando utilizado frequências altas e brilho baixo.
- Sem necessidade de preparação prévia (Como limpeza e gel) – A utilização de eletrodos a seco se mostrou eficaz, dispensando preparações prévias. Ainda assim, é necessário colocar uma touca ou aparato com eletrodos.
- Custo mínimo – Até aonde se pode verificar e o acesso é permitido, foi utilizado um equipamento de menor custo no mercado nacional e internacional.

5.3 Problemas a serem resolvidos e possíveis direções

Como sugestão para trabalhos futuros, destaca-se a possibilidade de construção de um teclado externo utilizando LEDs, a redução da quantidade de eletrodos e a tentativa de obter um melhor modelo que generalize para indivíduos que não participaram da etapa de treinamento. Isso se mostra particularmente importante para trabalhar com pessoas que não tenham a movimentação dos olhos e nenhuma forma de comunicação, o que tornaria o processo de calibração difícil de ser feito.

Além disso, destaca-se que qualquer dispositivo futuro pode vir a ser desenvolvido exclusivamente utilizando frequências acima de 25 Hz e intensidade luminosas baixas ou médias (30 – 50 lx a 1cm), não sendo vantajoso misturar frequências baixas com altas.

Em relação a pesquisa, é importante analisar se o método proposto se mostra robusto acompanhando um mesmo grupo de indivíduos ao longo do tempo, para verificar se futuras calibrações são necessárias e quanto os resultados variam conforme o dia. Nesse sentido, um algoritmo adaptativo poderia ser proposto para dispensar constantes calibrações.

Referências

- ALMEIDA, C. C. DOS S. DE. **Análise de técnicas separação cega de fontes para remoção de artefatos em interfaces cérebro-máquina.** [s.l: s.n.].
- ALTKORN, R. *et al.* Light Emitting Diode Safety and Safety Standards. [s.d.].
- BALUCH, F. Introduction to steady state visual evoked potential (ssvep). 2012.
- BEVERINA, F. *et al.* User adaptive BCIs: SSVEP and P300 based interfaces. **PsychNology Journal**, v. 1, n. 4, p. 331–354, 2003.
- BIEGER, J. **Stimulation Effects in SSVEP-Based BCIs.** [s.l.] Radboud University Nijmegen, 2010.
- BONDRE, C. Brain Computer Interfaces Using SSVEP : An Overview. v. 1, n. 2, p. 9–17, 2014.
- BREIMAN, L. Random forests. p. 1–33, 2001.
- CAO, T. *et al.* Engineering in Medicine and Biology Society Conference Flashing Color on the Performance of SSVEP-based Brain- Computer Interfaces. 2012.
- _____. Objective evaluation of fatigue by EEG spectral analysis in steady-state visual evoked potential-based brain-computer interfaces. **BioMedical Engineering OnLine**, v. 13, n. 1, p. 1–13, 2014.
- CAPILLA, A. *et al.* Steady-State Visual Evoked Potentials Can Be Explained by Temporal Superposition of Transient Event-Related Responses. v. 6, n. 1, 2011.
- CECOTTI, H.; VOLOSYAK, I.; GRÄSER, A. Reliable visual stimuli on LCD screens for SSVEP based BCI. **European Signal Processing Conference**, p. 919–923, 2010.
- CHEN, K. *et al.* A MUSIC-based method for SSVEP signal processing. **Australasian Physical {&} Engineering Sciences in Medicine**, v. 39, n. 1, p. 71–84, 2016.
- CHEN, X. *et al.* A high-ITR SSVEP-based BCI speller. **Brain-Computer Interfaces**, v. 1, n. 3–4, p. 181–191, 2 out. 2014.
- CORREA, A G. *et al.* Artifact removal from EEG signals using adaptive filters in cascade. **Journal of Physics: Conference Series**, v. 90, p. 12081, 2007.
- D. BAYLISS, J.; H. BALLARD, D. **Single Trial P300 Recognition in a Virtual Environment.** [s.l: s.n.].
- _____. **Single trial P3 epoch recognition in a virtual environment.** [s.l: s.n.]. v. 32–33
- DAWSON, W. *et al.* Local Fundus Response to Blue (LED and Laser) and Infrared (LED and Laser) Sources. **Experimental Eye Research**, v. 73, n. 1, p. 137–147, 2001.

- DIEGO, D. *et al.* Independent component analysis-based method for electroencephalogram analysis during photic stimulation. **Journal of Neuroscience Methods**, v. 235, p. 252–261, 2014.
- FERREIRA, A. L. S. *et al.* A Survey of Interactive Systems based on Brain-Computer Interfaces. **SBC Journal on Interactive Systems**, v. 4, n. 1, p. 3–13, 2013.
- GALLOWAY, N. R. Human Brain Electrophysiology: Evoked Potentials and Evoked Magnetic Fields in Science and Medicine. **The British Journal of Ophthalmology**, v. 74, n. 4, p. 255, abr. 1990.
- GLANZ, J. Mastering the Nonlinear Brain. **Science**, v. 277, n. 5333, p. 1758 LP-1760, 19 set. 1997.
- GUGER, C. *et al.* How many people could use an SSVEP BCI? **Frontiers in Neuroscience**, v. 6, n. NOV, p. 2–7, 2012.
- GUGER, C.; KRAUSZ, G.; EDLINGER, G. Brain-computer interface control with dry EEG electrodes. **Proceedings of the 5th Int. Brain–Computer Interface Conference**, p. 3–6, 2011.
- HAKVOORT, G.; REUDERINK, B.; OBBINK, M. Comparison of PSDA and CCA detection methods in a SSVEP-based BCI-system. n. TR-CTIT-11-03, 2011.
- HERRMANN, C. S. Human EEG responses to 1 – 100 Hz flicker : resonance phenomena in visual cortex and their potential correlation to cognitive phenomena. v. 1, p. 346–353, 2001.
- HORKI, P.; NEUPER, C.; MÜLLER-PUTZ, G. Identifying “resonance” frequencies for SSVEP-BCI. **Ijbem.Org**, v. 13, n. 2, p. 76–77, 2011.
- HUANG, G. *et al.* Window function for EEG power density estimation and its application in SSVEP based BCIs. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 7102 LNAI, n. PART 2, p. 135–144, 2011.
- HYE, M. *et al.* Clinical Neurophysiology An amplitude-modulated visual stimulation for reducing eye fatigue in SSVEP-based brain – computer interfaces. **Clinical Neurophysiology**, v. 125, n. 7, p. 1380–1391, 2014.
- ICNIRP (INTERNATIONAL COMMISSION ON NON-IONIZING RADIATION PROTECTION). **Guidlines on limits of exposure to broad-band incoherent optical radiation (0.38 to 3 um)**Health physics, 1997.
- JAMES, G. *et al.* **An introduction to Statistical Learning**. [s.l.: s.n.]. v. 7
- JUKIEWICZ, M.; CYSEWSKA-SOBUSIAK, A. Stimuli design for SSVEP-based brain

computer-interface. **International Journal of Electronics and Telecommunications**, v. 62, n. 2, p. 109–113, 2016.

KHATRI, S.; TIWARI, S.; RIZVI, N. Z. **Electronic model of human brain using verilog** International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT). **Anais...**2016

KOWALIK, Z. J.; WROBEL, A.; RYDZ, A. Why does the human brain need to be a nonlinear system? **Behavioral and Brain Sciences**, v. 19, n. 2, p. 302–303, 1996.

KWAK, N.; MU, K.; LEE, S. A convolutional neural network for steady state visual evoked potential classification under ambulatory environment. p. 1–21, 2017.

KWAK, N. S.; MÜLLER, K. R.; LEE, S. W. A convolutional neural network for steady state visual evoked potential classification under ambulatory environment. **PLoS ONE**, v. 12, n. 2, p. 1–21, 2017.

LEBEDEV, M. A.; NICOLELIS, M. A L. Brain-machine interfaces: past, present and future. **Trends in Neurosciences**, v. 29, n. 9, p. 536–546, 2006.

LEBER, M. A. G. C. AND E. L. Noise Removal from EEG Signals in Polisomnographic Records Applying Adaptive Filters in Cascade. **Adaptive Filtering Applications**, p. 173–196, 2011.

LIAO, L.-D. *et al.* Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors. **Journal of NeuroEngineering and Rehabilitation**, v. 9, n. 1, p. 5, 2012.

LIN, F. C. *et al.* SNR analysis of high-frequency steady-state visual evoked potentials from the foveal and extrafoveal regions of Human Retina. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**, p. 1810–1814, 2012.

LIN, Z. *et al.* Frequency recognition based on canonical correlation analysis for SSVEP-Based BCIs. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 6, p. 1172–1176, 2007.

LUO, A.; SULLIVAN, T. J. A user-friendly SSVEP-based brain-computer interface using a time-domain classifier. **Journal of neural engineering**, v. 7, n. 2, p. 26010, 2010.

MAKRI, D.; FARMAKI, C.; SAKKALIS, V. Visual fatigue effects on Steady State Visual Evoked Potential-based Brain Computer Interfaces f : p. 22–24, 2015.

MALMIVUO, J.; PLONSEY, R. **Bioelectromagnetism. 13. Electroencephalography**. [s.l: s.n.].

- MELINSCAK, F.; MONTESANO, L. Sample size determination for BCI studies: How many subjects and trials? **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**, v. 2016–Octob, p. 1524–1527, 2016.
- MOLINA, G. G. Detection of high-frequency steady state visual evoked potentials using phase rectified reconstruction. **European Signal Processing Conference**, 2008.
- MÜLLER-PUTZ, G. R. *et al.* Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. **Journal of neural engineering**, v. 2, n. 4, p. 123–130, 2005.
- NAKANISHI, M. *et al.* Generating visual flickers for eliciting robust steady-state visual evoked potentials at flexible frequencies using monitor refresh rate. **PLoS ONE**, v. 9, n. 6, 2014.
- _____. A Comparison Study of Canonical Correlation Analysis Based Methods for Detecting Steady-State Visual Evoked Potentials. p. 1–19, 2015.
- NAKANISHI, M.; WANG, Y.; WANG, Y. a High-Speed Brain Speller Using Steady-State. v. 24, n. 6, p. 1–19, 2014.
- NG, K. B.; BRADLEY, A. P.; CUNNINGTON, R. Effect of competing stimuli on SSVEP-based BCI. **Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS**, p. 6307–6310, 2011.
- OIKONOMOU, V. P. *et al.* Comparative evaluation of state-of-the-art algorithms for SSVEP-based BCIs. **Arxiv Statistics - Machine Learning**, n. January, p. 1–33, 2016.
- PINTO, M. A. D. S. Estudo do potencial evocado visual em regime permanente baseado em LED para interface cérebro máquina. p. 140, 2011.
- PRABHU, K. **Window Functions and Their Applications in Signal Processing**. [s.l.] CRC Press, 2013.
- SAKURADA, T. *et al.* Clinical Neurophysiology Use of high-frequency visual stimuli above the critical flicker frequency in a SSVEP-based BMI. **Clinical Neurophysiology**, v. 126, n. 10, p. 1972–1978, 2015.
- SAMENI, R.; GOUY-PAILLER, C. An iterative subspace denoising algorithm for removing electroencephalogram ocular artifacts. **Journal of Neuroscience Methods**, v. 225, p. 97–105, 2014.
- SCHOLZ, M. Approaches to analyse and interpret biological profile data. **PhD thesis, University of Potsdam, Germany**, p. 101, 2006.
- SHEN, H.; HÜPER, K.; KLEINSTEUBER, M. On FastICA algorithms and some

- generalisations. **Lecture Notes in Electrical Engineering**, v. 80 LNEE, p. 403–432, 2011.
- SMT MÜLLER, TF BASTOS FILHO, M. S. F. Implementação de uma ICC-SSVEP para o Comando de uma Cadeira de Rodas Robótica. **X SBAI – Simpósio Brasileiro de Automação Inteligente**, v. X, p. 211–216, 2011.
- STOHR, M.; KRAUS, R. **Introdução a Neurofisiologia Clínica**. [s.l.: s.n.].
- SUAREZ, L. F. Um Sistema para Brain-Computer Interface (BCI) Baseado em SSVEP. 2013.
- SUN, S. Ensemble Learning Methods for Classifying EEG Signals. *In*: HAINDL, M.; KITTLER, J.; ROLI, F. (Eds.). . **Multiple Classifier Systems: 7th International Workshop, MCS 2007, Prague, Czech Republic, May 23-25, 2007. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 113–120.
- TALLGREN, P. *et al.* Evaluation of commercially available electrodes and gels for recording of slow EEG potentials. **Clinical Neurophysiology**, v. 116, n. 4, p. 799–806, 2005.
- VOLOSAYAK, I. SSVEP-based Bremen-BCI interface--boosting information transfer rates. **Journal of neural engineering**, v. 8, n. 3, p. 36020, 2011.
- WALLSTROM, G. L. *et al.* Automatic correction of ocular artifacts in the EEG: A comparison of regression-based and component-based methods. **International Journal of Psychophysiology**, v. 53, n. 2, p. 105–119, 2004.
- WANG, Y. *et al.* A practical VEP-based brain-computer interface. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 14, n. 2, p. 234–239, 2006.
- WANG, Y.; WANG, Y. **Cognitive models of the brain** Proceedings First IEEE International Conference on Cognitive Informatics. **Anais...**2002
- WEI, C. S. *et al.* Detection of steady-state visual-evoked potential using differential canonical correlation analysis. **International IEEE/EMBS Conference on Neural Engineering, NER**, p. 57–60, 2013.
- WU, C.; LAKANY, H. Impact of Stimulus Configuration on Steady State Visual Evoked Potentials (SSVEP) Response. **2012, The Fourth International Conference on Advanced Cognitive Technologies and Applications**, n. 3, p. 77–82, 2012.
- YANG, P. *et al.* A Review of Ensemble Methods in Bioinformatics. **Current Bioinformatics**, v. 5, n. 4, p. 296–308, 2010.
- YUAN, P. *et al.* A study of the existing problems of estimating the information transfer rate in online brain-computer interfaces. **Journal of neural engineering**, v. 10, n. 2, p. 26014, 2013.

ZHANG, Y. *et al.* Multiway Canonical Correlation Analysis for Frequency Components Recognition in. **International Conference on Neural Information Processing**, p. 1–9, 2011.

____. LASSO based stimulus frequency recognition model for SSVEP BCIs. **Biomedical Signal Processing and Control**, v. 7, n. 2, p. 104–111, 2012.

____. L1-Regularized Multiway Canonical Correlation Analysis for SSVEP-Based BCI. v. 21, n. 6, p. 887–896, 2013.

ZHANG, Y. *et al.* Prediction of SSVEP-based BCI performance by the resting-state EEG network. **Journal of Neural Engineering**, v. 10, n. 6, p. 66017, 2013.

ZHANG, Y. *et al.* Frequency Recognition in SSVEP-based BCI using Multiset Canonical Correlation Analysis. **International Journal of Neural Systems**, v. 24, n. 2, 2014a.

____. **SSVEP recognition using common feature analysis in brain–computer interface.** [s.l: s.n.], v. 244

APÊNDICE

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO - TCLE

Você/Sr./Sra. está sendo convidado(a) a participar, como voluntário(a), da pesquisa intitulada **“Interface cérebro-computador utilizando sinais SSVEP: Impacto da luminosidade no desempenho e na fadiga visual”**. Meu nome é **Andrei Damian da Silva**, sou o pesquisador responsável e minha área de atuação é engenharia elétrica e de computação.

Após receber os esclarecimentos e as informações a seguir, se você aceitar fazer parte do estudo, assine ao final deste documento, que está impresso em duas vias, sendo que uma delas é sua e a outra pertence ao(à) pesquisador(a) responsável. Esclareço que em caso de recusa na participação você não será penalizado(a) de forma alguma. Mas se aceitar participar, as dúvidas *sobre a pesquisa* poderão ser esclarecidas pelo(s) pesquisador(es) responsável(is), via e-mail (andreidamian@gmail.com) e, inclusive, sob forma de ligação a cobrar, através do(s) seguinte(s) contato(s) telefônico(s): (62)3645-6144/(62)994765185. Ao persistirem as dúvidas *sobre os seus direitos* como participante desta pesquisa, você também poderá fazer contato com o **Comitê de Ética em Pesquisa** da Universidade Federal de Goiás, pelo telefone (62)3521-1215.

1. Informações Importantes sobre a Pesquisa:

Título: Interface cérebro-computador utilizando sinais SSVEP: Impacto da luminosidade no desempenho e na fadiga visual

Justificativa

Pessoas com limitações motoras severas, como é o caso dos que sofreram de esclerose lateral amiotrófica e acidente vascular cerebral, dificilmente conseguem estabelecer facilmente a comunicação, encontrando dificuldades para expressar seus desejos e necessidades. Uma das principais técnicas utilizadas para esses casos, são interfaces cérebro-computador, que são dispositivos que extraem informações do cérebro da pessoa utilizando eletrodos, e transmitem essa informação para um computador, onde será interpretado a informação.

A técnica atual mais promissora que utiliza interfaces cérebro-computador, é realizada usando alguma fonte de luz, como a tela de um computador ou led. Através da análise realizada, podemos saber para qual fonte de luz a pessoa está olhando e podemos utilizar isso para construir, dentre outras coisas, um teclado para digitação em um computador. Neste estudo, estamos utilizando led's, pois queremos investigar o impacto da luminosidade do led, tanto para uma maior eficiência quanto para um maior conforto para a pessoa.

O conforto é fundamental para que estes dispositivos tenham maior aplicação prática e possam ser integrados de forma contínua no dia a dia da pessoa. É importante que o senhor (a) saiba que a alternativa existente no mercado atualmente é utilizar câmeras de alta resolução para acompanhar o movimento dos olhos.

Porém um dos problemas é o custo elevado, além disto, nem todos conseguem utilizar corretamente. Um dispositivo de interface cérebro-computador conforme utilizado neste procedimento pode ser construído com relativamente menos recursos financeiros, porém é necessário viabilizar seu conforto e praticidade, que são os objetivos principais deste estudo.

Riscos

Para participar nesta pesquisa, o (a) senhor (a) não pode possuir epilepsia ou histórico familiar de epilepsia, pois existe uma pequena possibilidade de desencadear uma crise epiléptica. Ressaltamos também que todo o procedimento visa minimizar seu desconforto, porém devido a utilização dos eletrodos, o (a) senhor (a) pode sentir um leve desconforto na cabeça.

Caso sinta, fique a vontade para informar ao pesquisador responsável. Pode ocorrer que sintas cansaço visual devido às luzes utilizadas no experimento. Neste caso também é importante que informe ao pesquisador sobre o desconforto, sempre livre para desistir do procedimento ou realizar uma pausa para descansar.

O (a) senhor (a) será solicitado a preencher um formulário ao final da pesquisa e colocar ele respondido (ou não) de volta em um envelope e lacrar. Também será solicitado a permitir o uso da sua imagem, para que possamos avaliar o cansaço visual facilmente. Mas assim como em qualquer pesquisa envolvendo humanos, estes procedimentos podem lhe constranger, de tal forma que você é livre para não realiza-los.

Tranquilizamos o (a) senhor (a), quanto ao risco de descargas elétricas, pois o aparelho esta usando somente pilhas e o notebook utilizado estará desconectado da fonte de energia elétrica.

Benefícios

Com essa pesquisa, esperamos obter informações que tornem possível a realização prática da interface cérebro-computador descrita. Desta forma, desejamos obter informações que tornem muito mais confortáveis e práticas as experiências dos indivíduos que utilizem tais aparelhos.

Destacamos a importância destas interfaces para pessoas com limitações severas de movimento e da importância no contexto brasileiro (e mundial) que estes aparelhos tenham um custo adequado ao contexto geral da população.

Destaca-se ainda que

Enquanto durar a pesquisa, e sempre que necessário, o (a) senhor (a) será esclarecido (a) sobre cada uma das etapas do estudo telefonando ou procurando a qualquer momento do dia por e-mail ou telefone acima descrito.

O (a) senhor (a) é absolutamente livre para, a qualquer momento, desistir de participar, sem que isso lhe traga qualquer penalidade ou prejuízo. Fica claro que as informações conseguidas através da sua participação nesta pesquisa poderão contribuir para elaboração de dissertação de mestrado e/ou artigo científico, independentemente se os resultados forem positivos ou negativos.

Nós pesquisadores garantimos sua total privacidade, não sendo expostos os seus dados pessoais e/ou sua família (nome, telefone ou endereço). Quando a imagens pessoais resultantes de sua participação neste estudo, serão colhidas de forma a preservar a integridade total sua, sem risco de discriminação.

Assumimos o compromisso de trazer-lhe os resultados obtidos na pesquisa assim que o estudo for concluído e aproveitamos para informar que **sua participação nesta pesquisa é totalmente voluntária, não havendo qualquer previsão de pagamento ou gratificação financeira pela sua participação. Apesar disto, diante de eventuais danos, identificados e comprovados, decorrentes da pesquisa, o senhor (a) tem assegurado o direito a indenização.**

Esperando tê-lo informado de forma clara, rubricamos todas as páginas do presente documento que foi elaborado em duas vias sendo uma delas destinada ao senhor (a).

Os dados e instrumentos utilizados na pesquisa ficarão arquivados com o pesquisador responsável por um período de 5 (cinco) anos no endereço: “Rua do Cobre Qd 161 Lt 13 Casa 1, Goiânia” após o término da pesquisa, e depois desse tempo serão destruídos.

Consentimento da Participação da Pessoa como Sujeito da Pesquisa:

Eu,, inscrito(a) sob o RG/CPF/n.º de prontuário/n.º de matrícula, abaixo assinado, concordo em participar do estudo intitulado “Interface cérebro-computador utilizando sinais SSVEP: Impacto da luminosidade no desempenho e na fadiga visual”. Informo ter mais de 18 anos de idade, e destaco que minha participação nesta pesquisa é de caráter voluntário. Fui, ainda, devidamente informado(a) e esclarecido(a), pelo pesquisador(a) responsável Andrei Damian da Silva, sobre a pesquisa, os procedimentos e métodos nela envolvidos, assim como os possíveis riscos e benefícios decorrentes de minha participação no estudo. Foi-me garantido que posso retirar meu consentimento a qualquer momento, sem que isto leve a qualquer penalidade. Declaro, portanto, que concordo com a minha participação no projeto de pesquisa acima descrito.


Por favor, rubrique uma das opções abaixo:

- () Permito a divulgação da minha imagem/voz/opinião nos resultados publicados da pesquisa;
() Não permito a publicação da minha imagem/voz/opinião nos resultados publicados da pesquisa.

Assinatura por extenso do(a) participante

Assinatura por extenso do(a) pesquisador(a) responsável

Testemunhas em caso de uso da assinatura datiloscópica



Goiânia, de de

Instrumento de Coleta de Dados

Interface cérebro-computador utilizando sinais SSVEP: Impacto da luminosidade no desempenho e na fadiga visual

ORIENTAÇÃO PARA PREENCHIMENTO:

Esta é uma pesquisa de mestrado. Sua participação é muito importante porque o resultado deste contribuir significativamente para obtenção de um maior conforto e praticidade em interfaces cérebro-máquina.

Marque apenas 1 (uma) das opções de cada item abaixo:

1. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como foi sua experiência neste experimento:

1	2	3	4	5

2. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como você considera a sensação dos eletrodos em sua cabeça?

1	2	3	4	5

3. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como você considera as luzes emitidas pelos led's quando dispostos de forma próxima uns aos outros?

1	2	3	4	5

4. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como você considera as luzes emitidas pelos led's quando dispostos de forma separada uns aos outros?

1	2	3	4	5

5. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como você considera as luzes emitidas pelos led's com maior intensidade de luz?

1	2	3	4	5

6. Em uma escada de 1 a 5, **sendo 5 muito confortável e 1 muito desconfortável**, como você considera as luzes emitidas pelos led's com menor intensidade de luz?

1	2	3	4	5

Escreva aqui qualquer consideração final que desejar:

Os dados abaixo são preenchidos pelo pesquisador responsável, antes de realizar a entrega deste formulário para você, e não devem ser alterados.

Umidade da sala:

Temperatura da sala: