

Luisa Fernanda Suarez Uribe

DESENVOLVIMENTO DE UMA INTERFACE HOMEM-MÁQUINA
BASEADA EM POTENCIAIS EVOCADOS VISUAIS EM REGIME
ESTACIONÁRIO

Campinas
2013

Universidade Estadual de Campinas
Faculdade de Engenharia Elétrica e de Computação

Luisa Fernanda Suarez Uribe

DESENVOLVIMENTO DE UMA INTERFACE HOMEM-MÁQUINA BASEADA EM POTENCIAIS
EVOCADOS VISUAIS EM REGIME ESTACIONÁRIO

Dissertação de mestrado apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestra em Engenharia Elétrica. Área de concentração: Engenharia de Computação.

Orientador: Prof. Dr. Eleri Cardozo
Co-orientador: Prof. Dr. Diogo Coutinho Soriano

Este exemplar corresponde à versão final da dissertação defendida pela aluna Luisa Fernanda Suarez Uribe, e orientada pelo Prof. Dr. Eleri Cardozo

Campinas
2013

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Elizangela Aparecida dos Santos Souza - CRB 8/8098

Su12d Suarez Uribe, Luisa Fernanda, 1985-
Desenvolvimento de uma interface homem-máquina baseada em potenciais evocados em regime estacionário / Luisa Fernanda Suarez Uribe. – Campinas, SP : [s.n.], 2013.

Orientador: Eleri Cardozo.
Coorientador: Diogo Coutinho Soriano.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Interação homem-máquina. 2. Interface (Computador). 3. Potenciais evocados. 4. Processamento de sinais - Análise espectral. 5. Sistemas de reconhecimento de padrões. I. Cardozo, Eleri, 1954-. II. Soriano, Diogo Coutinho. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Development of a human-machine interface based on steady state visual evoked potentials

Palavras-chave em inglês:

Man-machine interaction

Interface (Computer)

Evoked potentials

Signal processing - Spectral analysis

Pattern recognition systems

Área de concentração: Engenharia de Computação

Titulação: Mestra em Engenharia Elétrica

Banca examinadora:

Eleri Cardozo [Orientador]

Ricardo Suyama

Romis Ribeiro de Faissol Attux

Data de defesa: 29-11-2013

Programa de Pós-Graduação: Engenharia Elétrica


COMISSÃO JULGADORA - TESE DE MESTRADO

Candidata: Luisa Fernanda Suárez Uribe


Data da Defesa: 29 de novembro de 2013

Título da Tese: "Desenvolvimento de uma Interface Homem-Máquina Baseada em Potenciais Evocados Visuais em Regime Estacionário"


Prof. Dr. Eleri Cardozo (Presidente):



Prof. Dr. Ricardo Suyama:



Prof. Dr. Romis Ribeiro de Faissol Attux:



Resumo

Os potenciais evocados visuais de estado em regime permanente (SSVEP) são uma resposta cerebral medida na captura de sinais cerebrais através de Eletroencefalograma (EEG), usando-se uma touca com eletrodos posicionados no escalpo mediante estimulação visual externa. Um sistema que detecta a resposta SSVEP gerada em um sujeito estimulado com fontes de luz (LEDs) piscando a frequências diferentes foi desenvolvido nesta tese com o intuito de desenvolver uma interface homem-máquina. Para tanto, foram usados quatro estímulos visuais codificando quatro possíveis comandos, mais o estado de repouso, a serem classificados e identificados a partir da resposta observada no EEG e da devida análise espectral deste sinal.

As características que determinam se a resposta SSVEP está presente foram estudadas através de diferentes heurísticas para a seleção de descritores (coeficientes associados à densidade espectral de potência), os quais foram posteriormente passados para um classificador linear para a determinação do comando associado ao estímulo.

Para a seleção de características, o índice Davies Bouldin (DB) foi utilizado. No que concerne a análise de frequência realizada para os três sujeitos estudados, foi possível observar a presença da resposta SSVEP nas frequências de estimulação, mas, tal como esperado, com forte presença de ruído e com grande variabilidade entre os sujeitos. Apesar da variabilidade das características selecionadas pela estratégia adotada, obtiveram-se aqui resultados de classificação próximos a 90% de acerto para cada classe. Estes resultados de classificação indicaram que esta metodologia de processamento pode ser usada num sistema de BCI em tempo real, dado que o atual sistema foi projetado para operar somente com dados que foram gravados offline.

Palavras-chave: Interface cérebro computador. Potenciais evocados visuais de regime estacionário. Densidade espectral de potência. Extração de características. Índice Davies Bouldin. Classificação. Análise de discriminante lineal.

Abstract

Steady-State Visual Evoked Potential (SSVEP) is a brain response measured by capturing brain signals generated by external visual stimulation, through electroencephalogram (EEG), using a cap with electrodes placed on the scalp. A system for detection of the SSVEP response generated by a subject stimulated with light sources (LEDs) flashing at different frequencies has been developed in this dissertation in order to implement a human-machine interface. We used four visual stimuli encoding four possible commands, besides idle state, to be classified and identified from the response observed in the EEG through the spectral analysis of this signal.

The characteristics that determine if a SSVEP response is present were studied through different heuristics for selecting descriptors (coefficients associated with power spectral density), which were then passed to a linear classifier for the determination of the stimulus associated with the command.

The Davies-Bouldin (DB) index was the method used for the selection of features. From the frequency analysis carried out for three subjects, was observed the presence of SSVEP response on the stimulation frequencies, but, in some cases, as expected, it was blurred by noise, which differs among individuals. Despite the variability of the features selected by the adopted strategy, classification results with accuracy nearly 90% were obtained for each class. These classification results indicated that this processing methodology could be used in a BCI system in real time, as the current system was designed to operate only with data recorded offline.

Key-words: BCI - Brain-Computer Interface. EEG - Electroencephalogram. SSVEP - Steady-State Visual Evoked Potential. Power Spectral Density. Feature extraction. Davies Bouldin index. Linear Discriminant Analysis.

Sumário

1	Introdução	1
1.1	Sistema BCI Generalizado	3
1.1.1	Aquisição de sinal	3
1.1.2	Processamento e tradução	5
1.1.3	Realimentação e / ou saída	8
1.1.4	Protocolo operacional / estímulo	9
1.2	Objetivos da dissertação	11
2	BCI e Potenciais Evocados Visuais de Estado Estacionário	13
2.1	Estímulos visuais e SSVEP	14
2.2	Aplicações dos sistemas SSVEP-BCI	15
2.3	Processamento de sinal nos sistemas SSVEP-BCI	16
3	Métodos e Materiais	19
3.1	O sistema SSVEP-BCI	19
3.2	Descrição e construção do sistema SSVEP-BCI	21
3.2.1	Usuário BCI	21
3.2.2	Transdutor BCI	22
3.2.3	Dispositivos de saída	23
3.3	Processamento de Sinal SSVEP	23
3.3.1	Resposta e modelagem SSVEP	24
3.3.2	Pré-processamento	25
3.3.3	Extração de características	26
3.3.4	Seleção de características	28
3.3.5	Classificação	30
3.4	Sujeitos e aquisição dos dados	33
3.5	Protocolo e aquisição de sinais	34
3.6	Teste do sistema BCI	35
4	Resultados	37
4.1	Análise Espectral	37
4.2	Seleção de atributos nas frequências de estimulação sem seleção de eletrodos	48
4.3	Seleção de atributos usando a seleção de eletrodo pelo valor do índice DB	49
4.4	Livre escolha dos atributos segundo os valores do índice DB_{inv}	54

4.5	Considerações finais	57
5	Conclusões e Perspectivas	60
	Bibliografia	62

O cérebro humano é, então, a organização mais complexa da matéria que conhecemos

Isaac Asimov

Agradecimentos

Agradeço,

à minha família. Seu apoio, força e orientação me ajudaram e me encorajaram sempre que eu precisei. São muito importantes para mim meus pais, meus irmãos e meus tios.

à minha segunda família aqui no Brasil, meus amigos. Conhecê-los tem sido uma alegria na minha vida: Diana, Cesar, e os muitos amigos da minha república. Sou grata também às pessoas que vim a conhecer aqui e tem me acompanhado neste tempo com sua amizade, bem como os amigos que sempre na distancia me acompanharam.

à UNICAMP e ao pessoal muito importante que conheci neste lugar: meu orientador, Prof. Eleri, meu coorientador, Diogo Soriano, a equipe do projeto Destine, e os colegas do laboratório. Agradeço a todos a troca de experiências e conhecimentos.

aos membros da banca examinadora pelos comentários, sugestões e contribuições, que me ajudaram a melhorar a qualidade e a redação final desta dissertação.

à CAPES pelo apoio financeiro concedido durante o período de mestrado.

a todos que de alguma forma contribuíram com o meu progresso como aluna e como Ser.

Lista de Figuras

1.1	Modelo funcional de um sistema BCI. Fonte: Adaptada de Zhu et al. (2010). . .	3
1.2	Colocação dos eletrodos para aquisição do eletroencefalograma, de acordo com o Sistema Internacional de Posicionamento 10-20.	5
1.3	Estágios do processamento e tradução em um sistema BCI.	6
1.4	Estímulo e resposta para P300 Speller.	10
1.5	Áreas sensório-motoras: as zonas sensoriais são ilustrados por um “homúnculo sensorial”, indicando quais regiões são atribuídas para processar informações sensoriais a partir das respectivas partes do corpo.	11
2.1	Típicas formas de onda com deflexões VEP positivas (Pi) e negativas (Ni). Fonte: Adaptada de Ng et al.(2012).	14
2.2	Estímulos gráficos para SSVEP (a) Em estímulos gráficos simples o objeto gráfico aparece alternadamente no fundo. (b) Em estímulos de padrão de reversão pelo menos dois padrões são alternados em uma frequência especificada. Fonte: Adaptada de Zhu et al.(2010).	15
2.3	(a)Formas de onda para estímulos visuais em sistemas SSVEP-BCI. (b) Espectro de intensidade para uma resposta evocada por um estímulo visual em 10 Hz. Fonte: Adaptada de Bin et al.(2009).	16
3.1	Sistema BCI generalizado.	19
3.2	Montagem dos LEDs para os experimentos realizados.	20
3.3	Diagrama de blocos do sistema BCI.	20
3.4	Apresentação e captura de dados para estimulação do sistema SSVEP-BCI construído.	22
3.5	Placa para controle e configuração dos estímulos visuais no sistema SSVEP-BCI.	24
3.6	Equipamento e configuração para captura de EEG.	33
3.7	Tempos do protocolo para aquisição de dados. Fonte: Adaptado de DALbis (2008).	35
4.1	Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.	39
4.2	Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.	40

4.3	Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.	41
4.4	Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.	42
4.5	Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.	43
4.6	Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.	44
4.7	Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.	45
4.8	Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.	46
4.9	Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.	47
4.10	Diagrama do blocos do transdutor BCI.	48
4.11	Mapa de coeficientes DB_{inv} para sujeito J.	51
4.12	Mapa de coeficientes DB_{inv} para sujeito L.	51
4.13	Mapa de coeficientes DB_{inv} para sujeito P.	52
4.14	Desempenho de erro de classificação para as diferentes estratégias de seleção de atributos. a) Sujeito J, b) Sujeito L, c) Sujeito P.	56
4.15	Desempenho de porcentagem de acerto de classificação para as diferentes estratégias de seleção de atributos. a) Para vetor de atributos com N=16. b) Para vetor de atributos com os melhores resultados.	58

Lista de Tabelas

1.1	Comparação de técnicas para medir a atividade cerebral em BCI.	4
4.1	Desempenho geral do erro de classificação - Método 1.	50
4.2	Desempenho geral do erro de classificação - Método 2.	53
4.3	Desempenho geral do erro de classificação - Método 3.	55
4.4	Comparação do número de atributos necessários em cada uma das técnicas usadas e dos sujeitos participantes para um erro de classificação de 10%.	57

Lista de Acrônimos e Notação

AAC	Augmentative and Alternative Communication (Comunicação suplementar e alternativa)
ALS	Amyotrophic Lateral Sclerosis
AT	Assistive Technology (Tecnologia assistiva)
BCI	Brain Computer Interface (Interface cérebro computador)
BSS	Blind Source Separation
CAR	Common Average Reference
CCA	Canonical Correlation Analysis
CSP	Common Spatial Pattern
DB	Davies Bouldin
ECoG	Electrocorticography
EEG	Electroencephalogram (Eletroencefalograma)
EMG	Electromyography
ERP	Event Related Potentials
FFT	Fast Fourier Transform (Transformada Rápida de Fourier)
HMM	Hidden Markov Model
ICA	Independent Component Analysis
ITR	Information Transfer Rate (Taxa de transferência de informações)
KNN	K-nearest neighbor algorithm
LDA	Linear Discriminant Analysis (Análise de discriminante lineal)
MCC	Maximum Contrast Combination
MEC	Minimum Energy Combination
PCA	Principal Component Analysis
PSD	Power Spectral Density (Densidade espectral de potência)
QDA	Quadratic Discriminant Analysis
SCI	Spinal Cord Injury
SCP	Slow Cortical Potential
SMR	Sensory-Motor Rhythms
SNR	Signal-to-Noise Ratio
SSVEP	Stady State Visual Evoked Potential (Potenciais evocados visuais de estado estacionário)
SVM	Support Vector Machine
VEP	Visual Evoked Potential

Introdução

Criar um canal de comunicação alternativo entre o cérebro e uma máquina sem recorrer às saídas convencionais do corpo humano, tais como a fala e o movimento muscular, é o principal objetivo da área de pesquisa conhecida como interface cérebro computador (do inglês *Brain - Computer Interface*, BCI). Esses sistemas definem um importante paradigma de tecnologia assistiva, possibilitando que pessoas com grave deficiência motora (tal como ocorre na esclerose lateral amiotrófica ou mesmo pós-acidente vascular cerebral) se comuniquem com o mundo exterior.

Um sistema BCI permite que, através do reconhecimento de determinados padrões de atividade elétrica do cérebro, estes possam ser interpretados e dar origem a comandos para o controle de dispositivos externos, tais como cadeiras de rodas, braços robóticos, teclados, entre outros (Millán et al. 2010).

De fato, muitas pessoas são incapazes de interagir de forma eficaz, ou mesmo operar dispositivos assistivos devido a deficiências e incapacidades funcionais. Em geral, o tipo de doenças neuromusculares degenerativas se caracterizam por uma perda da atividade muscular sem comprometer as funções cognitivas. Indivíduos no estado conhecido como *locked-in* estão conscientes e podem pensar e raciocinar, mas são incapazes de falar ou mover-se, possuindo apenas o movimento dos olhos.

Só na Europa, um número estimado de 300 mil pessoas sofrem de uma lesão da medula espinal (Spinal Cord Injury SCI), com 11.000 novas lesões por ano (Sobani et al. 2010). Quarenta por cento da população total dos pacientes com SCI são tetraplégicos. A perda das funções motoras leva a uma vida de dependência e a uma diminuição drástica da qualidade de vida (Wolpaw et al. 2002).

A *Charity Communication Matters*¹ publicou dois importantes relatórios sobre Comunicação Suplementar e Alternativa (Augmentative and Alternative Communication -AAC), reportando que 3 mil pessoas em todo o Reino Unido podem estar vivendo sem acesso a um auxílio efetivo de comunicação e quase um terço de um milhão de pessoas, 300 mil em todo o Reino Unido estão se beneficiando ou podem se beneficiar de algum apoio de AAC. Nestes casos, a qualidade de vida destes indivíduos poderia ser significativamente melhorada com o desenvolvimento de

¹A Charity Communication Matters é o órgão do Reino Unido da Sociedade Internacional para a Comunicação Suplementar e Alternativa (ISAAC).

dispositivos assistivos adequados, proporcionando-lhes um meio prático e confiável para retornar parcialmente suas habilidades perdidas.

A AAC é uma área da prática clínica que tenta compensar temporária ou permanentemente as dificuldades de indivíduos com distúrbios de comunicação graves devido a deficiências e incapacidades. O termo “suplementar” refere-se ao processo de aumentar as capacidades de comunicação existentes, enquanto o termo alternativo refere-se ao processo de proporcionar uma via alternativa (Glennen & DeCoste 1997). Neste sentido, tarefas de comunicação podem incluir qualquer tipo de interação com o mundo exterior, não só em relação à comunicação com palavras. Assim, a AAC trabalha em duas linhas principais: a) estabelecimento de um canal de informação eficiente e confiável do paciente com o mundo exterior. b) encontrar a melhor forma de explorar este canal (que normalmente é ruidoso, ineficiente e pouco confiável).

Dependendo do nível de profundidade no dano das habilidades motoras do indivíduo vários dispositivos estão disponíveis para recuperar, ao menos em parte, a capacidade de interação da pessoa com o ambiente. Em geral, não existe, uma abordagem ou equipamento único, sendo as características dos sinais de saída e a complexidade dos sistemas empregados muito diferentes, o que depende das capacidades residuais reais do paciente.

Para os pacientes que retêm a capacidade de mover parcialmente as mãos ou ao menos um dedo, teclados especiais estão disponíveis no mercado (Millán et al. 2010), mas, em geral, teclados, mouse e outras interfaces que requerem um maior controle muscular não podem ser usados diretamente por este tipo de pacientes. Sistemas alternativos para usuários com um maior nível de deficiência baseiam-se em movimentos oculares voluntários, tais como o realizado ao focar o olhar num objeto. Nestes casos, os sinais de eletromiografia (EMG) e da respiração também podem ser utilizados (Barreto et al. 2000).

Entre alguns exemplos de software para PC utilizando operações de seleção para pacientes com deficiência motora profunda temos: a) “Tonguepoint”. Esse sistema consiste em um *joystick* isométrico sensível a pressão fixado a um bocal de modo que possa ser operado pela língua de um usuário. b) Headmouse, o qual consiste em um “*mouse*” baseado no movimento de um dispositivo apontador que transforma movimentos da cabeça em movimento num cursor na tela. Isto é feito por meio de um sensor óptico que rastreia um pequeno alvo com adesivo situado na testa ou nos óculos de um usuário.

Por fim, o sinal cerebral também pode ser usado com este fim. A ideia central aqui seria que um usuário de um sistema BCI teria apenas de “pensar” ou imaginar o movimento definindo algum estado cerebral específico para controlar algum dispositivo externo.

Cada aplicação e cada perspectiva de desenvolvimento para o BCI tem focado em diferentes métodos para construir e melhorar os sistemas atuais. A ênfase tem sido dada, principalmente, na melhoria da capacidade de controle e precisão. Os atuais aplicativos projetados para BCI são capazes de levar em consideração as diferenças individuais, otimizando a interface com o usuário ao incorporar técnicas de inteligência artificial, dentre outras estratégias. A utilização de tais técnicas já provou ser útil para estes sistemas, tal como, por exemplo, o uso comum das estratégias de reconhecimento de padrões, classificação de dados e navegação inteligente de ambientes (Cincotti et al. 2008). Algumas dessas técnicas foram estudadas neste trabalho de pesquisa procurando efetivamente atender às expectativas atuais nesta área.

A seguir apresenta-se uma visão mais aprofundada dos sistemas BCI, os paradigmas mais utilizados e um pouco do estado da arte da pesquisa. Finalmente, define-se os principais objetivos deste trabalho bem como a sua estrutura de desenvolvimento.

1.1 Sistema BCI Generalizado

A definição do termo BCI data de 1999, durante a primeira reunião internacional sobre investigação e desenvolvimento de BCI (Wolpaw et al. 2000). Nesta, tem-se: “A interface cérebro-computador é um sistema de comunicação que não depende da saída normal do cérebro para os nervos periféricos e músculos”. Assim, as medidas diretas de atividade cerebral são traduzidas em mensagens ou comandos, permitindo que os usuários se comuniquem sem o uso dos referentes biológicos clássicos. Sistemas BCI foram desenvolvidos inicialmente no âmbito acadêmico, tentando fornecer meios de comunicação para as pessoas com severa deficiência motora (Wolpaw et al. 2002).

A pesquisa em BCI baseia-se no desenvolvimento de sistemas que podem fornecer meios de comunicação e controle através da aquisição de informações diretamente do cérebro e usá-las para executar ações operadas por um usuário. Trata-se de um sistema em malha fechada em tempo real que usualmente conta com uma realimentação para o usuário. Wolpaw et al. (2002) descreve os quatro componentes principais de qualquer sistema BCI: aquisição de sinal, processamento de sinal, realimentação/saída e estímulo/protocolo operacional, tal como ilustrado na figura 1.1 e comentado a seguir.




Figura 1.1: Modelo funcional de um sistema BCI. Fonte: Adaptada de Zhu et al. (2010).

1.1.1 Aquisição de sinal

No contexto de BCI, um sinal relacionado com a atividade neuronal cerebral pode ser registrado por meio de diferentes técnicas, diferentes resoluções espaciais e temporais, e de forma invasiva ou não invasiva.

Os sistemas BCI invasivos registram a atividade cerebral por meio de microeletrodos implantados na superfície cortical (eletrocorticografia, ECoG) ou de dentro do córtex. Por sua vez, BCIs não-invasivos usam sinais cerebrais registrados na superfície do escalpo. Apesar das grandes vantagens em termos de qualidade de sinal dos métodos invasivos frente aos não-invasivos, os primeiros requerem cirurgias delicadas e arriscadas.

Atualmente, quase todas as comunicações não-invasivas de BCI baseiam-se no EEG para medir a atividade cerebral (mais de 80% das publicações em BCI usam sinais elétricos gravados no escalpo (Mason et al. 2007)). A tabela 1.1 apresenta uma comparação das diferentes técnicas de medição de atividade cerebral.

Tabela 1.1: Comparação de técnicas para medir a atividade cerebral em BCI.

Método	Quantidade medida	Invasivo	Resolução espacial	Resolução temporal	Equipamento portátil
EEG	Pot. Elétrico	Não	-	++	Sim
ECoG	Pot. Elétrico	Sim	+	++	Sim
Micro-eletrodos	Pot. Elétrico	Sim	++	++	Sim
MEG	Campo magnético	Não	+	++	Não
fMRI	Nível de oxigênio no sangue	Não	++	-	Não
NIRS	Nível de oxigênio no sangue	Não	+	+	Sim

A atividade medida pelo EEG está associada aos potenciais elétricos induzidos pelas correntes pós-sinápticas, após a passagem do potencial de ação. Portanto, potenciais elétricos medidos no escalpo que produzem o EEG são devidos às correntes iônicas extracelulares (Teplan 2002). No entanto, a disposição dos eletrodos no EEG é incapaz de cobrir ou registrar de forma adequada as múltiplas fontes elétricas que formam a atividade cerebral, o que implica em uma baixa resolução espacial com o agravante da atenuação do sinal gerado pelo próprio crânio.

Observe-se ainda que existe uma nomenclatura padrão para o esquema de posicionamento para EEG, o chamado sistema internacional 10-20. Este é baseado em uma subdivisão de arcos iterativa no escalpo a partir de quatro pontos de referência craniométricos: nasion (NS),inion (IN) e os pontos pré-auriculares de esquerda (PAL) e direita (PAR) (ver figura 1.2 ²). No sistema internacional 10-20 diferentes eletrodos são colocados a uma distância fixa a partir desses pontos. O nome de “10-20” refere-se ao fato das distâncias reais entre os eletrodos adjacentes serem de 10% ou 20% do total das distâncias NS-IS ou das distâncias PAL-PAR.

²Fonte: <http://neuroengenharia-proc-bio.blogspot.com.br/>.




Figura 1.2: Colocação dos eletrodos para aquisição do eletroencefalograma, de acordo com o Sistema Internacional de Posicionamento 10-20.

Cada eletrodo tem uma letra para identificar o lóbulo e um número de identificação da localização do hemisfério. As letras F, T, C, P e O representam frontal, temporal, central, parietal e occipital, respectivamente. Um “z” (zero) refere-se a um eletrodo colocado na linha média. Números pares (2,4,6,8) referem-se a posições de eletrodos no hemisfério direito, enquanto que números ímpares (1,3,5,7) referem-se aqueles no hemisfério esquerdo. Por exemplo, os eletrodos C3 e C4, são colocados na parte central do córtex (C), respectivamente, no hemisfério direito (4) e esquerdo (3).

1.1.2 Processamento e tradução

O processamento de sinais e a tradução da série temporal registrada em um comando é o componente fundamental de qualquer sistema BCI. Seu objetivo é converter sinais gravados a partir do cérebro em um sinal de controle adequado para um dispositivo externo. Diferentes etapas são executadas como parte do processamento de sinal, tais como: filtragem, extração de características, seleção de características, classificação e tradução. A figura 1.3 apresenta os diferentes estágios de processamento mencionados e algumas das características de cada um deles.




Figura 1.3: Estágios do processamento e tradução em um sistema BCI.

A primeira etapa de pré-processamento do sinal inclui, geralmente, a redução de artefatos. Estes podem aparecer devido ao ruído introduzido pelo equipamento de gravação, outras fontes de origem biológica, ou devido a mudanças na impedância do eletrodo. Os artefatos fisiológicos são causados por uma série de processos biológicos, tal como: o movimento ocular (EOG) causado pelo piscar de olhos e movimentos da pupila e os artefatos musculares gerados com o movimento de qualquer parte do corpo, incluindo músculos da face, mandíbula e língua. Os artefatos podem ser manipulados no sentido de serem evitados ou removidos. No primeiro caso, os segmentos de EEG corrompidos são identificados e rejeitados. A maneira mais simples de fazer isso é gravar a atividade EOG e EMG diretamente e simultaneamente ao registro de EEG. Uma opção consiste na rejeição do sinal de EEG na janela de tempo em que ocorre o artefato, o que é feito principalmente para análises off-line. É possível também tentar manter os fenômenos neurológicos interessantes intactos usando outras estratégias, tal como filtragem temporal, regressão e separação cega de fontes (do inglês *Blind Source Separation*, BSS) (Schlogl et al. 2007), (Fabiani et al. 2004).

Como foi mencionado anteriormente, o sinal de EEG tem uma baixa resolução espacial, sendo que já foi mostrado que apenas a metade da contribuição de um eletrodo do escalpo provém de fontes dentro de um raio de 3 centímetros. Uma maneira de melhorar a qualidade do sinal é a filtragem espacial. Há um certo número de filtros espaciais disponíveis na literatura, sendo que a maior parte deles aplica uma transformação linear para obter o sinal EEG, recalculando a contribuição de cada canal em um eletrodo específico (Dornhege et al. 2007). Alguns filtros espaciais, como a referência de média comum (do inglês *Common Average Reference*, CAR) ou filtros laplacianos, preservam o número original de canais e produzem sinais de saída que ainda estão relacionados com sua fonte de origem, outros filtros perdem esta referência direta. Exemplos destes são dados pela análise de componentes principais (do inglês *Principal Component Analysis*, PCA), análise de componentes independentes (do inglês *Independent Component Analysis*, ICA) e padrões espaciais comuns (do inglês *Common Spatial Patterns*, CSP). Esta

segunda classe de filtros é normalmente utilizada quando os canais de saída são projetados para ser usados como características discriminativas.

Posterior ao pré-processamento pode se realizar a extração de características. Para discriminar as intenções do usuário a partir de sua atividade cerebral, as características relevantes precisam ser extraídas do EEG de modo que os fenômenos neurofisiológicos subjacentes possam ser identificados e traduzidos sucessivamente em sinais de controle. Os algoritmos de extração de atributos adequados para BCIs estão baseados em um conhecimento a priori sobre as características dos fenômenos neurofisiológicos normalmente explorados. Estas características podem ser extraídas no domínio do tempo, da frequência ou do espaço (Ramoser et al. 2000), (Fabiani et al. 2004), (Grosse-Wentrup & Buss 2008).

As características extraídas no domínio do tempo relacionam a amplitude do sinal de EEG com variações no tempo ligadas a apresentação de estímulos. Características no domínio do tempo são normalmente utilizadas quando os fenômenos neurofisiológicos subjacentes baseiam-se em potenciais relacionados a eventos (como P300), já que normalmente ocorrem dentro de janelas de tempo precisas após a apresentação de um estímulo.

Características no domínio da frequência são relacionadas com alterações na atividade oscilatória do sinal EEG. Tais alterações podem ser geradas por um estímulo externo, ou autoinduzidas pelo usuário ao concentrar-se numa tarefa mental específica. Características no domínio da frequência são empregados principalmente em sistemas BCI baseados em imaginação motora e SSVEP.

Os atributos no domínio espacial combinam a informação proveniente de diferentes canais de EEG, a fim de identificar padrões na atividade cerebral relacionada a diferentes fenômenos neurofisiológicos. Como já mencionado, várias técnicas de filtragem espacial são empregadas para este propósito, entre as mais comuns estão PCA, ICA e CSP. Como as características de frequência, as características espaciais têm sido amplamente usadas por ser provadas como uma boa estratégia para melhorar a qualidade da informação discriminativa do sinal.

Finalmente, na cadeia de tarefas executadas no processamento está o bloco encarregado de traduzir a atividade cerebral em sinais de controle, onde duas abordagens principais podem ser usadas: a regressão e a classificação. Na regressão as características do sinal de EEG são avaliadas em tempo real e usadas para gerar um sinal de controle contínuo.

A classificação é uma abordagem mais popular na pesquisa de BCI. Algoritmos de classificação adotam técnicas comumente utilizadas para reconhecimento de padrões e aprendizado de máquina. Um grande número de algoritmos de classificação têm sido usados em sistemas de BCI (Dornhege et al. 2007). Estes podem ser classificados em métodos baseados em memória, funções de discriminantes e modelos dinâmicos. Um exemplo de um método baseado em memória é k-vizinhos mais próximos (do inglês *k-nearest neighbor*, KNN). Funções discriminantes são classificadores baseados em modelos lineares, quadráticos e outros. Modelos lineares incluem análise de discriminante linear (do inglês *Linear Discriminant Analysis*, LDA) e máquinas de vetores suporte (do inglês *Support Vector Machine*, SVM), onde se assume classes linearmente separáveis. Limites de classe quadrática são empregados por análise discriminante quadrática (do inglês *Quadratic Discriminant Analysis*, QDA), enquanto que limites não-lineares são usados pelas redes neurais artificiais (do inglês *Artificial Neural Network*, ANN) e métodos de kernel

(do inglês *Kernel Methods*, KM). Finalmente, os modelos dinâmicos assumem que o sistema que está sendo considerado evolui no tempo e que o seu comportamento pode ser modelado através de um conjunto de estados, tais que descritos pelas cadeias de Markov (do inglês *Hidden Markov model*, HMM), Filtros de Kalman e modelos auto-regressivos. O trabalho de revisão de (Bashashati et al. 2007) menciona uma serie de trabalhos de BCI que tem utilizado estas técnicas.

1.1.3 Realimentação e / ou saída

Dependendo do tipo de sistema BCI, este pode ter uma realimentação e / ou um módulo de estimulação. Quando a atividade do cérebro é produzida por modulações autoinduzidas, a realimentação muitas vezes é fornecida para auxiliar o usuário em sua tarefa, obtendo-se desta forma um controle em laço fechado. Quando os fenômenos neurofisiológicos de interesse são derivados de eventos externos, é necessário um módulo de estimulação.

Além disso, a adaptação é um conceito que precisa ser considerado para os sistemas BCI. Dois tipos diferentes de adaptação existem: a adaptação do usuário em relação à máquina e a adaptação da máquina em relação ao usuário. No primeiro caso, o sujeito aprende a regular as atividades específicas do cérebro por meio de um sinal de realimentação que é fornecido em tempo real pelo sistema de BCI. A realimentação fornece informações contínuas sobre a alteração das atividades cerebrais, permitindo, assim, um processo de treinamento consciente ou inconsciente do usuário (Perrin et al. 2010). A abordagem de adaptação da máquina consiste na parametrização para cada usuário do algoritmo de aprendizagem (bloco de processamento de sinais).

O uso da realimentação é ainda um tópico de intenso estudo em BCI, já que tem sido observado que o usuário é significativamente afetado por este processo para mudar sua estratégia mental de realização da tarefa, e obviamente no caso de realimentação errada o processo de aprendizagem seria fortemente afetado. A melhor forma de lidar corretamente com este complexo problema de co-adaptação ainda é uma questão aberta no campo da pesquisa BCI (Guger et al. 2001).

Considerando os paradigmas de controle BCI estes definem a forma como os usuários podem interagir com os respectivos sistemas. Neste caso, há basicamente três maneiras diferentes de realizar essa interação. O controle assíncrono que é definido quando o usuário aciona a interação com o sistema BCI que está continuamente disponível. Portanto, períodos de controle intencional alternam com períodos de nenhum controle (estado de repouso), sendo estes intervalos impostos pelo próprio sujeito (self-paced). Durante o estado de repouso o sistema deverá manter-se inalterado em espera para o usuário possa iniciar um novo controle intencional. Já no controle sincronizado, se o usuário não responde em fase com o estímulo durante a execução, tem-se uma ação autônoma do dispositivo, o que se confirma como uma ação indesejada (provavelmente causada por uma classificação aleatória). Em um sistema de controle de ritmo, em vez disso, o usuário pode decidir quando iniciar e parar o controle intencional dentro das janelas de tempo em que o sistema está disponível. O sistema de controle de ritmo pode também ser considerado como um controle assíncrono em que o sistema se torna completamente disponível em janelas de tempo específicas. Esta abordagem é claramente melhor em comparação que

o controle síncrono, mas requer que o sistema BCI possa identificar as transições de controle intencional para estado de repouso e vice-versa.

A seguir a presente dissertação dedica-se a detalhar os paradigmas de controle de BCI.

1.1.4 Protocolo operacional / estímulo

Diferentes fenômenos neurofisiológicos podem ser explorados para extrair informações a partir de sinais de EEG do escalpo. Em alguns casos, estes fenômenos são gerados conscientemente pelo usuário (sistema endógeno), em outros casos, existe um mecanismo inconsciente, isto é em resposta a um estímulo externo (sistema exógeno). BCIs exógenos são baseados em potenciais relacionados a eventos (Event Related Potentials - ERP), enquanto as principais BCIs endógenos são baseados em potenciais corticais lentos (do inglês *Slow Cortical Potentials*, SCP) e ritmos sensório-motores (do inglês *Sensory-Motor Rhythms*, SMR). Nos parágrafos seguintes, estas três classes de fenômenos neurofisiológicos são brevemente expostos.

Potenciais relacionados a eventos (ERP) Potenciais relacionados a eventos são potenciais eletrocorticais que podem ser medidos no sinal EEG antes, durante ou depois de um determinado evento. Eles possuem um tempo de atraso fixo em relação ao estímulo que o evoca e a sua amplitude é geralmente muito menor do que a atividade de EEG espontânea. Esses ERP podem ser detectados pela média de muitas gravações relacionadas ao evento. Este cálculo da média anula a atividade de fundo que não está sincronizada com o estímulo. Existem diferentes tipos de ERPs, sendo os mais comumente utilizados os potenciais evocados visuais de estado estacionário (SSVEP) e o P300.

O P300 é uma deflexão positiva no EEG que ocorre cerca de 300 ms após a apresentação de estímulos ou tarefas relevantes ou surpreendentes. Para evocar o P300, os indivíduos devem observar uma sequência aleatória de dois tipos de estímulos. Um tipo de estímulo (o estímulo raro) só aparece raramente na sequência, enquanto o outro tipo de estímulo (o estímulo normal) aparece com mais frequência. Sempre que o estímulo alvo aparecer, uma resposta P300 pode ser observada no EEG. Os sujeitos devem estar atentos aos estímulos, quanto maior atenção, maior a amplitude do potencial P300 evocado. Uma aplicação típica consiste em um *speller* em que uma matriz contendo os símbolos do alfabeto é exibido em uma tela. Linhas e colunas da matriz brilham em ordem aleatória, os flashes da linha ou coluna que contém o símbolo desejado constituem o estímulo raro, enquanto todos os outros flashes constituem estímulos normais (Rivet et al. 2009). A figura 1.4 ³ apresenta o estímulo e a resposta obtida quando usado o paradigma P300 e a aplicação P300 Speller. O sinal apresentado na figura mostra a resposta P300 aparecendo no tempo, e a região do cérebro onde é mais notável esta resposta.

³Fonte:<http://i1.ytimg.com/vi/wKDimrzvWYA/hqdefault.jpg>.



Figura 1.4: Estímulo e resposta para P300 Speller.

As oscilações SSVEPs são observáveis nos eletrodos occipitais, induzidas por estimulação visual repetitiva. Estímulos a uma certa frequência levam a oscilações na mesma frequência e em harmônicos e sub-harmônicos da frequência de estimulação (Bin, Gao & Wang 2009). Os usuários podem selecionar um estímulo, concentrando-se neste, o que leva a um aumento da amplitude nas faixas de frequências correspondentes à frequência do estímulo. O principal problema com esta abordagem é que exige controle de atenção, o que se torna inadequado para pacientes com controle restrito do movimento dos olhos. Este paradigma mostra-se mais estável entre diferentes sujeitos, e também mais simples no ligado ao treinamento para gerar esta resposta. O trabalho feito nesta pesquisa basou-se neste paradigma, assim no capítulo seguinte se aprofunda mais sobre o BCI com SSVEP.

Potenciais corticais lentos Potenciais corticais lentos (SCP) referem-se as mudanças de tensão lentas do sinal EEG que ocorrem na faixa de frequência de 1-2 Hz. SCPs negativos correspondem a uma diminuição geral na excitabilidade cortical, enquanto SCPs positivos correspondem a um aumento geral na excitabilidade cortical. Provou-se que os indivíduos podem aprender a controlar voluntariamente suas SCPs quando eles são treinados com realimentação visual ou auditivo de seu potencial cerebral (Pfurtscheller & Neuper 2001).

Ritmos sensório-motores e imaginação motora A atividade cerebral oscilatória ocorre em muitas regiões do cérebro seguindo as mudanças do estado dos sujeitos (e.g. entre vigília e sono ou entre trabalho concentrado e repouso). Esta atividade do EEG é usualmente classificada em diferentes faixas de frequência ou ritmos. Os ritmos típicos estão dentro de diferentes faixas de frequência: delta (1-4 Hz), teta (4 -8 Hz), mu (8 - 13 Hz), beta (13-25 Hz) e gama (25 - 40 Hz). Os ritmos sensório-motores (SMR) são atividades oscilatórias observáveis nas áreas sensório-motoras (lobo parietal) específicas do córtex, concentrados na frequência das bandas mu e beta.

Diferentes partes do corpo humano são mapeados em regiões específicas do córtex sensitivo-motor. Além disso, órgãos ou membros que necessitam de um controle motor muito fino ou informação sensorial detalhada, como as mãos ou língua, são mapeados em regiões maiores no córtex sensório-motor (ver figura 1.5 ⁴). Provou-se que, após um período de treinamento, as pes-

⁴Fonte: [http://willcov.com/bio-consciousness/diagrams/Homunculus%20\(Topographic\)%20Diagram.htm](http://willcov.com/bio-consciousness/diagrams/Homunculus%20(Topographic)%20Diagram.htm).

soas podem aprender a modular voluntariamente os ritmos sensório-motores, particularmente os das áreas do córtex motor das mãos e pés. Na realidade o movimento, ou a preparação para o movimento, é acompanhada por uma diminuição da atividade dos SMR, particularmente contralateral ao movimento. Esta diminuição foi rotulada de “evento relacionado de dessincronização (do inglês *event-related synchronization*, ERD)” (Pfurtscheller & Lopes da Silva 1999). Enquanto o seu oposto, que é o aumento da potência do ritmo, é “evento relacionado de sincronização (do inglês *event-related synchronization*, ERS)”, o qual ocorre no período de pós-movimento e com o relaxamento. Além disso, é importante notar que para aplicações BCI, tanto ERD e ERS não requerem movimento real, estes ocorrem mesmo quando apenas a imaginação de movimento é realizado (imaginação motora).




Figura 1.5: Áreas sensório-motoras: as zonas sensoriais são ilustrados por um “homúnculo sensorial”, indicando quais regiões são atribuídas para processar informações sensoriais a partir das respectivas partes do corpo.

1.2 Objetivos da dissertação

O principal objetivo e contribuição desta pesquisa é construir um sistema BCI que adquira sinais do cérebro de um usuário e os traduza em ações adequadas através do uso de pré-processamento eficiente, fazendo extração e seleção de características e utilizando métodos de classificação clássicos.

O paradigma adotado de BCI é a resposta SSVEP. O sistema é composto de um painel de LEDs para gerar os estímulos visuais. Cinco comandos foram obtidos, incluindo o estado de repouso. Quando o sujeito observa qualquer dos 4 LEDs piscando, espera-se observar no sinal EEG a resposta SSVEP associada, que foi tratada com o processamento de sinal que incluiu o uso de métodos de seleção de características baseados em métricas de clusterização e descritores alternativos, o índice de Davies-Bouldin (Davies & Bouldin 1979) foi utilizado para esta tarefa.

A análise do sinal EEG baseou-se na análise em frequência usando o método de Welch (Welch 1967), na seleção de características usando o índice Davies-Bouldin como discriminante

e classificadores lineares para o modulo de saída.

O desempenho do sistema BCI foi avaliado para diferentes sujeitos. Os dados usados ao longo da pesquisa foram adquiridos pelo próprio grupo, ou seja, através da utilização de equipamento para a captura de sinais EEG.

Esta dissertação esta estruturada da seguinte forma: o capítulo 2 apresenta uma revisão mais aprofundada de sistemas BCI utilizando a resposta SSVEP. O capítulo 3 aborda os métodos e materiais usados no desenvolvimento desta pesquisa. O capítulo 4 apresenta os resultados obtidos. Finalmente, o capítulo 5 expõe as conclusões e as perspectivas futuras desde trabalho.

BCI e Potenciais Evocados Visuais de Estado Estacionário

Animais e seres humanos produzem respostas cerebrais relacionadas com fenômenos visuais, por meio de mecanismos de excitação e inibição neuronal quando estímulos visuais são apresentados. Hubel & Wiesel, Jones & Palmer (1987), Daugman (1985), Watson et al. (1983) trabalharam no estudo da neurofisiologia do sistema visual humano, encontrando que os padrões de grades, barras, bordas e reversões de padrões, como estímulos de xadrez, ativam as células do córtex visual, que atuam como detectores de bordas e filtros espaço- temporais. As propriedades específicas, como o contraste de iluminação de um item e sua frequência espacial, podem alterar a atividade neuronal e modular uma resposta evocada visual ou VEP (potencial evocado visual).

Se este tipo de estímulos visuais são apresentados repetitivamente a uma taxa de pelo menos 6 Hz, as deflexões do VEP se sobrepõem, criando oscilações quase senoidais, formando uma resposta conhecida como potencial evocado visual de estado estacionário (SSVEP), com frequência e fase ligada ao estímulo (Bin, Gao & Wang 2009). A resposta SSVEP tem sido estudada e analisada, por meio da captura de sinais cerebrais através de eletroencefalograma (EEG), usando uma touca com eletrodos posicionados no escalpo. Esta técnica é amplamente utilizada em estudos médicos e aplicações que permitem a utilização desses sinais em tempo real, assim como as interfaces cérebro - computador (BCI).

As respostas SSVEP podem ser detectadas dentro de estreitas faixas de frequências (por exemplo, $\pm 0,1$ Hz), em torno das frequências de estimulação visual através de métodos de processamento de sinal que exploram as características específicas do sinal, tais como ritmicidade e sincronização. As mais fortes respostas ocorrem no córtex visual primário, embora outras áreas do cérebro são ativados em diferentes graus. A figura 2.1 mostra uma representação dos típicos sinais obtidos na eletroencelegrafia (EEG) em um sujeito, mediante estimulação visual.

Entre 1999 e 2000, surgiu na literatura umas das primeiras tentativas de usar sistemas SSVEP-BCI (Calhoun & McMillan 1996) (Middendorf et al. 2000). Já na atualidade estes sistemas apresentam resultados que os colocam como um dos principais sistemas BCI, ao lado dos paradigmas P300 e imaginação de movimento. Isso devido a seu curto tempo de resposta, a taxa de transferência de informação (ITR) elevada, e por ser também uma resposta inerente




Figura 2.1: Típicas formas de onda com deflexões VEP positivas (Pi) e negativas (Ni). Fonte: Adaptada de Ng et al.(2012).

do cérebro (Zhang et al. 2012). Assim, a área de desenvolvimento de sistemas com SSVEP-BCI tem muitas perspectivas e desafios que surgem quando se tenta criar um sistema que realmente tenha utilidade prática. Espera-se que os sistemas SSVEP-BCI, como qualquer outro sistema BCI, tornem-se uma ferramenta que possa integrar-se na vida diária de alguma forma (jogos, entretenimento, comunicação, recuperação motora de pacientes e deficientes) (Millán et al. 2010).

Com o intuito de entender melhor a estrutura dos sistemas SSVEP-BCI apresenta-se a seguir diferentes aspectos que têm sido estudados para o desenvolvimento de tais sistemas, estes são: características dos estímulos visuais, o desenho prático do sistema e os diferentes métodos de processamento de sinal utilizados.

2.1 Estímulos visuais e SSVEP

Os sistemas SSVEP-BCI usam os estímulos visuais como forma de evocar um determinado padrão elétrico no córtex visual. Ao contrário de sistemas BCI independentes, onde a execução baseia-se no controle voluntário da atividade neural do sujeito (por exemplo, Trejo et al. (2006), Pfurtscheller & Neuper (2001)), a operação dos sistemas SSVEP-BCI depende da capacidade do sujeito de se concentrar, fixar e seguir os estímulos visuais de acordo com a ação pretendida por ele.

Assim, os estímulos atuam como um fator exógeno para ajudar a capturar e dirigir a atenção do sujeito. Foi estabelecido que um estímulo observado irá provocar uma resposta SSVEP reforçada (Joon Kim et al. 2007). No entanto, quando vários estímulos são apresentados no mesmo campo visual, devido à capacidade limitada de processamento do sistema visual humano, os estímulos irão competir na resposta neural no córtex (Ng et al. 2012). Em sistemas SSVEP-BCI, já foi conseguido usar vários estímulos visuais simultaneamente, correspondendo a um número de opções disponíveis para um usuário. A competição pela presença de estes estímulos modula os potenciais evocados resultantes e influencia o desempenho do BCI. A seguir a figura 2.2 apresenta alguns padrões e formas de estímulos visuais usados em sistemas SSVEP.

Existem na literatura uma série de artigos dedicados ao estudo da influência do tipo de estímulo visual usado. Zhu et al. (2010) apresentou uma revisão onde consta um resumo dos




Figura 2.2: Estímulos gráficos para SSVEP (a) Em estímulos gráficos simples o objeto gráfico aparece alternadamente no fundo. (b) Em estímulos de padrão de reversão pelo menos dois padrões são alternados em uma frequência especificada. Fonte: Adaptada de Zhu et al.(2010).

estímulos usados em diferentes trabalhos e alguns dos resultados mais representativos obtidos com cada um deles. A forma, a cor, o contraste e a frequência foram os fatores mais importantes na resposta SSVEP. De acordo com esta referência, a intensidade do sinal SSVEP realmente é influenciada pela frequência e a cor do estímulo. Levando isso em consideração, a utilização de estímulos com LED permite a realização de experiências com uma grande variação das características, superando as limitações da utilização de um monitor de computador, como a restrição no uso da gama de frequências de estimulação. Quanto à cor do estímulo, a luz amarela é menos dependente da frequência utilizada, segundo estudo que analisou o impacto dos segundo e terceiro harmônicos em função das características cromáticas do estímulo. O último tema abordado nesta referência foi como o aumento do número de estímulos diminui a resolução espectral, o que pode tornar o problema de classificação mais difícil.

Em Wu & Lakany, (2012) tem-se também o estudo do impacto do estímulo visual, concluindo que uma separação maior entre estímulos e um maior tamanho destes, melhoram a resposta SSVEP. (Ng et al. 2012), também oferece resultados semelhantes, concluindo que uma maior precisão é obtida quando os estímulos visuais são separados a mais de 5 graus, para frequências de estímulo entre a banda alfa e beta.

2.2 Aplicações dos sistemas SSVEP-BCI

Dentro das principais aplicações práticas que já foram feitas utilizando um sistema SSVEP-BCI, Muller-Putz & Pfurtscheller (2008) fizeram o controle de uma prótese de mão por meio de quatro estímulos visuais evocados por LEDs montados na prótese. Outro trabalho usando SSVEP-BCI consistiu em criar um sistema de comunicação simples (Sanchez et al. 2011), utilizando três estímulos visuais evocados por LEDs e obtendo uma taxa de acerto média de 92% e uma taxa de transferência de informação (do inglês, *Information Transfer Rate* - ITR) de até 16 bits/min. Outro trabalho (Gao et al. 2003) relata um sistema que consegue separar 48 opções/estímulos com um ITR médio de 68 bits/min e taxa de acerto média de 87,5%. Os resultados de sistemas SSVEP-BCI com relação ao ITR são considerados altos em comparação a outros sistemas BCI (Bin, Gao, Yan, Hong & Gao 2009).

Outros trabalhos testaram o desempenho do sistema SSVEP-BCI na execução de gerenciamento de dispositivos on-line. Em Ortner et al. (2011) implementaram o controle de uma órtese de mão de forma assíncrona, sendo que os resultados mostraram que os indivíduos alcançaram uma taxa média positiva de predição de $78\% \pm 10\%$. Dois LEDs foram usados como estímulos visuais a 8 e 13 Hz. O processamento foi realizado utilizando densidade espectral de potência (PSD), sendo que um segundo de dados foi analisado levando-se em conta a resposta na frequência de estimulação e no segundo e terceiro harmônicos. As classes foram encontradas por detecção de soma de harmônicos.

2.3 Processamento de sinal nos sistemas SSVEP-BCI

A análise espectral de potência é uma das técnicas mais amplamente utilizadas para a identificação de padrões em sistemas SSVEP-BCI. A figura 2.3 apresenta a imagem das formas de onda típicas usadas para a estimulação e uma representação do espectro de frequência obtido na análise do sinal EEG num sistema SSVEP-BCI. Para um segmento de dados x de sinal EEG, obtido a partir de um k padrão observado com frequência de oscilação $f_1, f_2, \dots, f_k$ respectivamente a identificação do alvo pode ser implementado através dos seguintes passos: 1) Cálculo do espectro do sinal EEG usando *Fast Fourier Transform* (FFT) ou uma outra técnica de análise espectral. 2) A partir dos coeficientes em frequência obtidos pode-se utilizar qualquer método que permita discriminar entre as diferentes classes (estímulos) usados. É normalmente utilizado o cálculo da razão sinal - ruído para realçar e discriminar os diferentes espectros de potência. Também é usado às vezes filtragem espacial, que permite separar, realçar, e criar combinações de diferentes eletrodos. 3) Finalmente o uso de uma estratégia de classificação de dados também é comum. A seguir apresenta-se os diferentes métodos que têm sido usados na literatura e alguns dos resultados obtidos até agora com o seu uso.




Figura 2.3: (a) Formas de onda para estímulos visuais em sistemas SSVEP-BCI. (b) Espectro de intensidade para uma resposta evocada por um estímulo visual em 10 Hz. Fonte: Adaptada de Bin et al.(2009).

Em Wang et al. (2006) propuseram um sistema de potenciais evocados visuais (VEP) prático, baseado no trabalho de Sutter em 1992 com VEP transiente (TVEP), mas evoluindo para o fenômeno de SSVEP. Já neste estudo o problema da variabilidade da resposta SSVEP entre os usuários foi abordado, um fator que pode ser significativamente reduzido através da seleção

adequada da localização dos canais, frequência dos estímulos e velocidade de seleção. A posição precisa dos canais foi determinada com o estudo do mapeamento de potência do EEG na frequência de estímulo. Este mapa foi levantado através da obtenção da decomposição do sinal e ruído, utilizando análise de componentes independentes (do inglês *Independent Component Analysis*, ICA). Treze componentes independentes (ICs) foram calculados como fontes através da ICA. Os ICs com maior amplitude normalizada no sinal na frequência de estímulo foram considerados atividade e os restantes foram considerados ruído. Portanto, o canal com a resposta SSVEP mais forte foi selecionado como canal de referência com o qual os componentes de fundo do sinal podem ser reduzidos. Outras conclusões deste trabalho são sobre o uso da faixa de frequências. Neste caso, verificou-se que a utilização da banda alfa (8-13Hz) não é aconselhável para evitar a ocorrência de falsos positivos. Sobre a velocidade de seleção, que é um parâmetro que influencia o aumento da ITR, a seleção deste parâmetro é um fator a ser considerado pela sua influência na relação sinal-ruído (do inglês, *Signal to Noise Rate - SNR*). Os dados mostraram que um valor de 8 seg. é para a maioria das pessoas deste experimento um valor que ainda mantém uma boa SNR. Finalmente, em relação à resposta de amplitude SSVEP com respeito à frequência, concluiu-se que as baixas frequências até 20 Hz têm a maior amplitude, mas em termos de SNR, as três bandas testadas, (baixa, média e alta) têm quase níveis idênticos.

O trabalho do mesmo laboratório de Wang et al. (2006), apresentou em 2008 uma continuação de sua experiência com SSVEP (Wang et al. 2008), onde leva-se em conta o número de harmônicos que são utilizados para realizar a análise de potência espectral (PSD). O segundo harmônico foi considerado necessário porque, para alguns sujeitos, era mais forte do que o componente fundamental. Outro tópico tratado foi o uso das características de fase que podem ser utilizadas e também estão codificadas nos estímulos visuais. Isto pode possibilitar que dois estímulos usem a mesma frequência de excitação, mas com duas fases distintas.

Iskan et al. (2011) apresentaram uma aplicação mais específica sobre a separação e classificação de 4 e 5 estímulos visuais utilizando um monitor de computador como elemento de estimulação. Utilizando-se o PSD das amplitudes vizinhas da frequência de estimulação e a primeira e segunda harmônicas, o vetor de características foi obtido como entrada para um conjunto de classificadores. Foi feita uma comparação entre três técnicas de classificação: *Support Vector Machine* (SVM), *Fisher's Linear Discriminant Analysis* (LDA) e *Nearest Mean Classifier* (NMC). No caso do experimento com 4 estímulos visuais, os melhores resultados foram obtidos com NMC para comprimentos de segmento de 1 a 3 segundos, LDA apresentou o melhor desempenho para segmentos de 2 segundos. No caso de cinco estímulos foram encontrados resultados semelhantes. A taxa de acerto média foi de 83,6% para 4 estímulos e 73,5% para 5 estímulos, com segmentos de 3 segundos, neste caso, demonstrou-se que a utilização de segmento mais longo melhorou a precisão da classificação. Finalmente, deve-se notar que o grupo de frequências utilizada foi de 4.6 a 10.70 Hz

Em 2006 foram propostas alternativas para a classificação, processamento e análise de um sinal de SSVEP. Lin et al. (2007), propuseram uma técnica conhecida como análise de correlação canônica (do inglês *canonical-correlation analysis*, CCA) que usa os sinais de múltiplos canais usando a covariância de cada canal para melhorar a relação sinal-ruído. Experimentos off-line

foram realizados com dados para nove frequências de estimulação. A taxa média de acerto foi de 75% para um segmento de dados de 2.25 seg (um tamanho inferior de segmento gera precisões menores). Mais tarde, Friman et al. (2007), propuseram técnicas alternativas: *Minimum Energy Combination* (MEC) e *Maximum Contrast Combination* (MCC). Uma comparação foi feita entre estas técnicas e as técnicas clássicas que usam PSD. Os resultados mostraram que as novas técnicas propostas têm maior robustez a fenômenos tais como a variação da resposta entre os usuários. A taxa média de acerto foi de 71% para o método bipolar, 84% para MEC e 81% para MCC. O mesmo grupo apresentou um trabalho com MEC para o controle de um sistema de reabilitação robótica, com quatro comandos codificados, obtendo uma porcentagem de 96% na taxa de acerto média (Valbuena & Cyriacks 2007).

O desenvolvimento com estes métodos alternativos continuou com Bin, Gao, Yan, Hong & Gao (2009). Neste trabalho foi utilizado o método CCA mas desta vez on-line. Os resultados para seis estímulos visuais mostram que é possível, com nove canais de sinal e um segmento de 2 segundos, obter uma taxa de acerto média de 95.3% e uma taxa de transferência de informação de 58 ± 9.6 bit/min. A mesma capacidade de baixa variabilidade entre os usuários é mantida.

No caso da técnica de MEC Volosyak (2011) descreve uma plataforma chamada Bremen BCI-System que consiste de um teclado desenhado em uma tela de computador, com 32 caracteres e cinco caixas de estimulação. O ITR médio foi de $61,70 \pm 32,676$ bit/min e a taxa de acerto entre 89 e 100%, o mais alto ITR obtido na experiência por um sujeito foi 109,02 bit/min. Vale ressaltar que este valor é superior ao ITR de todos os valores previamente publicados na literatura para qualquer tipo de paradigma BCI.

A ideia geral encontrada em algumas destas pesquisas sobre a influencia dos parâmetros-chave no desempenho de tais sistemas, indica que a utilização de métodos de otimização pode ajudar a aumentar a força da resposta SSVEP, melhorando a relação sinal-ruído (Wang et al. 2006).

No seguinte capítulo se apresentara o modelo do sistema SSVEP-BCI projetado neste trabalho, para isso são descritos os metodos e materiais para este fim.

Métodos e Materiais

3.1 O sistema SSVEP-BCI

Um sistema BCI é usado principalmente para controlar dispositivos de assistência a pessoas com deficiências motoras graves. Sinais cerebrais são extraídos e convertidos em comandos de saída adequados. Os sistemas BCI podem ser usados para acionar uma grande variedade de dispositivos de saída. Dentre as aplicações clássicas estão dispositivos de processamento de texto, envio de e-mails, seleção de itens de um menu, acesso à Internet ou navegação em um ambiente virtual. Aplicações mais complexas incluem sistemas BCI que requerem controle multidimensional, por exemplo, controle de cadeiras de rodas, braços robóticos, ou neuro próteses (Millán et al. 2010).

Um típico sistema SSVEP-BCI consiste em uma série de fontes de luz piscando com frequências diferentes e usadas como estímulos visuais. Cada frequência codifica um comando de controle. Neste caso, cabe ao módulo de processamento de sinal decidir qual fonte de luz o usuário está dirigindo sua atenção com base na resposta SSVEP evocada. A figura 3.1 apresenta o esquema do sistema BCI generalizado.




Figura 3.1: Sistema BCI generalizado.

Em particular, o sistema SSVEP-BCI projetado neste trabalho é composto de um conjunto

de estímulos visuais colocados ao redor de uma tela de computador. LEDs foram usados para provocar os estímulos visuais, e controlados por um circuito que permite a variação da intensidade de iluminação e a frequência de acionamento. O sistema foi projetado para usar máximo quatro estímulos, possibilitando ainda um estado de repouso. A seleção de LEDs, em vez do uso de uma tela de computador onde esta é usada para apresentar os estímulos, tem como objetivo conseguir um maior controle sobre a gama de frequências de estimulação e sobre a variação das cores dos estímulos. A seleção do tipo de estímulo visual dos sistemas SSVEP-BCI, tem sido abordado por estudos na literatura com intensa discussão sobre as vantagens e desvantagens de cada abordagem (Zhu et al. 2010) tal como discutido anteriormente na sessão 2.1 . A Figura 3.2 apresenta o esquema da montagem dos LEDs utilizada para este trabalho.



Figura 3.2: Montagem dos LEDs para os experimentos realizados.

Usualmente a resposta SSVEP induzida no córtex visual quando um usuário dirige sua atenção a um dos estímulos visuais pode ser identificada por uma análise em frequência. Uma vez extraídas as características (coeficientes em frequência) realiza-se a classificação de atributos visando associação com o sinal de controle do dispositivo externo. Neste trabalho, o resultado da análise e da classificação do sinal não irá ser usado para executar uma ação em tempo real, mas sim para avaliar seu próprio desempenho criando um protótipo para tal tarefa. A seguir a figura 3.3 apresenta o diagrama de blocos do sistema BCI.




Figura 3.3: Diagrama de blocos do sistema BCI.

Em essência, o foco de desenvolvimento deste trabalho foi o bloco transdutor BCI. O bloco usuário BCI também será parte da experiência através da captura de dados com o qual os testes do transdutor BCI foram feitos. Como apenas testes off-line foram conduzidos, o bloco de Realimentação não foi utilizado, e deve ser introduzido em um trabalho posterior.

Introduz-se a seguir algumas características dos módulos construídos que compõem um sistema SSVEP-BCI completo. Posteriormente, tem-se o aprofundamento nos métodos usados para o processamento de sinal, para finalmente explicar sobre o processo de aquisição de dados e os testes do sistema como um todo.

3.2 Descrição e construção do sistema SSVEP-BCI

A construção do sistema BCI consiste na tarefa de criar e implementar os blocos de Usuário BCI e Transdutor BCI. Um tipo de *framework* é proposto para construir o sistema, utilizando-se um conjunto de classes cooperantes que podem ser usadas para criar aplicativos de BCI. A ideia foi construir um sistema modular em que seja possível incluir a apresentação de realimentação em tempo real (pensando no futuro do sistema total), a aquisição de sinais de controle BCI e a medição do desempenho do BCI, procurando-se adequar ao tipo de concepção dos requisitos que foram definidos para o sistema. Esta ideia de *framework* é comumente utilizada para o desenvolvimento de tais sistemas, tal como se observa nas diversas plataformas que facilitam a integração de blocos, e a concepção de sistemas BCI, como: Openvibe ¹, BCI2000 ² e BCILab (Brunner et al. 2011).

3.2.1 Usuário BCI

A eletroencefalografia (EEG) (Schomer 2007) refere-se à técnica de registro dos sinais elétricos cerebrais a partir de eletrodos na superfície do escalpo. O registro do EEG tem a vantagem de ser relativamente simples e não-invasivo, mas, ao mesmo tempo, tem limitações na resolução espacial. Além disso, EEG é suscetível à interferência da rede de alimentação e outros artefatos tais como os provocados pela atividade muscular e a atividade electroculográfica (EOG).

Os sistemas de aquisição de EEG usualmente oferecem a possibilidade de armazenar e exibir informações sobre as atividades cerebrais praticamente em tempo real, uma vez que os sinais são devidamente amplificados. Os dispositivos de EEG ainda contam com módulos de filtragem analógico para remoção de artefatos (sobretudo biológicos), compostos de filtros passa-baixa, responsáveis por remover ruídos de frequência entre 50Hz e 100Hz, e filtros passa-alta responsáveis por remover frequências abaixo de 0,5 Hz.

Em relação às configurações usadas para equipamento de captura dos sinais de EEG, estas são descritas posteriormente neste capítulo na seção que especifica os métodos usados para a aquisição de sinais. Assim, nesta seção vamos aprofundar no *software* utilizado para a realização dos experimentos.

De maneira geral, o BCI2000 foi o programa usado para criar módulos para o sistema BCI a partir das ferramentas que este fornece. Foi implementado um módulo de interface visual para os experimentos de captura de dados mediante a apresentação de estímulos SSVEP. A seleção das diferentes frequências de estimulação, a intensidade dos estímulos, e da configuração física

¹Openvibe <http://openvibe.inria.fr/>

²BCI2000 é um sistema de propósito geral para pesquisa com interface cérebro-computador (BCI). Pode ser usado para a aquisição de dados, apresentação de estímulos, e aplicações de monitoramento de cérebro. <http://www.bci2000.org/BCI2000/Home.html>

destes na montagem dos experimentos foi escolhida baseada na referencia (Zhu et al. 2010). Os valores específicos são descritos nas seções 3.2.2 e 4.5

Esta aplicação sincroniza a apresentação dos estímulos e se comunica diretamente com o equipamento de *hardware* de captura, armazenando os dados obtidos para cada sujeito durante o experimento. Estes dados estão em um formato próprio de BCI2000 e podem ser exportados para ser tratados diretamente em MATLAB, sendo este o esquema utilizado uma vez que todo o processamento dos dados foi feito através de um programa desenvolvido em MATLAB. A figura 3.4 mostra a execução de um experimento com o módulo criado com BCI2000. Pode-se observar a janela da interface do usuário, mostrando as indicações sugeridas para cada experimento, e os sinais de EEG que estão sendo capturados naquele momento.




Figura 3.4: Apresentação e captura de dados para estimulação do sistema SSVEP-BCI construído.

3.2.2 Transdutor BCI

Uma vez que os sinais são adquiridos, a unidade de processamento de sinal extrai as suas características e as traduz em mensagens ou comandos. Para o sistema BCI, os sinais de interesse são idealmente aqueles que refletem as intenções do usuário. Neste bloco são implementadas funções de processamento de sinal que geralmente incluem: extração de características e algoritmos de tradução/classificação (Wang et al. 2008).

A seguir é mostrado parte da estrutura utilizada para o programa desenvolvido em MATLAB para a execução das funções de processamento de sinal (normalização, densidade espectral de potência, seleção de atributos, classificação), estas funções descritas indicam a estrutura usada no programa, a explicação aprofundada sobre os métodos em que foi baseado o processamento de sinal será visto em seções posteriores deste capítulo:

- **Preprocessamento:** Foram criadas funções para a normalização dos dados, atenuando assim as discrepâncias da escala entre os atributos obtidos. Não foi utilizado nenhum tipo de filtragem temporal ou espacial.
- **Extração e seleção de características:** A função de *pwelch* do MATLAB foi usada para realizar a extração das características em frequência. Desta forma foi obtida a densidade

espectral de potência PSD. A partir destas características espectrais obtidas para cada um dos canais analisados foi possível fazer a análise dos atributos. A seleção de características foi realizada por meio do índice Davies-Bouldin tal como definido mais adiante. O método implementado foi uma função que faz a análise do índice Davies Bouldin. Por meio dos resultados desta análise foi possível ordenar os melhores atributos, para depois selecioná-los segundo diferentes estratégias para compor o vetor de atributos.

- **Classificação:** Um classificador mapeia as características de entrada em uma das classes do experimento, cada classe corresponde a um estímulo visual. Foi utilizado um classificador baseado em análise de discriminante linear (do inglês *Linear Discriminant Analysis*, LDA). A função de MATLAB *classify* foi usada.

A técnica de *pwelch* foi utilizada pela sua simplicidade após compara-la com outras técnicas de mesma complexidade, por exemplo, o periodograma e a Transformada de Fourier.

3.2.3 Dispositivos de saída

Conforme já mencionado, os aplicativos projetados para BCI devem ser versáteis, o que implica levar em consideração as diferenças de cada usuário. Certamente, a seleção de características adequada e o uso de técnicas adaptativas podem facilitar e aumentar o desempenho do sistema como um todo. A estratégia aqui adotada concentrou-se em adaptar as características do usuário através dos algoritmos de processamento de sinal feitos no bloco transdutor BCI. Futuramente, pretende-se continuar este processo de adaptação no que concerne à realimentação para o treinamento do usuário e ajuste do paradigma BCI.

Com este propósito, este bloco concentrou-se na concepção e construção de uma plataforma de hardware para o controle dos estímulos visuais. Foi desenvolvida pelo engenheiro João Paulo Gomes uma placa com um microcontrolador, o qual possibilita ajustar a frequência de oscilação dos estímulos, através de uma porta serial USB. Também é possível controlar e configurar até 8 estímulos simultaneamente de diferentes frequências diferentes, que podem se encontrar entre 1-30 Hz. A placa é alimentada por uma entrada USB e é portátil possibilitando realizar os experimentos onde seja desejado. Os estímulos também podem ser localizados na distribuição física que atenda às necessidades de cada experimento. Adicionalmente é possível modificar a intensidade do brilho de cada LED separadamente por meio de potenciômetros (Observar figura 3.5). Há também a possibilidade de se trocar os LEDs utilizados para evocar os estímulos (os experimentos foram feitos utilizando LEDs brancos convencionais). Na figura 3.5 é apresentada uma imagem da placa desenvolvida, é possível reconhecer o microcontrolador, os potenciômetros para o ajuste do brilho, a porta serial, e um *switch* que permite escolher os dos modos de funcionamento: Run, quando está executando a oscilação dos LEDs, e Prog, quando esta sendo configurado com os valores de oscilação para cada LED.

3.3 Processamento de Sinal SSVEP

A análise no domínio da frequência foi a técnica fundamental que permitiu estudar o sinal SSVEP, pois fornece uma relação direta entre as características (coeficientes em frequência) e o




Figura 3.5: Placa para controle e configuração dos estímulos visuais no sistema SSVEP-BCI.

estímulo visual aplicado. Neste sentido, técnicas baseadas na transformada de Fourier (FFT), tal como o periodograma (Manolakis et al. 2000), e o método de Welch, foram aqui consideradas.

Assim, da análise espectral é obtida a densidade espectral potência (do inglês *Power Spectral Density*, PSD) dos sinais. A PSD representa a potência do sinal em cada componente de frequência. Os valores da PSD nas frequências de estimulação foram adotados como características padrão a serem selecionadas para compor um vetor de atributos. Entretanto, o ruído é um problema que prejudica a resposta espectral e pode contribuir para estimativas erradas ou simplesmente reduzir a qualidade (em termos de separabilidade das classes) dos atributos selecionados. No presente trabalho, duas formas para realizar a análise dos atributos foram testadas: a) clássica, tomando só os coeficientes de densidade espectral nas frequências de estimulação; b) utilizando uma medida de clusterização (índice de Davies-Bouldin) como discriminante para seleção de atributos.

Depois de analisar e selecionar os atributos que serão utilizados para classificar os sinais, existem diferentes estratégias e classificadores que podem ser usados. Neste trabalho, analisamos a resposta através de um classificador baseado na análise de discriminante linear (LDA). As funções construídas para implementar os algoritmos de processamento foram feitas em MATLAB, e, portanto, a análise da resposta foi feita off-line com dados que foram capturados para os diferentes indivíduos. A abordagem utilizada para o processamento de sinal da resposta SSVEP é apresentada a seguir.

3.3.1 Resposta e modelagem SSVEP

Um sistema SSVEP-BCI requer a intensificação da atenção do usuário para um estímulo visual oscilante. A amplitude e a fase que definem uma resposta SSVEP dependem da frequência, intensidade e da estrutura deste estímulo visual (Ng et al. 2012). Para modelar uma resposta SSVEP foi considerada aqui uma estimulação visual com uma frequência oscilação de f Hz.

A tensão entre o i -ésimo eletrodo e um eletrodo de referência no tempo t , $y_i(t)$, pode ser descrita como uma função da frequência dos estímulos f_i , e as suas harmônicas, tal como mostrado no primeiro termo da equação 3.1. Já o segundo termo corresponde ao conjunto de sinais de perturbação, por exemplo, de outros processos cerebrais ou distúrbios externos, tais como a respiração, demais artefatos e interferências da rede de alimentação. Estes sinais de

perturbação são adicionados ao sinal de cada eletrodo com fatores de ponderação. Finalmente, existe um componente interferente que é específico para cada eletrodo i , definindo o sinal $e_i(t)$. N_h é o número de harmônicas consideradas.

$$y_i(t) = \sum_{k=1}^{N_h} a_{i,k} \sin(2\pi k f + \theta_{i,k}) + \sum_j b_{i,j} z_j(t) + e_i(t) \quad (3.1)$$

O modelo é linear e para um segmento de tempo de N_t amostras do sinal, amostradas a uma frequência de amostragem F_s . O modelo pode ser expresso na forma vetorial (equação 3.2):

$$\mathbf{y}_i = \mathbf{X}\mathbf{a}_i + \mathbf{Z}\mathbf{b}_i + \mathbf{e}_i \quad (3.2)$$

onde $\mathbf{y}_i = [y_i(1), \dots, y_i(N_t)]^T$ é um vetor de $N_t \times 1$ que contém o sinal de EEG para o eletrodo i . De modo semelhante $\mathbf{e}_i$ é um vetor da mesma forma representando o ruído. Por sua vez, a matriz de informação SSVEP $\mathbf{X}$ é de dimensão $N_t \times 2N_h$ e contém os componentes de seno e cosseno associados com os N_h harmônicos,

$$\mathbf{X} = [\mathbf{X}_1 \mathbf{X}_2 \dots \mathbf{X}_{N_h}] \quad (3.3)$$

O vetor $\mathbf{a}_i$ é de tamanho $2N_h \times 1$ e contém as correspondentes amplitudes que ponderam a matriz $\mathbf{X}$. Da mesma forma, $\mathbf{Z}$ é a matriz com os sinais de perturbação nas suas colunas, e $\mathbf{b}_i$ o vetor correspondente de pesos.

Assumindo os sinais $y_i(t)$ de um número de eletrodos $i = 1, \dots, N_y$, o modelo pode ser generalizado para,

$$\mathbf{Y} = \mathbf{X}\mathbf{A} + \mathbf{Z}\mathbf{B} + \mathbf{E} \quad (3.4)$$

onde $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_{N_y}]$ é uma matriz $N_t \times N_y$ com os sinais dos eletrodos como colunas, $\mathbf{Z}$ é a atividade de fundo. $\mathbf{A}$ e $\mathbf{B}$ apresentam as respectivas amplitudes, e $\mathbf{E}$ é a matriz de ruído.

3.3.2 Pré-processamento

O sinal modelado na seção anterior tem uma resposta na qual o ruído é um componente aditivo, e, assim, poderia se tentar reduzir ou eliminar com técnicas que separam esta porção do sinal, o que permitiria extrair apenas a parte que foi gerado pela resposta SSVEP. A combinação de eletrodos de modo que os componentes comuns sejam realçados ou eliminados conforme o caso é realizada na filtragem espacial. No processamento do sinal SSVEP desenvolvido neste trabalho não foi usado esse tipo de filtragem, uma vez que o conhecimento prévio dos melhores eletrodos é necessário. No entanto, foram usados filtros analógicos do tipo notch com frequência de corte em 60 Hz para eliminar o ruído da rede, um filtro passa-alta de 0,1 Hz e um filtro passa-baixa em 50 Hz.

A estratégia de tratamento feito nesta fase centrou-se principalmente na utilização de normalização dos dados, de modo a atenuar discrepâncias da escala entre os atributos obtidos.

A normalização foi realizada por meio do cálculo da média e da variância. Para N_t amostras de sinal separadas para diferentes classes, considerando uma classe como um conjunto de dados

de um número de exposições ao mesmo estímulo, com um certo número de classes $N_c = [1, \dots, M]$, tem-se:

$$\mathbf{Y}_{N_c} = \mathbf{X}_{N_c} \mathbf{A}_{N_c} + \mathbf{Z}_{N_c} \mathbf{B}_{N_c} + \mathbf{E}_{N_c} \quad (3.5)$$

$$\bar{\mathbf{Y}}_{N_c} = \frac{1}{Nt} \sum_{i=1}^{Nt} \mathbf{Y}_{i_{N_c}} \quad (3.6)$$

$$\sigma_{N_c}^2 = \frac{1}{Nt-1} \sum_{i=1}^{Nt} (\mathbf{Y}_{i_{N_c}} - \bar{\mathbf{Y}}_{N_c})^2 \quad (3.7)$$

$$\hat{\mathbf{Y}}_{N_c} = \frac{\mathbf{Y}_{i_{N_c}} - \bar{\mathbf{Y}}_{N_c}}{\sigma_{N_c}} \quad (3.8)$$

A equação 3.8 apresenta o sinal $\hat{\mathbf{Y}}_{N_c}$ normalizado, este sinal transformado tem média nula e variância unitária. Onde $\mathbf{Y}_{N_c}$ (equação 3.5) refere-se ao sinal total de resposta SSVEP para todos os eletrodos N_y para uma classe N_c . A equação (3.6) refere-se a media do sinal $\mathbf{Y}_{N_c}$ e a equação (3.7) a variância do mesmo sinal

3.3.3 Extração de características

O estudo da resposta SSVEP requer análise para determinar a potência do sinal em cada componente em frequência, o que é feito pela estimação da densidade espectral de potência (PSD). Em geral, os vários algoritmos usados na estimação espectral, se dividem em duas grandes categorias: não paramétricos e paramétricos. Os métodos não paramétricos não requerem noções preconcebidas sobre a natureza do sinal sendo a Transformada Discreta de Fourier um exemplo típico desta categoria, e, por isso, selecionada para a presente aplicação devido ao seu baixo custo computacional. Alguns tipos de técnicas nesta categoria são o periodograma clássico, o método de Bartlett e o método de Welch (Johnson 2013, pp. 104–116).

O periodograma é uma técnica que estima o PSD para sinais de natureza estocástica sobre um determinado intervalo de tempo, considerando um número limitado de amostras, como é o nosso caso. Este método é considerado como um estimador parcial, já que o valor de variância não diminui com um menor número de amostras, e, também porque o periodograma emprega um janelamento (usualmente retangular) que cria problemas de resolução e vazamento espectral. Formalmente, se $y(n); n = 0, \pm 1, \pm 2, \dots$ denota um processo aleatório estacionário de segunda ordem com a sequência de autocorrelação $\rho(x) = E[y(t)y^*(t-k)]$, a PSD $\phi(w)$ é definida como (Manolakis et al. 2000):

$$\phi(w) = \sum_{k=-\infty}^{+\infty} \rho(k) e^{-jwk} \quad (3.9)$$

sendo uma definição alternativa dada por:

$$\phi(w) = \lim_{N \rightarrow \infty} E \left[\frac{1}{N} \left| \sum_{t=1}^N y(t) e^{-jw t} \right|^2 \right] \quad (3.10)$$

que após manipulação algébrica fornece:

$$\phi(w) = \lim_{N \rightarrow \infty} E \left[\frac{1}{N} |Y(w)|^2 \right] \quad (3.11)$$

A partir de um registro de comprimento finito de $y(1), y(2), \dots, y(N)$, pode-se determinar uma estimativa $\hat{\phi}(w)$ de sua densidade espectral de potência $\phi(w)$ para $\omega \in [-\pi, +\pi]$ na forma (Manolakis et al. 2000):

$$\hat{\phi}(w) = \frac{1}{N} \left| \sum_{t=1}^N y(t) e^{-j\omega t} \right|^2 \quad (3.12)$$

Trabalhando com a autocorrelação a equação também pode ser expressa da seguinte maneira:

$$\hat{\phi}(w) = \sum_{k=-(N-1)}^{+(N+1)} \hat{\rho}(k) e^{-j\omega k} \quad (3.13)$$

onde $\hat{\rho}(k)$ é a estimação da autocorrelação calculada para N amostras disponíveis.

Com o intuito de melhorar a estimativa do PSD, técnicas complementares foram propostas para resolver alguns dos problemas do periodograma. O método de Welch propõe a divisão dos dados totais em K segmentos, em que o periodograma é aplicado individualmente, podendo ou não haver sobreposição, o que reduz significativamente a variância do processo de estimação de espectro. O resultado final é obtido ao calcular o valor médio do periodograma de todos os segmentos.

Das técnicas não paramétricas para estimação espectral o método de Welch foi selecionado para nossa aplicação por considerar o uso de diferentes tipos de janelas e segmentação dos dados. Usando a mesma notação anterior, a estimação espectral pode ser descrita, neste caso, por:

$$\hat{\phi}(w)_{medio} = \frac{1}{K} \sum_{m=0}^{K-1} \hat{\phi}^m(w) \quad (3.14)$$

Particionando-se y_n em K segmentos não sobrepostos, para um comprimento total N e um comprimento de segmento L , tem-se $N = K \times L$. Para sequências sobrepostas a quantidade de sobreposição entre $y_i[n]$ e $y_j[n]$ é $L - D$ pontos, tem-se $N = L + D(K - 1)$. A quantidade de sobreposição é controlável, $D = L$ (sem sobreposição) ou, por exemplo, 50% para $D = L/2$. Consequentemente, ao permitir que as sequências sejam sobrepostas, é possível aumentar o número e/ou o comprimento das sequências que serão consideradas na média, trocando deste modo uma redução de variância por uma redução na resolução, levando a:

$$\hat{\phi}(w)_{welch} = \frac{1}{KLU} \sum_{m=0}^{K-1} \left| \sum_{n=0}^{L-1} f_{win}(n) y(n + iD) e^{-j\omega n} \right|^2 \quad (3.15)$$

onde $f_{win}(n)$ é a função da janela. O valor de U é constante e definido por:

$$U = \frac{1}{N} \sum_{n=0}^{N-1} |f_{win}(n)|^2 \quad (3.16)$$

O tamanho do segmento analisado L , o tipo de janela, a resolução em frequência (determinado pelo número de pontos na FFT) foram estudados em diferentes experimentos para compreender o seu efeito sobre o processamento realizado.

3.3.4 Seleção de características

Nesta fase do processamento do sinal, um certo número de características são extraídas a partir dos espectros de EEG. Estas características foram especificamente projetadas para discriminar o máximo possível as cinco classes usadas (quatro estímulos visuais em diferentes frequências e a classe de repouso).

Segundo o modelo descrito na equação 3.4, diz-se que a resposta SSVEP é composta das funções seno e cosseno na frequência de estimulação e as suas harmônicas mais componentes de ruído. De acordo com este modelo é natural que a busca por atributos para discriminação das classes se dê nos pontos do espectro de frequência em torno das frequências de estimulação. Tomando os quatro valores de potência espectral nos estímulos de frequência, no caso: $f_1 = 13Hz$, $f_2 = 18Hz$, $f_3 = 21Hz$ e $f_4 = 25Hz$. Foi construído assim um vetor de características que define os atributos de entrada para o classificador. A equação 3.17 apresenta a estrutura de esse vetor, tendo as frequências f_1 , f_2 , f_3 e f_4 , como a codificação das 4 frequências. Obviamente, esse vetor de características pode conter frequências associadas a diversos eletrodos.

$$Vc = [P_{f_1}, P_{f_2}, P_{f_3}, P_{f_4}] \quad (3.17)$$

A análise visual das características espectrais do EEG foi feita para observar graficamente a resposta esperada, confirmando a presença de problemas conhecidos, tais como: muito ruído, particularidades de cada indivíduo, e a variabilidade na resposta entre os eletrodos mais e menos reconhecidos pela sua atividade SSVEP. A escolha de atributos nas frequências de estimulação foi guiada seguindo uma estratégia clássica de seleção, uma abordagem que tem sido geralmente observada em outros estudos (Sanchez et al. 2011), mas que também não é mandatória, possibilitando o uso de métodos complementares para seleção de parâmetros com base em medidas de qualidade para separação de classes. Uma escolha baseada neste tipo de medida foi realizada também para tentar reduzir os problemas mencionados no início do presente parágrafo.

A busca das melhores características de cada sujeito foi o ponto crucial para superar o problema da resposta de má qualidade em alguns canais devido, sobretudo, ao ruído. Duas abordagens utilizando o índice de Davies Bouldin foram realizadas, a primeira concentrando-se na busca dos canais com a melhor resposta nas frequências de estimulação, e, a segunda, uma busca das melhores características espalhadas em todos os canais e para todos os valores de espectro de frequência (8-30 Hz).

Um método para seleção de características como Davies Bouldin (DB) visa quantificar a capacidade discriminatória dos atributos gerados (coeficientes do espectro de frequência) para o problema em questão (Theodoridis & Koutroumbas 1999). É importante observar que analisar cada atributo independentemente está longe de ser o ideal, mas realiza uma busca promissora quando comparado com outras técnicas mais elaboradas, evitando, por exemplo, buscas exaustivas.

Se x é uma variável aleatória que representa uma característica particular, tenta-se investigar se os valores da variável para diferentes classes, w_i , $i = 1, 2, \dots, m$ diferem significativamente. Considerando s_i uma medida de dispersão da classe w_i (isto é, uma medida da sua dispersão em torno do seu v médio) e $d(w_i, w_j) \equiv d_{ij}$ a distância entre os centróides das classes. O índice de similaridade R_{ij} entre w_i, w_j é,

$$R_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (3.18)$$

onde R_{ij} é simétrica. Assim o R_i é definido como:

$$R_i = \max_{j=1, \dots, m, j \neq i} R_{ij} \quad i = 1, \dots, m \quad (3.19)$$

em seguida, o índice DB pode ser definido como:

$$DB_m = \frac{1}{m} \sum_{i=1}^m R_i \quad (3.20)$$

ou seja, DB_m é a similaridade média entre cada classe w_i , $i = 1, 2, \dots, m$ e seu mais semelhante. Como é desejável que as classes tenham o mínimo possível de semelhança entre si, buscamos classes que minimizam DB. Portanto, valores pequenos de DB são indicativas da presença de grupos compactos e bem separados.

Para um conjunto de pontos da classe w_i , seja X_j um vetor de características n dimensional atribuído à classe w_i . A dispersão s_i é definida como:

$$s_i = \sqrt[q]{\frac{1}{T_i} \sum_{j=1}^{T_i} |X_j - A_i|^q} \quad (3.21)$$

onde A_i representa o vetor médio de w_i e T_i e o número de amostras da classe. Normalmente, o valor de q é 2, o que torna esta uma função de distância euclidiana entre o valor médio do *cluster*, e cada vetor de características. A dissimilaridade $\mathbf{d}(w_i, w_j)$ entre duas classes é definida como:

$$d_{ij} = \|A_i - A_j\| = \left(\sum_{k=1}^n |a_{k,i} - a_{k,j}|^s \right)^{1/s} \quad (3.22)$$

onde d_{ij} é a medida de separação entre as classes w_i, w_j e $a_{k,i}$ é o k -ésimo elemento de A_i . Para k atributos de dados, esta medida é basicamente a distância euclidiana entre os centros das classes i e j quando s é igual a 2.

Depois de definir as três estratégias (a clássica, e as duas baseadas no índice DB) utilizadas para selecionar os atributos que farão parte do vetor de características de entrada para o classificador, podemos trabalhar na definição da quantidade de atributos que farão parte desse vetor. A primeira estratégia de seleção restringe os atributos para os pontos do espectro nas frequências de estimulação, se tomamos os quatro pontos de frequência para os 16 eletrodos em que as medições foram feitas, teríamos um total de 64 descritores para construir um vetor de atributos. A equação (3.23) apresenta a matriz VC de vetores de atributos para a classe m ,

sendo $P = 16$ o número de eletrodos, T o número de amostras por classe e VT_P é um vetor do tipo definido na equação (3.17).

$$VC_m = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1P} \\ \vdots & \vdots & & \vdots \\ v_{T1} & v_{T2} & \dots & v_{TP} \end{bmatrix} \quad (3.23)$$

A segunda estratégia dedicou-se à criação de um vetor de atributos de dimensão l através do teste de diferentes combinações de atributos, avaliando sua eficácia de discriminação no classificador. Neste caso, o valor de l é progressivamente aumentado até chegar em 64, que é o limite máximo para os atributos do vetor e coerente com o limite máximo da estratégia anterior.

Logo, por meio do inverso do índice DB escolhe-se os eletrodos com as melhores respostas para as frequências de estimulação, fazendo um ranking em ordem decrescente dos melhores aos piores eletrodos. Assim, o classificador é alimentado com vetores de 4 descritores (equação 3.17) do primeiro eletrodo com melhor pontuação e progressivamente incrementando segundo a ordenação feita até completar P eletrodos com $P = 16$, sempre avaliando o desempenho dado pelo classificador com o aumento progressivo do número de atributos.

Finalmente uma terceira estratégia também foi testada, a seleção de l atributos a partir da criação de um ranking de todos os valores do índice DB obtidos para todos os atributos avaliados (valores do espectro de potência entre 8 e 30 Hz para 16 eletrodos). A lista foi organizada em ordem decrescente dos melhores aos piores, e o vetor de atributos definido a partir dos M atributos da lista com o incremento progressivo de M até 64.

3.3.5 Classificação

Muitas técnicas diferentes tem sido utilizadas para fins de classificação de sinal em BCI, sendo, provavelmente as seguintes características as encontradas nos sistemas BCI, que devem ser lidadas por o classificador:

- Presença de ruído e valores atípicos: os atributos são muito propensos a ser ruidosos ou afetados por valores atípicos, devido a sua baixa relação sinal-ruído;
- Alta dimensionalidade: O número de atributos utilizados pode ser normalmente alto, uma vez que vários canais em diferentes segmentos de tempo devem ser considerados;
- Pequenos conjuntos de treinamento: os conjuntos de treinamento são relativamente pequenos, uma vez que a captura de dados com os sujeitos pode tornar-se um processo demorado e exigente.

Devido a sua baixa complexidade, classificadores lineares são geralmente considerados estáveis e podem ser treinados mesmo com uma quantidade limitada de dados. Mas, mesmo assim deve-se considerar que um número muito elevado de atributos deve ser acompanhado de uma boa quantidade de dados de treinamento, a relação entre estes dois atributos restringe a solução de um problema de classificação por parte de um classificador.

Entre alguns dos tipos mais utilizados de classificadores lineares para BCI temos: a Análise de Discriminante Linear (LDA) e as máquinas de vetores suporte (SVM). Estes métodos utilizam hiperplanos para particionar o espaço de características em regiões, cada uma correspondendo a uma classe diferente. SVM difere de LDA na forma que os hiperplanos são escolhidos: entre todos os possíveis hiperplanos que separam, SVM escolhe os que maximizam as margens inter-classe, ou seja, a distância entre os pontos de treinamento mais próximos de diferentes classes. Os resultados satisfatórios encontrados ao utilizar LDA foram a razão para não aprofundar em outros testes com mais tipos de classificadores.

Análise de Discriminante Linear (LDA) O critério de classificação considerado no LDA é o erro total de classificação (TCE), o qual busca reduzir os objetos classificados incorretamente quanto possível. Em outras palavras, tenta-se minimizar a probabilidade de erro de classificação atribuindo um objeto à classe com a maior probabilidade condicional.

Se Y é uma variável aleatória discreta com valores $c_1, c_2, \dots, c_n$ representando as classes a ser preditas e X é um vetor aleatório representando os atributos de entrada, tem-se que dado um vetor de atributos observado x , vamos procurar a classe $\hat{c}$ de modo a maximizar a probabilidade daquela observação pertencer a referida classe, ou seja:

$$\hat{c} = \arg \max_{c_i} P(Y = c_i | X = x) \quad (3.24)$$

Esta abordagem é designada como Máximo a Posteriori (MAP) porque requer maximizar a probabilidade a posteriori da classe, dado um vetor de atributos observado. Como $P(Y = c_i | X = x)$ não é fácil de ser estimado, o teorema de Bayes pode ser usado para reescrever esta probabilidade na forma:

$$P(Y = c_i)P(X = x | Y = c_i) = P(X = x)P(Y = c_i | X = x) \quad (3.25)$$

$$P(Y = c_i | X = x) = \frac{P(X = x | Y = c_i)P(Y = c_i)}{P(X = x)} \quad (3.26)$$

Como o denominador continua igual para cada c_i considerado, basta maximizar o numerador, o que leva a:

$$\hat{c} = \arg \max_{c_i} P(X = x | Y = c_i)P(Y = c_i) \quad (3.27)$$

Considera-se aqui $P(Y = c_i)$ como sendo a probabilidade a priori de classe c_i . Assim, $P(Y = c_i) = 1/n$, sendo n o número de classes, onde todas as classes são equiprováveis. No caso de $P(X = x | Y = c_i)$ como a probabilidade do atributo x pertencer à classe c_i o cálculo de $P(X = x | Y = c_i)$ para LDA assume que cada classe tem uma distribuição multivariável normal com media μ_i e todas as classes com a mesma matriz de covariança C . O que pode ser descrito por:

$$P(X = x | Y = c_i) = \frac{1}{2\pi^{\frac{1}{2}} |C|^{\frac{1}{2}}} \exp \left(-\frac{1}{2} (\mathbf{x} - \mu_i)^T \mathbf{C}^{-1} (\mathbf{x} - \mu_i) \right) \quad (3.28)$$

com :

$$\mathbf{C} = E[(\mathbf{x} - \mu_i)(\mathbf{x} - \mu_i)] \quad (3.29)$$

e $|\mathbf{C}|$ denota o determinante de $\mathbf{C}$. Assim, mostra-se que a equação (3.27) pode ser reescrita como:

$$\hat{c} = \arg \max_i f_i(\mathbf{x}) \quad (3.30)$$

onde, devido a forma exponencial da equação (3.28), é preferível trabalhar com a função discriminante $f_i(\cdot)$, que envolve a função (monótona) logarítmica $\ln(\cdot)$:

$$f_i(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \mu_i)^T \mathbf{C}^{-1}(\mathbf{x} - \mu_i) + \ln(P(Y = c_i)) + d_i \quad (3.31)$$

com d_i constante igual a $-(1/2)\ln 2\pi - (1/2)\ln|\mathbf{C}|$. Se, expandirmos a equação 3.31 sem levar em conta as expressões sem relação direta para maximizar a função, tem-se

$$f_i(\mathbf{x}) = \mu_i \mathbf{C}^{-1} \mathbf{x}^T - \frac{1}{2} \mu_i \mathbf{C}^{-1} \mu_i^T + \log(P(Y = c_i)) \quad (3.32)$$

A derivação completa da expressão que caracteriza a LDA está disponível em Theodoridis & Koutroumbas (1999, pp. 12–20). Conforme previsto, a matriz $\mathbf{C}$ é a estimativa combinada de covariância e é calculada segundo as formulas das seguintes equações.

$$S_W = \sum_{i=1}^{C_n} S_i \quad (3.33)$$

para i iterando sobre todas as classes disponíveis (C_n), e:

$$S_i = \sum_{x \in c_i} (\mathbf{x} - \mu_i)(\mathbf{x} - \mu_i)^T \quad | \quad \mu_i = \frac{1}{N_i} \sum_{x \in c_i} x \quad (3.34)$$

sendo N_i o número de elementos na classe c_i . A função $f_i(\cdot)$ é a função discriminante da classe c_i e corresponde a uma projeção linear do vetor de características $\mathbf{x}$. Na sua forma mais geral, a função discriminante linear para a classe c_i pode ser definida como:

$$g_i(\mathbf{x}) = W_i^T \mathbf{x} + b_i \quad (3.35)$$

e o hiperplano é denotado pela equação:

$$W_i^T \mathbf{x} + b_i = 0 \quad (3.36)$$

o qual separa a região de classe c_i do restante espaço de características.


3.4 Sujeitos e aquisição dos dados

Três indivíduos saudáveis (uma mulher e dois homens) nas idades 21-30 anos (idade média 25 anos) se voluntariaram para a aquisição de dados. Foram consideradas apenas pessoas saudáveis dado que o sistema BCI está em fase de protótipo visando, portanto, uma caracterização robusta de desempenho.

Destaca-se aqui que nenhum dos sujeitos tinha experiência prévia com BCI. Os participantes são todos alunos da UNICAMP e a referência aos indivíduos é feita nomeando a primeira letra de seus nomes, sendo P, J e L.

A fim de adquirir, digitalizar e amplificar os sinais de EEG foi utilizado o equipamento g.USBamp da g.tec. Este equipamento possui conexão USB 2.0 e capacidade de capturar 16 canais de biosinais simultaneamente com resolução de 24 bits quando ligado a um computador desktop. O dispositivo é mostrado na figura 3.6(a).


O EEG foi registrado usando uma touca de eletrodos secos. O sistema de eletrodos é conhecido como g.SAHARA da g.tec, e consiste de 16 eletrodos de 8 pinos feitos de uma liga especial de ouro (veja a figuras 3.6(a) e 3.6(b)). Estes eletrodos foram posicionados em 16 locais definidos pelo sistema internacional 10-20, essas posições foram escolhidas por serem consideradas por sua boa resposta SSVEP, são elas: Fz, Cz, Pz, Oz, PO3, PO4, O1, O2, P3, P4, Iz, POz, PO7, PO8, O9, O10. Dois eletrodos de referência foram colocados em cada um dos mastóides, a figura 3.6(c) apresenta o esquema de posicionamento na touca.



(a)



(b)



(c)

Figura 3.6: Equipamento e configuração para captura de EEG.

Antes de iniciar qualquer sessão de aquisição, foi garantido que todos os eletrodos apresentaram valores de impedância abaixo $5K\Omega$, sendo este limite normalmente considerado para gravações de EEG de boa qualidade.

O amplificador foi configurado com um filtro de banda de 0.1-60 Hz e um filtro notch a 60 Hz para todos os canais de EEG, de modo que componentes DC e o ruído sejam reduzidos. Uma frequência de amostragem de 128 Hz foi usada em todas as capturas de dados, fazendo com que a banda de frequências dos sinais capturadas fosse limitada em $f < 64$ Hz. Nota-se aqui que os estímulos visuais utilizados estão na banda de frequências entre 1-30 Hz, de modo que algumas das componentes harmônicas para estes estímulos se perdem, o que justifica a sua não utilização na análise da resposta SSVEP.

O *software* utilizado no computador para a aquisição de sinal foi o BCI2000. Este *software* permitiu criar experimentos com configurações particulares para as capturas de dados. O protocolo utilizado nos experimentos é descrito na próxima seção. Os dados capturados são armazenados em arquivos de formato do próprio BCI2000, e posteriormente foram importados para o MATLAB.

Para a estimulação visual foi utilizado um conjunto de 4 diodos emissores de luz (LEDs brancos). Estes LEDs foram acionados nas quatro frequências 13, 18, 21 e 25 Hz, respectivamente. Estes valores foram escolhidos devido ao foco de estudos anteriores que mostraram que as respostas mais fortes de SSVEP são evocados nessa faixa (Zhu et al. 2010). Cada LED tem uma área de cerca de $0.5 \times 0.5cm$. Os sujeitos foram colocados em uma cadeira confortável com cerca de 0.5 m de distância para os LEDs e a tela do computador. O mesmo nível de luz ambiente foi mantido durante a execução dos experimentos.

3.5 Protocolo e aquisição de sinais

As sessões de captura de dados foram realizadas com os três sujeitos em duas datas diferentes. Em cada data de aquisição quatro sessões diferentes foram realizadas com cinco minutos de intervalo entre elas. As três primeiras sessões foram compostas de quatro execuções separadas por um minuto de pausa, a última sessão só teve três exposições. No mesmo dia foram realizadas 14 exposições.

Cada execução é por sua vez composta de 25 ensaios associados a 5 diferentes tarefas. Assim, um total de $14 \times 25 = 350$ ensaios por dia foi realizado, sendo $350/5 = 70$ o número total de ensaios de cada dia para cada tarefa por sujeito. Cada conjunto de dados da aquisição de um dia foi utilizado para realizar o treinamento e teste do conjunto de algoritmos de processamento e classificação.

Durante um ensaio o sujeito é solicitado a executar uma tarefa de concentração num estímulo visual ou para permanecer relaxado com base nas imagens exibidas na tela do computador. Durante cada execução o sujeito foi instruído para permanecer o mais imóvel possível, evitando induzir algum tipo de artefato no sinal capturado. As imagens consideradas e suas tarefas correspondentes são as seguintes:

- Seta para a esquerda: olhar o LED da esquerda da tela,

- Seta para a direita: olhar o LED da direita da tela;
- Seta para cima: olhar o LED de cima da tela;
- Seta para baixo: olhar o LED de baixo da tela;
- Mensagem na tela : condição de repouso.

Cada imagem é exibida continuamente por 6s, depois desse intervalo a tela fica branca por 1.5s antes da próxima imagem aparecer. Quando estiver na condição de repouso o sujeito pode descansar os olhos, mas é quando se dá pausa entre execuções que ele tem um tempo para alongar-se e movimentar-se um pouco.

A Figura 3.7 mostra um diagrama de tempos do protocolo BCI utilizado para as sessões realizadas.




Figura 3.7: Tempos do protocolo para aquisição de dados. Fonte: Adaptado de DALbis (2008).

3.6 Teste do sistema BCI

O desempenho de um sistema BCI pode ser influenciado por vários fatores: o paradigma experimental, o protocolo operacional, os padrões cerebrais, os recursos selecionados, tipo de classificador, a presença de realimentação, a aplicação, etc. Para comparar diferentes sistemas BCI, é necessário definir critérios de avaliação coerentes.

A seguir são definidos os critérios de avaliação para medir o desempenho do sistema BCI.

A matriz de confusão e a precisão global de classificação. Para um problema de classificação multi-classe, os resultados são usualmente descritos por meio da matriz de confusão. Onde cada elemento n_{ij} desta matriz indica quantas amostras da classe i foram classificadas como da classe j .

Uma vez que não é fácil comparar matrizes de confusão foram introduzidas medidas mais diretas para avaliar o desempenho de classificação. A mais utilizada neste caso é a precisão global de classificação p_o :

$$p_o = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (3.37)$$

onde M é o número de classes e N é o número total de amostras:

$$N = \sum_{i=1}^M \sum_{j=1}^M n_{ij} \quad (3.38)$$

O problema com a precisão global é que os valores de fora da diagonal da matriz de confusão não são considerados. Por exemplo, se as verdadeiras classes ocorrem com frequências diferentes, as classes menos frequentes seriam responsáveis com pesos menores na precisão final. Esta medida não permite comparar diretamente classificadores com diferente número de classes uma vez que o nível de precisão muda para $1/M$.

A precisão específica para cada classe i pode ser calculada a partir da matriz de confusão da seguinte maneira:

$$p_i = \frac{2n_{ii}}{\sum_{j=1}^N n_{ij} + \sum_{j=1}^N n_{ji}} \quad (3.39)$$

onde $\sum_{j=1}^N n_{ji}$ é a soma da coluna i -ésima e $\sum_{j=1}^N n_{ij}$ é a soma da i -ésima linha da matriz de confusão.

Finalmente, de acordo com as definições feitas neste capítulo foram descritos os métodos utilizados para construir o sistema SSVEP-BCI proposto neste trabalho, também foi descrita a metodologia usada nos diferentes experimentos para o teste do sistema. No próximo capítulo são apresentados os resultados para os três indivíduos que participaram deste estudo.

Resultados

Neste capítulo, as estratégias propostas no capítulo de Métodos e Materiais são comparadas e a eficácia de classificação de cada método é medida. Primeiramente, uma análise visual da resposta nos permite observar as características gerais do padrão SSVEP entre os indivíduos e verificar o grau de dificuldade em manipular estes atributos devido a ruído e artefatos. Depois de analisar esta resposta, as seguintes seções mostram os resultados para as diferentes estratégias utilizadas para a classificação dos dados.

- A seção 4.2 apresenta os resultados da estratégia 1 (Seleção de atributos nas frequências de estimulação sem seleção de eletrodos);
- A Seção 4.3 apresenta os resultados da estratégia 2 (Seleção de atributos procurando eletrodos pelo valor do índice DB);
- A Seção 4.4 apresenta os resultados da estratégia 3 (Livre escolha dos atributos segundo os valores do índice DB)

4.1 Análise Espectral

Os dados de EEG registrados foram analisados no domínio da frequência, com o intuito de encontrar características úteis para discriminar cinco classes: estímulo 1 (LED acima - 18 Hz), estímulo 2 (LED embaixo - 21 Hz), estímulo 3 (LED à esquerda - 25 Hz), estímulo 4 (LED à direita - 13 Hz) e repouso. Análises offline a partir de 16 canais de EEG foram realizadas para encontrar padrões relevantes de ativação sujeito-dependentes. Foram analisados três sujeitos saudáveis: J, P e L.

O primeiro sujeito analisado foi o sujeito J (figuras 4.1, 4.2, 4.3). A obtenção da densidade espectral de potência (PSD) foi realizada usando a estimativa de Welch disponível em MATLAB. O espectro na figura representa a densidade espectral média sobre vários segmentos de experimento. Os parâmetros usados para o cálculo do PSD foram os seguintes: função de janela de Hamming considerando segmentos de 128 pontos (o que equivale a 1s de comprimento de sinal), 50% de sobreposição entre segmentos (64 pontos), e 384 pontos (3s) para cálculo da FFT. Como o comprimento da FFT era maior do que o comprimento do segmento, a técnica de

preenchimento com zeros (zero-padding) foi utilizada. Assim, a resolução obtida foi de 0.33 Hz, o que foi suficiente para diferenciar graficamente as frequências utilizadas no experimento. Um menor valor de resolução foi usado nas seguintes seções onde foram feitos os cálculos usando 128 pontos (1 seg) para o cálculo da FFT, deste modo obteve-se uma resolução de 1 Hz. A melhor resolução espectral usada nesta seção permite observar melhor o comportamento da figura do espectro de frequência, enquanto a situação de menor resolução, permite lidar com um número menor de atributos, sem, no entanto perder informação nos pontos do espectro analisados.

As figuras 4.1, 4.2, 4.3 apresenta a estimativa da PSD para o sujeito J. A classe 2 se refere aos dados obtidos para a frequência de estimulação $f = 21Hz$, classe 3 para $f = 25Hz$, e classe 4 para $f = 13Hz$. Cada figura da PSD apresenta dois espectros, cada uma das classes versus o repouso. Assim foi possível identificar situações mais estáveis e outras mais ruidosas (o que provavelmente pode estar associado com a perda de atenção ao estímulo). Por exemplo, para o sujeito J a resposta para a classe 2 (21 Hz) não é muito perceptível, observando apenas que, o canal 6 (eletrodo PO4) tem uma pequena atividade. No caso da classe 3 (25Hz), os canais 4 (Oz), 6 (PO4) e 7 (O2) exibem atividades aparentemente mais intensas, o que também é válido para a classe 4 (13Hz). A presença de atividade para estes canais é coerente com a área do córtex visual, região tida como proeminente na resposta SSVEP. Um aumento de amplitude da resposta perto as regiões de 10 e 20 Hz também foi observado.

Para o sujeito P as figuras 4.4, 4.5, 4.6, apresentam a PSD para as três classes mencionadas. A resposta apresentou um forte incremento de seu valor perto de 20 Hz, e, em alguns canais (4 a 8), perto de 11 Hz. Para a classe 2, foi possível notar atividade mais intensa na frequência de estimulação para os canais 4 (Oz) e 7(O1). Em relação a classe 3, não foi possível notar visualmente um incremento significativo na frequência de estímulo. Já para a classe 4 a atividade dos canais 4(Oz), 7(O1) e 8(O2) aumentou acentuadamente nas frequências de estimulação.

Na resposta do sujeito L (figuras 4.7, 4.8, 4.9) a PSD para a classe 2 mostra que existe uma atividade para a frequência de estimulação nos canais 4 e 5-8. Para a classe 3 não foi possível observar alguma atividade que realmente possa se distinguir do repouso, mas também não se observa ruído em forma de atividade que interfere com outros pontos do espectro de frequência. A classe 4 apresenta atividade notável nos canais 3-8. A resposta em geral mantém uma atividade que não é muito proeminente nas frequências de estimulação, ou mesmo em outros pontos do espectro, o que talvez seja parte da resposta própria do indivíduo ou mesmo devido ao fato da situação de repouso sofrer de influência (mesmo que apenas da visão periférica) de todos os estímulos visuais. Contudo, foi possível encontrar visualmente atividade em 3 das 4 classes; Estas características eventualmente permitiram que a classificação fosse feita de forma correta.




Figura 4.1: Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.




Figura 4.2: Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.




Figura 4.3: Densidade do espectro de frequência para o sujeito J para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.




Figura 4.4: Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.




Figura 4.5: Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.




Figura 4.6: Densidade do espectro de frequência para o sujeito P para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.




Figura 4.7: Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class2 (21 Hz) vs. Repouso.




Figura 4.8: Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class3 (25 Hz) vs. Repouso.




Figura 4.9: Densidade do espectro de frequência para o sujeito L para diferentes canais. Eixo X (Potencia, V^2). Eixo Y (Frequencia, Hz). Class4 (13 Hz) vs. Repouso.

Deve-se destacar que as figuras da PSD apresentadas mostram uma comparação entre a resposta dos sujeitos no estado de repouso e nos estados de atenção ao estímulo. Assim, foi possível ver que no repouso a resposta também se vê afetada pelo ruído, e também que o sujeito foi sempre exposto aos estímulos, no caso do repouso por meio da visão periférica. Isto possivelmente poderia afetar a qualidade da resposta, justificando a dificuldade em diferenciar

estes espectros.

A partir da análise efetuada para estes sujeitos foi possível observar que existe uma resposta nas frequências de estimulação, mas, em alguns casos, esta não foi suficientemente intensa e diferiu entre indivíduos. A seguir apresentam-se os resultados da classificação obtidos ao utilizar diferentes estratégias de seleção de atributos. De acordo com estes resultados foi possível determinar a estratégia mais eficaz para resolver este problema de classificação.

4.2 Seleção de atributos nas frequências de estimulação sem seleção de eletrodos

A figura 4.10 ilustra por meio de um diagrama de blocos a estratégia utilizada para transformar os sinais de EEG num conjunto de atributos e um sinal de controle como saída do classificador. No presente projeto, na saída do bloco extração de características são obtidos os vetores de atributos que representam os coeficientes da PSD. O cálculo da PSD foi executado a partir do método de Welch com os seguintes parâmetros: segmentos de 6 segundos (768 pontos de sinal) sobre os quais aplica-se uma divisão de 8 janelas sobrepostas em 50%, cada janela usou a função de Hamming e foi realizada sobre $(768/8 = 96)$ pontos de sinal). O número de pontos da FFT foi de 128, obtendo assim uma resolução espectral de 1 Hz. Considerando apenas os coeficientes de frequência inferior a 31 Hz, foram obtidos 32 coeficientes, cada um representando um ponto de espectro de frequência a cada 1 Hz. Assim, desses 32 pontos, apenas 4 correspondem às frequências de estimulação em cada eletrodo.




Figura 4.10: Diagrama do blocos do transdutor BCI.

A primeira análise feita consistiu em criar um vetor de características sem usar nenhuma métrica para considerar a qualidade de cada atributo para compor o vetor de atributos. Diferentes vetores foram criados, escolhendo progressivamente quatro pontos do espectro de frequência para as frequências de estimulação dos 16 eletrodos utilizados. A sequência de eletrodos foi ascendente (1,2,...) até completar 64 atributos (4 pontos * 16 eletrodos).

Considerando cinco classes para classificação, tem-se que cada classe possui 70 segmentos de 6 segundos, sobre os quais foi executado a extração de características. Obteve-se, assim, 70 possíveis vetores de características por classe, com um total de 350 possíveis vetores de características para todas as classes.

Depois de obtidos os atributos e os vetores de características tem-se o estágio de classificação. Este bloco executa esta tarefa usando um classificador baseado em LDA (tal como implementado na função `classify` do MATLAB). Do total de dados foram separados dois conjuntos, um para treinamento e outro para teste. Um esquema de validação cruzada também foi realizado com 200 repetições, produzindo um erro de classificação médio ($\pm I$ desvio padrão). A seguir são apresentados os resultados obtidos para o erro de classificação global, e de cada classe. A tabela 4.1 apresenta os resultados de cada um dos indivíduos que realizaram os experimentos.

Os resultados apresentam o desempenho de classificação para os três sujeitos em três condições do vetor de atributos, usando 4, 16 ou 64 atributos. Para os indivíduos J e L taxas de acerto superiores a 80%, tanto global como para cada classe, foram obtidos a partir da utilização de 16 eletrodos. O sujeito P teve taxas de acerto de classificação próximas de 70%, para algumas das classes utilizando 16 atributos, sendo que para 64 atributos os resultados atingem uma taxa de acerto de 98% para todos os sujeitos. No caso de 4 atributos o desempenho atinge apenas 20% de taxa de acerto.

4.3 Seleção de atributos usando a seleção de eletrodo pelo valor do índice DB

Depois de ter criado vetores de características sem a utilização de uma técnica para a seleção dos melhores atributos, esta seção apresenta um critério para tal tarefa, utilizando o índice de Davies-Bouldin (DB).

O índice DB é usado como uma medida da qualidade de um atributo na discriminação das classes. O cálculo do índice DB foi feito tomando os 32 coeficientes do espectro de frequência dos 16 eletrodos, totalizando 512 atributos (16 eletrodos * 32 pontos de espectro de frequência). Os valores dos índices de DB de cada eletrodo para todos os coeficientes em frequência foram somados, e esse resultado foi tomado como medida de qualidade na seleção dos eletrodos. Assim, de acordo com a soma, foi organizada uma lista decrescente (do melhor para o pior eletrodo) para a seleção de atributos. A seguir apresentam-se as figuras 4.11, 4.12 e 4.13 onde observa-se o mapa de coeficientes $DB_{inv} = 1/DB$ para cada indivíduo.

Tabela 4.1: Desempenho geral do erro de classificação - Método 1.

Sujeito	No. de atributos	Total (Media / Dev.std)	Class 1 (Media / Dev.std)	Class 2 (Media / Dev.std)	Class 3 (Media / Dev.std)	Class 4 (Media / Dev.std)
J	4	0.616 / 0.043	0.651 / 0.094	0.133 / 0.07	0.896 / 0.062	0.9 / 0.066
	16	0.081 / 0.025	0.084 / 0.051	0.004 / 0.016	0.091 / 0.066	0.153 / 0.078
	64	0.0003 / 0.001	0.0007 / 0.005	0 / 0	0.0006 / 0.005	0 / 0
	Melhor	0 / 0				
L	4	0.729 / 0.038	0.907 / 0.071	0.38 / 0.126	0.922 / 0.055	0.901 / 0.06
	16	0.092 / 0.026	0.051 / 0.045	0 / 0	0 / 0	0.136 / 0.069
	64	0.008 / 0.008	0.012 / 0.024	0.0005 / 0.005	0.016 / 0.024	0.004 / 0.015
	Melhor	0.003 / 0.003				
P	4	0.769 / 0.032	0.766 / 0.14	0.818 / 0.22	0.7 / 0.288	0.745 / 0.258
	16	0.147 / 0.028	0.081 / 0.049	0.31 / 0.091	0.011 / 0.022	0.283 / 0.091
	64	0.011 / 0.007	0.022 / 0.025	0.003 / 0.011	0.0002 / 0.002	0.014 / 0.02
	Melhor	0.007 / 0.007				




Figura 4.11: Mapa de coeficientes DB_{inv} para sujeito J.




Figura 4.12: Mapa de coeficientes DB_{inv} para sujeito L.




Figura 4.13: Mapa de coeficientes DB_{inv} para sujeito P.

Nas figuras apresenta-se os valores do inverso do índice DB (DB_{inv}) de modo que os pontos do mapa (eletrodo x frequência) com os valores mais altos indicam um coeficiente com boas características para a separação das classes. É possível ver que, para cada um dos diferentes sujeitos, há uma atividade significativa para diferentes eletrodos, assim coeficientes de alto valor também aparecem em diferentes pontos através do espectro de frequência. Além disso, nota-se que existe uma forte atividade em torno das frequências de estimulação, mas também em outros pontos do espectro.

Por exemplo, na figura 4.11 (sujeito J), o eletrodo 11 (Iz) possui uma boa discriminabilidade segundo seus valores de índice DB_{inv} . Também destacam-se para este sujeito os eletrodos 4 (Oz), 6 (PO4), 10 (P4) e 12 (POZ). No caso do sujeito L (figura 4.12) destacam-se o eletrodo 15 (O9) e 11 (Iz). Para o sujeito P (figura 4.13) os eletrodos mais relevantes foram o eletrodo 9 (P3) e 7 (O1). Estes resultados estão em conformidade com as expectativas sobre determinadas áreas de ativação cerebral onde a atividade SSVEP tem maior ativação.

Seguindo essa estratégia de seleção, os resultados da classificação são apresentados na tabela 4.2. Cada combinação de vetores de atributos foi criada ao fazer uma contínua união de quatro atributos (coeficientes do espectro de frequência para as quatro frequências de estimulação) de cada um dos eletrodos de acordo com sua posição na lista de desempenho do índice DB_{inv} .

Os resultados de desempenho de classificação mostram para um vetor de atributos de tamanho 16, foram atingidas taxas de acerto próximas de 89% e 100% para algumas classes e sujeitos. No caso de se utilizar 4 atributos, o resultado é muito diferente em cada sujeito, em alguns casos, os valores de taxa de acerto de classificação estão entre 60 e 70%, mas em outros apenas em 10%.

Tabela 4.2: Desempenho geral do erro de classificação - Método 2.

Sujeito	No. de atributos	Total (Media / Dev.std)	Class 1 (Media / Dev.std)	Class 2 (Media / Dev.std)	Class 3 (Media / Dev.std)	Class 4 (Media / Dev.std)
J	4	0.409 / 0.042	0.487 / 0.112	0.333 / 0.104	0.256 / 0.09	0.392 / 0.094
	16	0.027 / 0.018	0.016 / 0.016	0 / 0	0.011 / 0.022	0.079 / 0.07
	64	0.0004 / 0.001	0.0007 / 0.006	0 / 0	0.001 / 0.007	0 / 0
	Melhor	0 / 0				
L	4	0.513 / 0.044	0.721 / 0.097	0.017 / 0.024	0.559 / 0.112	0.6 / 0.106
	16	0.09 / 0.026	0.062 / 0.052	0 / 0	0.191 / 0.089	0.151 / 0.079
	64	0.009 / 0.01	0.016 / 0.028	0.0008 / 0.006	0.013 / 0.022	0.005 / 0.017
	Melhor	0.005 / 0.005				
P	4	0.34 / 0.04	0.264 / 0.087	0.013 / 0.019	0.364 / 0.09	0.609 / 0.079
	16	0.051 / 0.018	0.123 / 0.061	0.01 / 0.02	0.0006 / 0.005	0.044 / 0.036
	64	0.01 / 0.007	0.023 / 0.027	0.003 / 0.011	0 / 0	0.014 / 0.019
	Melhor	0.008 / 0.008				

4.4 Livre escolha dos atributos segundo os valores do índice DB_{inv}

Finalmente, foi testada uma estratégia para a seleção de atributos removendo a restrição pela escolha destes pontos por sua localização apenas nas frequências de estimulação do espectro de frequência. Assim, qualquer atributo que se destaca por um alto valor do coeficiente de DB pode ser selecionado para fazer parte do vetor de atributos. A seguir apresentam-se os resultados do desempenho de classificação (% de erro de classificação) obtidos com esta estratégia (Tabela 4.3).

Os resultados mostram que para os três indivíduos foi observado que o uso de 4 atributos no vetor de características fornece uma taxa de acerto de 50 a 80% para cada uma das classes. Já com 16 atributos é alcançada uma precisão da classificação de quase 98%.

A seguir apresentam-se os resultados que foram obtidos ao realizar a comparação entre o desempenho de classificação das três estratégias utilizadas. A figura 4.14 mostra a evolução dos resultados da classificação que cada estratégia obteve ao usar mais atributos no vetor de características.

Para o sujeito J (figura 4.14(a)) os resultados da comparação das três técnicas usadas para a seleção dos atributos do vetor de características mostraram que, a partir de um certo número de atributos selecionados as três estratégias estabilizam-se no mesmo valor do erro de classificação, isto é, próximo de 100% de acerto o que ocorre em torno de 20 atributos para este sujeito. Enquanto isso, a estratégia de seleção de atributos usando apenas a medida do índice DB_{inv} mostrou-se como a mais rápida na obtenção de baixos erros de classificação, o que se justifica com o uso de apenas 5 atributos para a obtenção de uma taxa de acerto 80%.


No caso do sujeito L (figura 4.14(b)) a seleção de atributos utilizando a seleção de eletrodos é a estratégia mais rápida para obter erros de classificação baixos, o que se justifica com o uso de dois atributos para a obtenção de 80% de acerto. A partir de 18 atributos as três estratégias são muito próximas em desempenho com valores próximos a 90% de taxa de acerto.

Para o sujeito P (figura 4.14(c)), verificou-se que as duas estratégias que usaram o índice DB_{inv} conseguiram resultados muito próximos para a taxa inicial de redução do erro de classificação, sendo que com 5 atributos, a taxa de acerto esteve próxima de 80%. Depois deste comportamento inicial, a estratégia de seleção de eletrodos piorou em desempenho para finalmente estabilizar a partir de 30 atributos com 90% de acerto, assim como as demais estratégias.


Os resultados mostraram que todos os sujeitos alcançaram taxas de acerto de cerca de 90% utilizando entre 10 e 20 atributos, sendo que cada um apresentou uma estratégia diferente como a mais bem-sucedida sobre as demais utilizadas. Em geral, o uso da medida do índice DB_{inv} sempre resultou em resultados de erro de classificação que caíram de forma mais rápida contra a estratégia que não utilizou nenhuma métrica para seleção de atributos.

Tabela 4.3: Desempenho geral do erro de classificação - Método 3.


Sujeito	No. de atributos	Total (Media / Dev.std)	Class 1 (Media / Dev.std)	Class 2 (Media / Dev.std)	Class 3 (Media / Dev.std)	Class 4 (Media / Dev.std)
J	4	0.352 / 0.044	0.389 / 0.102	0.214 / 0.082	0.256 / 0.103	0.473 / 0.091
	16	0.077 / 0.028	0.004 / 0.016	0.140 / 0.083	0.089 / 0.068	0.08 / 0.056
	64	0.004 / 0.006	0 / 0	0 / 0	0.043 / 0.013	0.019 / 0.03
	Melhor	0.002 / 0.004				
L	4	0.22 / 0.041	0.337 / 0.104	0.014 / 0.024	0.208 / 0.08	0.25 / 0.1
	16	0.121 / 0.03	0.054 / 0.016	0.002 / 0.01	0.213 / 0.092	0.122 / 0.073
	64	0.019 / 0.012	0.009 / 0.022	0.015 / 0.023	0 / 0	0.032 / 0.039
	Melhor	0.019 / 0.012				
P	4	0.3 / 0.033	0.323 / 0.087	0 / 0	0.223 / 0.081	0.469 / 0.084
	16	0.133 / 0.027	0.078 / 0.049	0.002 / 0.007	0.064 / 0.041	0.218 / 0.082
	64	0.01 / 0.008	0.008 / 0.018	0 / 0	0 / 0	0.009 / 0.018
	Melhor	0.01 / 0.008				



(a)



(b)



(c)

Figura 4.14: Desempenho de erro de classificação para as diferentes estratégias de seleção de atributos. a) Sujeito J, b) Sujeito L, c) Sujeito P.

Tabela 4.4: Comparação do número de atributos necessários em cada uma das técnicas usadas e dos sujeitos participantes para um erro de classificação de 10%.

Sujeitos	Estratégias		
	1	2	3
J	16	12	13
L	17	13	13
P	30	6	30


A tabela 4.4 apresenta os resultados da comparação do número de atributos necessários em cada uma das técnicas usadas para cada sujeito. Assim, é possível observar as diferenças entre os sujeitos nos resultados para um valor de erro de 10%. Nota-se que as diferenças do número de atributos não são significativas. Entretanto, a técnica com melhores resultados foi a que utilizou o índice Davies Bouldin e a seleção dos atributos tomando-se todo o espectro de frequência.

Mas uma comparação do desempenho de classificação foi realizada e se apresenta na figura 4.15 onde observou-se a taxa de acerto para cada sujeito considerando as três estratégias utilizadas para 16 e 64 atributos. No caso de 16 atributos (figura 4.15(a)) o sujeito J (sujeito 1 na figura), exibiu taxas ligeiramente mais elevadas do que os outros dois sujeitos. Em geral, para este número de atributos, os valores de precisão das três técnicas são muito próximos, sendo que a técnica 2 (seleção de eletrodos utilizando o índice de DB_{inv}) obteve melhor desempenho para os três sujeitos. No caso da técnica 1, (nenhum método para a seleção de atributos) e 3 (técnica que utiliza apenas os atributos com melhor valor do índice DB_{inv}) observa-se praticamente o mesmo desempenho dado este número de atributos.


4.5 Considerações finais

Segundo os resultados apresentados nesta seção, para o projeto de um sistema SSVEP-BCI como o apresentado neste trabalho de pesquisa foi constatado que o uso de extração de características no domínio da frequência permite caracterizar o sinal e sua resposta SSVEP. O método de Welch apresentou restrições por ser um estimador da potência espectral parcial, mas seu baixo custo computacional o torna atraente para esta aplicação. O mesmo vale para os métodos usados para seleção de características os quais ajudaram a reduzir a complexidade do classificador, embora também foram utilizados para tentar reduzir a influência do ruído no sinal tratado. O índice de Davies-Bouldin foi utilizado para a análise off-line dos atributos. Assim, ao encontrar os pontos de frequência e os canais mais promissores para a separação das classes, foi obtida uma taxa de acerto de classificação de 70% com apenas quatro atributos empregados para a separação de cinco classes. Estes resultados promissores demonstram que a utilização das técnicas adotadas neste trabalho são recomendados para este tipo de sistema BCI. Entretanto, considerando os resultados obtidos, é recomendável continuar a pesquisa de técnicas complementares para uma redução mais significativa do ruído, bem como a avaliação de heurísticas eficazes para a seleção de atributos.

Outras conclusões estão voltadas para o estudo da frequência de estimulação em que uma boa resposta foi encontrada para os usuários, mas foi observado diferentes respostas entre os



(a)



(b)

Figura 4.15: Desempenho de porcentagem de acerto de classificação para as diferentes estratégias de seleção de atributos. a) Para vetor de atributos com N=16. b) Para vetor de atributos com os melhores resultados.

sujeitos. A experiência também indica a influência da intensidade do estímulo que reflectiu nos resultados dos experimentos. Estes experimentos mostraram uma grande interferência entre cada uma das respostas quando a intensidade da fonte luminosa era elevada, que gera uma percepção relativamente desconfortável para os olhos.

Também a partir deste trabalho, podemos observar que o uso de técnicas simples permite a classificação de quatro estímulos com velocidade suficiente para operar o sistema em tempo real. Entretanto, são necessários estudos adicionais visando aumentar o número de estímulos, bem como a velocidade de classificação para se obter uma resposta rápida ao estímulo.

Conclusões e Perspectivas

Nesta dissertação de mestrado uma interface Cérebro-Computador (BCI) foi construída e estudada a partir da utilização do paradigma SSVEP. Essencialmente, observou-se aqui a típica resposta evocada no córtex visual obtida a partir do EEG de superfície e de fontes luminosas externas. Foram utilizadas estratégias para a seleção de atributos e para classificação com o intuito de associar os estímulos visuais com comandos externos sem a utilização dos usuais referentes biológicos. Os experimentos aqui conduzidos baseiam-se em estratégias de processamento off-line, com boa perspectiva de implementação em tempo real em um futuro próximo.

Em princípio, o desenvolvimento do sistema pautou-se por entender melhor os paradigmas mais usais em BCI (P300, imaginação de movimento, potenciais corticais lentos, SSVEP, entre outros), e, em seguida, decidiu-se pelo paradigma SSVEP devido sua facilidade de implementação e pouca necessidade de treinamento por parte do usuário.

Do ponto de vista da implementação da interface, inicialmente foi construída uma plataforma para estimulação visual baseada em LEDs, a partir da qual foi possível analisar as características fundamentais do paradigma SSVEP. Posteriormente estudou-se formas eficientes de se realizar a extração de características: por meio da análise espectral - utilizando o método de Welch; seleção das características utilizando uma medida de discriminante das classes (inverso do índice DB); e classificação baseada na análise do discriminante linear.

O resultado obtido ao estudar graficamente a densidade espectral de potência é claro ao indicar a variabilidade da resposta entre os sujeitos. A influência do ruído é forte e varia para cada um dos eletrodos, e entre os sujeitos. Dentre as principais desvantagens, foi observado nos experimentos a dificuldade de permanecer continuamente olhando para a tela por um período de tempo. Além disso, observou-se no gráfico do espectro de potência para todos os três indivíduos um componente comum em 10 Hz, e às vezes, também em 20 Hz, o qual parece atípico da resposta SSVEP, e pode ser causado por alguma fonte de ruído externo.

Do ponto de vista de processamento de sinais foram propostas três estratégias diferentes para a seleção de atributos. Os resultados obtidos foram satisfatórios na medida em que taxas de acerto elevadas foram atingidas. A importância de obter estes resultados permite concluir que, finalmente, um classificador robusto com LDA pode ser implementado como proposto nesta pesquisa. A contribuição deste trabalho destaca-se por conseguir fazer a classificação com a seleção de características usando um pequeno número de atributos. Desta forma, o treinamento

pode ser simplificado, o que influencia o número de testes necessários, e reduz a complexidade do sistema para a aplicação em tempo real.

Perspectivas

Dentre as principais perspectivas deste trabalho podemos citar:

- Estudar a melhora de desempenho quando alguma abordagem de filtragem espacial é empregada tal como as aborgagens fundamentadas em análise de componentes principais;
- estudar a possibilidade de aumentar a ITR diminuindo o tempo utilizado em cada *trial* para caracterizar um estímulo;
- estudar o desempenho de outras estruturas de classificação tais como redes neurais artificiais e máquinas de vetores suporte;
- desenvolver um classificador para operar em tempo real.

Diante desses aspectos, concluímos que este primeiro estudo e desenvolvimento abriram uma grande linha de perspectivas interessantes, o que condiz com os propositos e objetivos desta dissertação de mestrado

Publicações

Um Sistema para Brain-Computer Interface (BCI) Baseado em SSVEP. Luisa Fernanda Suarez , Eleri Cardozo, Diogo C. Soriano. Encontro de Alunos e Docentes do DCA (EADCA 2013), Departamento de Engenharia de Computação e Automação Industrial (DCA), da Faculdade de Engenharia Elétrica e de Computação (FEEC) da Universidade Estadual de Campinas (Unicamp). <http://www.dca.fee.unicamp.br/portugues/pesquisa/seminarios/2013/>

Um Sistema para Brain-Computer Interface (BCI) Baseado em SSVEP. Luisa Fernanda Suarez, Eleri Cardozo, Diogo C. Soriano . 4º Simpósio de Processamento de Sinais da UNICAMP (SPS-UNICAMP 2013). Faculdade de Engenharia Elétrica e de Computação (FEEC) da Universidade Estadual de Campinas (Unicamp). <http://www.sps.fee.unicamp.br/>

Music versus motor imagery for BCI systems. A study using fMRI and EEG: preliminary results. Diogo Soriano, Luisa FS Uribe, Guilherme Coelho, Eric Rohmer, Fernando Von Zuben, Ricardo Suyama, José Raimundo de Oliveira, Romis Attux, Elvis L Silva, Gabriel F Slenes, Fabricio O Lima, Thiago D Venâncio, Guilherme C Beltramini, Brunno M Campos, Carlos AS Anjos, Li M Li, Roberto JM Covolan, Gabriela Castellano. Biosignals and Biorobotics Conference (BRC), 2013 ISSNIP. Rio de Janeiro, Brazil, 2013.

Bibliografia

- Barreto, A. B., Scargle, S. D. & Adjouadi, M. (2000). A practical EMG-based human-computer interface for users with motor disabilities., *Journal of rehabilitation research and development* **37**(1): 53–63.
- Bashashati, A., Fatourechi, M., Ward, R. K. & Birch, G. E. (2007). A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals., *Journal of neural engineering* **4**(2): R32–57.
- Bin, G., Gao, X. & Wang, Y. (2009). VEP-based brain-computer interfaces: time, frequency, and code modulations, *Computational Intelligence Magazine, IEEE* **4** , **Issue:**(November): 22–26.
- Bin, G., Gao, X., Yan, Z., Hong, B. & Gao, S. (2009). An online multi-channel SSVEP-based brain-computer interface using a canonical correlation analysis method., *Journal of neural engineering* **6**(4): 046002.
- Brunner, C., Andreoni, G. & Bianchi, L. (2011). BCI Software Platforms, *Towards Practical Brain-Computer Interfaces*, Springer Berlin Heidelberg, pp. 303–331.
- Calhoun, G. L. & McMillan, G. R. (1996). Eeg-based control for human-computer interaction, *Proceedings of the 3rd Symposium on Human Interaction with Complex Systems (HICS '96)*, HICS '96, IEEE Computer Society, Washington, DC, USA, pp. 4–.
- Cincotti, F., Mattia, D., Aloise, F. & Bufalari, S. (2008). Non-invasive braincomputer interface system: towards its application as assistive technology, *Brain research bulletin* **75**(6): 796–803.
- Daugman, J. G. (1985). Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters, *Journal of The Optical Society of America A-optics Image Science and Vision* **2**.
- Davies, D. L. & Bouldin, D. W. (1979). A cluster separation measure, *Pattern Analysis and Machine Intelligence, IEEE Transactions on* **PAMI-1**(2): 224–227.

- Dornhege, G., Krauledat, M., Müller, K.-R. & Blankertz, B. (2007). General Signal Processing and Machine Learning Tools for BCI Analysis, *Toward Brain-Computer Interfacing*, Eds. Cambridge, Massachusetts: The MIT Press, pp. 207–234.
- Fabiani, G. E., McFarland, D. J., Wolpaw, J. R. & Pfurtscheller, G. (2004). Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **12**(3): 331–8.
- Friman, O., Volosyak, I. & Gräser, A. (2007). Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces, *IEEE transactions on bio-medical engineering* **54**(4): 742–750.
- Gao, X., Xu, D., Cheng, M. & Gao, S. (2003). A BCI-based environmental controller for the motion-disabled., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **11**(2): 137–40.
- Glennen, S. & DeCoste, D. C. (1997). *The handbook of augmentative and alternative communication.*, Singular Pub. Group.
- Grosse-Wentrup, M. & Buss, M. (2008). Multiclass common spatial patterns and information theoretic feature extraction, *IEEE transactions on bio-medical engineering* **55**(8): 1991–2000.
- Guger, C., Schlögl, A., Neuper, C., Walterspacher, D., Strein, T. & Pfurtscheller, G. (2001). Rapid prototyping of an EEG-based brain-computer interface (BCI), *IEEE transactions on neural systems and rehabilitation engineering* **9**(1): 49–58.
- Hubel, D. H. & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex, *The Journal of Physiology* **160**(1): 106–154.
- Iscan, Z., Özkaya, O. & Dokur, Z. (2011). Classification of EEG in a Steady State Visual Evoked Potential Based Brain Computer Interface Experiment, pp. 81–88.
- Johnson, D. H. (2013). Statistical signal processing. Rice University. Houston, Texas, USA.
- Jones, J. P. & Palmer, L. (1987). An evaluation of the two-dimensional Gabor filter model of simple receptive fields in cat striate cortex., *Journal of neurophysiology* **58**(6): 1233–58.
- Joon Kim, Y., Grabowecy, M., Paller, K. A., Muthu, K. & Suzuki, S. (2007). Attention induces synchronization-based response gain in steady-state visual evoked potentials, *Nature Neuroscience* **10**(1): 117.
- Lin, Z., Zhang, C., Wu, W. & Gao, X. (2007). Frequency recognition based on canonical correlation analysis for SSVEP-based BCIs., *IEEE transactions on bio-medical engineering* **54**(6 Pt 2): 1172–6.

- Manolakis, D. G., Ingle, V. K. & Kogan, S. M. (2000). *Statistical and adaptive signal processing: spectral estimation, signal modeling, adaptive filtering, and array processing*.
- Mason, S. G., Bashashati, A., Fatourech, M., Navarro, K. F. & Birch, G. E. (2007). A comprehensive survey of brain interface technology designs., *Annals of biomedical engineering* **35**(2): 137–69.
- Middendorf, M., McMillan, G., Calhoun, G. & Jones, K. S. (2000). Brain-computer interfaces based on the steady-state visual-evoked response., *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **8**(2): 211–4.
- Millán, J. D. R., Rupp, R., Müller-Putz, G. R., Murray-Smith, R., Giugliemma, C., Tangermann, M., Vidaurre, C., Cincotti, F., Kübler, a., Leeb, R., Neuper, C., Müller, K.-R. & Mattia, D. (2010). Combining Brain-Computer Interfaces and Assistive Technologies: State-of-the-Art and Challenges., *Frontiers in neuroscience* **4**(September): 1–15.
- Muller-Putz, G. & Pfurtscheller, G. (2008). Control of an electrical prosthesis with an SSVEP-based BCI, *Biomedical Engineering, IEEE Transactions on* **55**(1): 361–364.
- Ng, K. B., Bradley, A. P. & Cunnington, R. (2012). Stimulus specificity of a steady-state visual-evoked potential-based brain-computer interface., *Journal of neural engineering* **9**(3): 036008.
- Ortner, R., Allison, B. Z., Korisek, G., Gagg, H. & Pfurtscheller, G. (2011). An SSVEP BCI to control a hand orthosis for persons with tetraplegia., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **19**(1): 1–5.
- Perrin, X., Chavarriaga, R., Colas, F., Siegwart, R. & Millán, J. D. R. (2010). Brain-coupled interaction for semi-autonomous navigation of an assistive robot, *Robotics and Autonomous Systems* **58**(12): 1246–1255.
- Pfurtscheller, G. & Lopes da Silva, F. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles, *Clinical neurophysiology* **110**(11): 1812–57.
- Pfurtscheller, G. & Neuper, C. (2001). Motor imagery and direct brain-computer communication, *Proceedings of the IEEE* **89**(7): 1123–1134.
- Ramoser, H., Müller-Gerking, J. & Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement, *IEEE transactions on neural systems and rehabilitation engineering* **8**(4): 441–446.
- Rivet, B., Souloumiac, A., Gilbert, G., Attina, V. & Bertrand, O. (2009). Sensor selection for P300 speller brain computer interface, *Proceedings of European Symposium on Artificial Neural Networks - Advances in Computational Intelligence and Learning*.

- Sanchez, G., Diez, P. F., Avila, E. & Leber, E. L. (2011). Simple communication using a SSVEP-based BCI, *Journal of Physics: Conference Series* **332**: 012017.
- Schlogl, A., Keinrath, C., Zimmermann, D., Scherer, R., Leeb, R. & Pfurtscheller, G. (2007). A fully automated correction method of {EOG} artifacts in {EEG} recordings, *Clinical Neurophysiology* **118**(1): 98 – 104.
- Schomer, D. L. (2007). The normal eeg in an adult, in A. S. Blum & S. B. Rutkove (eds), *The Clinical Neurophysiology Primer*, Humana Press, pp. 57–71.
- Sobani, Z. A., Quadri, S. A. & Enam, S. A. (2010). Stem cells for spinal cord regeneration: Current status, *Surgical Neurology International* **1**(93): 531–534.
- Teplan, M. (2002). Fundamentals of eeg measurement, *Measurement science review* **2**(2): 1–11.
- Theodoridis, S. & Koutroumbas, K. (1999). *Pattern Recognition, Second Edition*, 2th edn, Academic Press.
- Trejo, L., Rosipal, R. & Matthews, B. (2006). Brain-computer interfaces for 1-d and 2-d cursor control: designs using volitional control of the eeg spectrum or steady-state visual evoked potentials, *Neural Systems and Rehabilitation Engineering, IEEE Transactions on* **14**(2): 225–229.
- Valbuena, D. & Cyriacks, M. (2007). Brain-computer interface for high-level control of rehabilitation robotic systems, *Rehabilitation Robotics, 2007. ICORR 2007. IEEE 10th International Conference on*, Vol. 00, pp. 619 – 625.
- Volosyak, I. (2011). SSVEP-based Bremen-BCI interface-boosting information transfer rates., *Journal of neural engineering* **8**(3): 036020.
- Wang, Y., Gao, X., Hong, B., Jia, C. & Gao, S. (2008). Brain-computer interfaces based on visual evoked potentials., *IEEE engineering in medicine and biology magazine : the quarterly magazine of the Engineering in Medicine & Biology Society* **27**(5): 64–71.
- Wang, Y., Wang, R., Gao, X., Hong, B. & Gao, S. (2006). A practical VEP-based brain-computer interface., *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **14**(2): 234–9.
- Watson, A. B., Barlow, H. B. & Robson, J. G. (1983). What does the eye see best?, *Nature* pp. 419–22.
- Welch, P. D. (1967). The use of fast fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms, *Audio and Electroacoustics, IEEE Transactions on* **15**(2): 70–73.
- Wolpaw, J., Birbaumer, N., Heetderks, W., McFarland, D., Peckham, P., Schalk, G., Donchin, E., Quatrano, L., Robinson, C. & Vaughan, T. (2000). Brain-computer interface technology: a review of the first international meeting, *Rehabilitation Engineering, IEEE Transactions on* **8**(2): 164–173.

- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G. & Vaughan, T. M. (2002). Brain-computer interfaces for communication and control, *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology* **113**(6): 767–791.
- Wu, C.-h. & Lakany, H. (2012). Impact of Stimulus Configuration on Steady State Visual Evoked Potentials (SSVEP) Response, *COGNITIVE 2012, The Fourth International Conference on Advanced Cognitive Technologies and Applications*, number 3, Nice, France, pp. 77–82.
- Zhang, Y., Xu, P., Liu, T., Hu, J., Zhang, R. & Yao, D. (2012). Multiple frequencies sequential coding for SSVEP-based brain-computer interface., *PloS one* **7**(3): e29519.
- Zhu, D., Bieger, J., Garcia Molina, G. & Aarts, R. M. (2010). A survey of stimulation methods used in SSVEP-based BCIs., *Computational intelligence and neuroscience* **2010**: 702357.