



**UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO**

**SARAH NEGREIROS DE CARVALHO LEITE**

**CONTRIBUIÇÕES AO DESENVOLVIMENTO DE INTERFACES CÉREBRO-  
COMPUTADOR BASEADAS EM POTENCIAIS EVOCADOS  
VISUALMENTE EM REGIME ESTACIONÁRIO**

**CAMPINAS**

**2016**



**SARAH NEGREIROS DE CARVALHO LEITE**

**CONTRIBUIÇÕES AO DESENVOLVIMENTO DE INTERFACES CÉREBRO-  
COMPUTADOR BASEADAS EM POTENCIAIS EVOCADOS  
VISUALMENTE EM REGIME ESTACIONÁRIO**

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas para obtenção do título de Doutora em Engenharia Elétrica. Área de concentração: Telecomunicações e Telemática.

**Orientador: Prof. Dr. Romis Ribeiro de Faissol Attux**

**Coorientador: Prof. Dr. Diogo Coutinho Soriano**

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA TESE DEFENDIDA PELA ALUNA SARAH NEGREIROS DE CARVALHO LEITE, ORIENTADA PELO PROF. DR. ROMIS RIBEIRO DE FAISSOL ATTUX E COORIENTADA PELO PROF. DR. DIOGO COUTINHO SORIANO.

**CAMPINAS**

**2016**

**Agência(s) de fomento e nº(s) de processo(s):** CAPES

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Área de Engenharia e Arquitetura  
Luciana Pietrosanto Milla - CRB 8/8129

L536c Leite, Sarah Negreiros de Carvalho, 1985-  
Contribuições ao desenvolvimento de interfaces cérebro-computador baseadas em potenciais evocados visualmente em regime estacionário / Sarah Negreiros de Carvalho Leite. – Campinas, SP : [s.n.], 2016.

Orientador: Romis Ribeiro de Faissol Attux.

Coorientador: Diogo Coutinho Soriano.

Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Interfaces cérebro-computador. 2. Potenciais evocados. 3. Eletroencefalografia. 4. Aprendizado de máquina. 5. Processamento de sinais. I. Attux, Romis Ribeiro de Faissol, 1978-. 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:** Contributions to the development of brain-computer interfaces based on the steady state visually evoked potentials

**Palavras-chave em inglês:**

Brain-computer interface

Evoked potentials

Electroencephalography

Machine learning

Signal processing

**Área de concentração:** Telecomunicações e Telemática

**Titulação:** Doutora em Engenharia Elétrica

**Banca examinadora:**

Romis Ribeiro de Faissol Attux [Orientador]

Ricardo Suyama

Glauco Ferreira Gazel Yared

Gabriela Castellano

Leonardo Abdala Elias

**Data de defesa:** 07-04-2016

**Programa de Pós-Graduação:** Engenharia Elétrica

## **Banca Examinadora – Tese de Doutorado**

**Candidata:** Sarah Negreiros de Carvalho Leite - RA: 046450

**Data da Defesa:** 07/04/2016

**Título da Tese:** “Contribuições ao Desenvolvimento de Interfaces Cérebro-Computador baseadas em Potenciais Evocados Visualmente em Regime Estacionário”.

**Membros da Banca Examinadora:**

Presidente: Prof. Dr. Romis Ribeiro de Faissol Attux (FEEC/UNICAMP)

Membro externo: Prof. Dr. Ricardo Suyama (CECS/UFABC)

Membro externo: Prof. Dr. Glauco Ferreira Gazel Yared (ICEA/UFOP)

Membro interno: Profa. Dra. Gabriela Castellano (IFGW/UNICAMP)

Membro interno: Prof. Dr. Leonardo Abdala Elias (FEEC/UNICAMP)

A ata de defesa, com as respectivas assinaturas dos membros da banca examinadora, encontra-se no processo de vida acadêmica da aluna.

*Aos meus pais.*

## **Agradecimentos**

Primeiramente, agradeço a Deus pela conclusão deste trabalho que representa a realização de um sonho e o alcance de uma importante meta profissional.

Agradeço aos meus pais, Paulo e Cláudia, e as minhas irmãs, Patrícia e Flávia, pelo apoio incondicional, compreensão e incentivos dados durante esta jornada.

Agradeço ao meu marido, Harlei, que sempre esteve ao meu lado, pelas conversas e ajudas dadas durante a realização deste trabalho e por seu amor, paciência e compreensão.

Agradeço ao meu orientador Prof. Romis, por compartilhar seu conhecimento e me auxiliar no caminho da pesquisa, por servir de exemplo profissional na vivência no laboratório e também, pela amizade, disponibilidade e dedicação.

Agradeço enormemente ao Prof. Diogo, meu coorientador, pela colaboração e auxílio em me introduzir na área de processamento de sinais cerebrais, por suas ideias e solicitude.

Pelos bons momentos e ajudas, agradeço a todos os amigos com quem tive a oportunidade de interagir durante o doutorado, em especial ao Thiago Bulhões, Luísa Uribe, Rafael Ferrari, Luís Soutello, Prof.<sup>a</sup> Gabriela, Prof. Coradine, Prof. Eleri e Sara Regina.

Agradeço ao Prof. Yuzo pela compreensão e valiosa ajuda.

Agradeço também a todos os membros do DSPCom, em especial, aqueles com quem convivi mais diretamente: Michele, Denis, Kenji, Covre, Cazarotto, Zanetti, Levy, Daniel, Guilherme, Novaes, Wesley, Sérgio, Everton, Kazuo, Kobi, Celi, Prof. Renato Lopes, Prof. Leonardo Tomazeli e Prof. João Marcos.

Agradeço as boas conversas e motivações dos amigos: Veruska, Raquel, Fábio, Juliana, Leo, Verônica, Grazy, Gardênia e Cecília.

Agradeço a todos os colegas do DEELT, em especial aos professores Glauco e Carlos Barbosa, por terem viabilizado meu afastamento de 11 meses na UFOP para a realização da parte experimental deste trabalho.

Agradeço aos meus orientados de TCC, Luiz, Thiago e Weld, que de maneira indireta me permitiram manter esta pesquisa em desenvolvimento em meio aos muitos afazeres didáticos e administrativos.

Agradeço aos voluntários e pacientes, pela paciência e disposição em participar da coleta de dados EEG.

Agradeço a todos os professores e funcionários da FEEC/UNICAMP e da UFOP pelo apoio, oportunidade de capacitação e pela infraestrutura disponibilizada.

Enfim, agradeço a todos que colaboraram, direta ou indiretamente, para a concretização desse trabalho.

Também agradeço a UFOP, FINEP e a FAPESP, pelo apoio financeiro.

*Ultima hominis felicitas est in  
contemplatione veritatis.*

*São Tomás de Aquino*

## Resumo

As interfaces cérebro-computador baseadas em potenciais evocados visualmente em regime permanente (BCI-SSVEP) têm sido largamente empregadas em diferentes contextos, produzindo aplicações que vão desde o entretenimento à reabilitação. O presente estudo aborda o módulo de processamento de sinais de sistemas BCI-SSVEP que empregam sinais coletados por meio da eletroencefalografia (EEG). Ao longo deste trabalho, foi desenvolvido um sistema BCI-SSVEP completo e foi gerada uma base de dados de sinais EEG-SSVEP coletados tanto em pacientes que sofreram acidente vascular cerebral como em voluntários saudáveis. A partir desta base de dados e visando à concepção de um sistema capaz de operar em tempo de execução de maneira autônoma, eficiente e robusta, foram realizadas diversas análises nas quatro etapas fundamentais do módulo de processamento de sinais da BCI: pré-processamento, extração de características, seleção de características e classificação. Um amplo quadro comparativo, envolvendo mais de 36 combinações de técnicas, foi projetado permitindo vislumbrar os melhores arranjos a serem aplicados no desenvolvimento de uma BCI-SSVEP. Outras contribuições relevantes advindas deste trabalho são: a análise e caracterização de uma abordagem relativamente nova de classificação, definida pela rede neural conhecida como *Extreme Learning Machine*, e a proposta de uma técnica de filtragem espaço-temporal, capaz de combinar a disposição espacial dos eletrodos com as frequências que geraram os estímulos visuais.

**Palavras-chave:** Interface Cérebro-Computador, Potenciais Visualmente Evocados, Eletroencefalografia, Aprendizagem de Máquina, Processamento de Sinais.

## ***Abstract***

*Brain-computer interfaces based on steady state visually evoked potentials (BCI-SSVEP) have been increasingly used in different contexts, engendering applications from entertainment to rehabilitation. This study addresses the stage of signal processing of BCI-SSVEP systems that use electroencephalography signals. Throughout this study, a full BCI-SSVEP was developed and a database of EEG-SSVEP signals collected from patients that had suffered stroke and healthy volunteers was generated. From this database and in order to design a system capable of operating in real time, autonomously, efficiently and robustly, many analyses were carried out regarding the four signal processing module stages: pre-processing, feature extraction, feature selection and classification. A large comparative framework, involving more than 36 combinations of techniques, was designed allowing a notion of the best set of techniques to be applied on BCI-SSVEP systems. Other relevant contributions of this study are: the analysis and characterization of a relatively new approach to classification, defined by the neural network known as Extreme Learning Machine, and the proposal of a new technique of spatiotemporal filtering, able to combine the spatial arrangement of the electrodes with the frequencies of visual stimuli.*

**Keywords:** *Brain-Computer Interface, Visually Evoked Potentials, Electroencephalography, Machine Learning, Signal Processing.*

## Lista de Figuras

Figura 2.1 – Vista em perspectiva do encéfalo humano.....	26
Figura 2.2 – Etapas de uma interface cérebro-máquina. ....	28
Figura 2.3 – Onda P300.....	36
Figura 2.4 – Matriz de estímulos P300.....	37
Figura 2.5 – Interface de estímulos visuais – SSVEP. ....	40
Figura 3.1 – Etapas do módulo de processamento de sinais. ....	45
Figura 3.2 – (a) Sinal EEG adquirido em O1 durante estimulação visual em 6 Hz e (b) magnitude da FFT.....	52
Figura 3.3 – Filtros banda passantes centrados em 8 Hz do tipo (a) Butterworth e (b) equiripple.....	55
Figura 3.4 – Esquema de banco de filtros para extração de características nas frequências de 12 Hz e 15 Hz. ....	56
Figura 3.5 – Diagrama de polos e zeros do filtro de Goertzel.....	58
Figura 3.6 – Resposta em magnitude e fase do filtro de Goertzel.....	59
Figura 3.7 – Função temporal e resposta em magnitude da fanela de Hamming.....	60
Figura 3.8 – Extração de características da resposta SSVEP em 12 e 15 Hz, (a) densidade espectral de potência, (b) espaço de características considerando somente um canal. ....	61
Figura 3.9 – Exemplo do índice de Davies Bouldin para atributos de duas classes.....	69
Figura 3.10 – Hiperplano de classificação de duas classes. ....	73
Figura 3.11 – Separação de duas classes utilizando SVM. ....	78
Figura 3.12 – Mapeamento do vetor de entrada em um espaço de alta dimensão para ilustrar a operação de uma SVM baseada em kernels. ....	81
Figura 3.13 – Estrutura básica de uma rede neural <i>feedforward</i> . ....	83
Figura 3.14 – Arquitetura de uma ELM. ....	85
Figura 4.1 – Disposição dos 128 eletrodos.....	89

Figura 4.2 – Sinal cerebral adquirido em $O_1$ durante estimulação visual em 8, 14 e 28 Hz, (a) domínio do tempo e (b) domínio da frequência. ....	91
Figura 4.3 – Resposta em fase e magnitude dos filtros passa-bandas centrados em (a) 8 Hz, (b) 14 Hz e (c) 28 Hz.....	93
Figura 4.4 – Estrutura de classificação das três classes usando a rede ELM. ....	94
Figura 4.5 – Interface de estímulo visual. ....	100
Figura 4.6 – Gráfico de contorno da resposta VEP ao estímulo visual de 20 Hz.....	101
Figura 4.7 – Protocolo de aquisição dos sinais EEG.....	101
Figura 4.8 – Equipamentos utilizados para capturar os sinais EEG.....	102
Figura 4.9 – Disposição dos 16 eletrodos no escalpo para aquisição do sinal de EEG.....	103
Figura 4.10 – Técnicas de processamento de sinais comparadas.....	105
Figura 4.11 – Resposta dos filtros passa-bandas. Faixa de passagem centrada em torno das frequências evocadas (a) 12 Hz e (b) 15 Hz.....	106
Figura 4.12 – Desempenho de voluntários para cada cenário (a) voluntário 2, (b) voluntário 5, (c) voluntário 4. ....	108
Figura 4.13 – Distribuição da taxa de acerto obtido pelos sete voluntários.....	109
Figura 4.14 – Desempenho médio dos sete indivíduos usando diferentes configurações no módulo de processamento de sinais.....	110
Figura 4.15 – Ordenação dos canais com os melhores atributos para classificação. ....	112
Figura 5.1 – Diagrama do filtro MVDR combinando duas entradas e selecionando uma única frequência de interesse.....	126
Figura 5.2 – Resultado da filtragem em 15 Hz de duas senoides oscilantes a 15 Hz.....	132
Figura 5.3 – Resultado da filtragem em 15 Hz de dois sinais senoidais ruidosos.....	134
Figura 5.4 – Diagrama do filtro MVDR combinando duas entradas e selecionando $N$ frequências.....	135
Figura 5.5 – Resultado da filtragem em 15 e 20 Hz de quatro sinais senoidais combinados dois a dois.....	138
Figura 5.6 – Resultado da filtragem em 15 Hz e 20 Hz de sinais cerebrais com potencial	

visual evocado. ....	139
Figura 5.7 –Resultado da filtragem em seis diferentes frequências de sinais cerebrais com potencial visual evocado.....	140
Figura 5.8 – Diagrama do filtro MVDR combinando $N$ entradas e selecionando uma única frequência. ....	141
Figura 5.9 – Resultado da filtragem em 15 Hz de três sinais cerebrais com potencial visual evocado.....	144
Figura 5.10 – Resultado da filtragem em 15 Hz e 20 Hz de 3 s de sinais cerebrais com potencial visual evocado.....	145
Figura 5.11 – Resultado da filtragem em 15 Hz e 20 Hz de 2 s de sinais cerebrais com potencial visual evocado.....	146
Figura 5.12 – Resultado da filtragem em 15 Hz de dois sinais cerebrais usando diversas ordens de filtro.....	147
Figura A.1 – Desempenho dos sete voluntários para cada cenário. ....	172

## Lista de Quadros

Quadro 3.1 – Algoritmo de determinação dos coeficientes AR pelo método de Burg. ....	64
Quadro 3.2 – Algoritmo de seleção de atributos <i>forward wrapper</i> .....	71
Quadro 5.1 – Código de geração dos sinais senoidais com ruído aditivo do tipo impulsivo e gaussiano. ....	133

## Lista de Tabelas

Tabela 4.1 – Desempenho do sistema em cada um dos cenários. ....	95
Tabela 4.2 – Perfil dos Indivíduos da Base de Dados. ....	98
Tabela 4.3 – Escala NIHSS. ....	98
Tabela 4.4 – Escala RANKIN Modificado. ....	99
Tabela 4.5 – Desempenho do sistema BCI empregando atributos extraídos pelos métodos de Welch e Burg. ....	114
Tabela 4.6 – Desempenho com 2 estímulos visuais e interface de estímulos personalizada. ....	117
Tabela 4.7 – Desempenho com 4 estímulos visuais E interface de estímulos personalizada. ....	117
Tabela 4.8 – Desempenho com 6 estímulos visuais e interface de estímulos personalizada. ....	117
Tabela 4.9 – Desempenho com 2 estímulos visuais e interface de estímulos padrão. ....	119
Tabela 4.10 – Desempenho com 4 estímulos visuais e interface ded estímulos padrão. ....	119
Tabela 4.11 – Desempenho do sistema aplicando diferentes técnicas de filtragem espacial. ....	122
Tabela 5.1 – Combinação de sinais EEG na filtragem MVDR. ....	149
Tabela 5.2 – Desempenho da BCI para diferentes ordens. ....	150
Tabela 5.3 – Desempenho da BCI empregando o filtro MVDR. ....	151
Tabela 5.4 – Desempenho da BCI com quatro estímulos. ....	151
Tabela 5.5 – Desempenho da BCI com seis estímulos. ....	152

## Lista de Abreviaturas e Siglas

AIC	<i>Akaike Information Criterion</i>
API	<i>Application Programming Interface</i>
AR	Autorregressivo
AVC	Acidente Vascular Cerebral
BCI	<i>Brain Computer Interface</i>
BRAINN	<i>Brazilian Institute of Neuroscience and Neurotechnology</i>
CAR	<i>Common Average Reference</i>
CCA	<i>Canonical Correlation Analysis</i>
CRT	<i>Cathodic Ray Tube</i>
DB	Davies-Bouldin
DBinv	Índice de Davies-Bouldin Inverso
DESTINE	Desenvolvimento de Tecnologias da Informação para Neurologia
DFT	<i>Discrete Fourier Transform</i>
DSPCom	<i>Laboratory of Digital Signal Processing for Communication</i>
DTFT	<i>Discrete-Time Fourier Transform</i>
ECoG	Eletrocorticografia
EEG	Eletroencefalografia
ELA	Esclerose Lateral Amiotrófica
ELM	<i>Extreme Learning Machine</i>
ERP	<i>Event-Related Potential</i>
FAPESP	Fundação de Amparo à Pesquisa do Estado de São Paulo
FFT	<i>Fast Fourier Transform</i>
FINEP	Financiadora de Estudos e Projetos
FIR	<i>Finite Impulse Response</i>
fMRI	<i>Functional Magnetic Resonance Imaging</i>
IC	Intervalo de Confiança
LCD	<i>Liquid Cristal Display</i>
LDA	<i>Linear Discriminant Analysis</i>
MEC	<i>Minimum Energy Combination</i>
MCC	<i>Maximum Contrast Combination</i>
MEG	Magnetoencefalografia

MLP	<i>Multi-Layer Perceptron</i>
MSE	<i>Minimum Squared Error</i>
MVDR	<i>Minimum Variance Distortionless Response</i>
NIHSS	<i>National Institute of Health Stroke Scale</i>
NIRS	<i>Near-Infrared Spectroscopy</i>
PA	Potencial de Ação
PCA	<i>Principal Component Analysis</i>
PPS	Potencial Pós-Sináptico
PSD	<i>Power Spectral Density</i>
RDF	<i>Radial Basis Function</i>
RM	Ressonância Magnética
RMS	<i>Root Mean Square</i>
SSVEP	<i>Steady-State Visually Evoked Potential</i>
SSEP	<i>Steady-State Evoked Potential</i>
STFT	<i>Short-Time Fourier Transform</i>
SVD	<i>Singular Value Decomposition</i>
SVM	<i>Support Vector Machine</i>
TCLE	Termo de Consentimento Livre e Esclarecido
VEP	<i>Visually Evoked Potential</i>

# Índice

<b>1.INTRODUÇÃO .....</b>	<b>20</b>
<b>2.INTERFACES CÉREBRO-COMPUTADOR.....</b>	<b>25</b>
2.1 BASES NEUROFISIOLÓGICAS ASSOCIADAS A SISTEMAS BCIS .....	28
2.2 AQUISIÇÃO DO SINAL CEREBRAL.....	30
2.2.1 PARTICULARIDADES ASSOCIADAS AO EEG.....	32
2.3 PARADIGMAS DE BCI .....	35
2.3.1 PARADIGMAS DE BCI BASEADOS EM ATENÇÃO SELETIVA .....	36
2.3.2 PARADIGMAS DE BCI BASEADOS EM IMAGÉTICA.....	41
2.4 CONSIDERAÇÕES .....	43
<b>3.PROCESSAMENTO DE SINAIS APLICADO A SISTEMAS BCI-SSVEP .....</b>	<b>45</b>
3.1 PRÉ-PROCESSAMENTO.....	46
3.1.1 MÉDIA DE REFERÊNCIA COMUM.....	46
3.1.2 COMBINAÇÃO DE MÍNIMA ENERGIA .....	48
3.1.3 COMBINAÇÃO DE MÁXIMO CONTRASTE .....	50
3.2 EXTRAÇÃO DE CARACTERÍSTICAS.....	51
3.2.1 BANCO DE FILTROS .....	54
3.2.2 ESPECTROGRAMA .....	57
3.2.3 MÉTODO DE WELCH .....	59
3.2.4 COEFICIENTES DO MODELO AUTORREGRESSIVO – MÉTODO DE BURG.....	61
3.3 SELEÇÃO DE CARACTERÍSTICAS .....	65
3.3.1 FILTROS .....	66
3.3.1.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON.....	67
3.3.1.2 ÍNDICE DE DAVIES-BOULDIN.....	67
3.3.2 WRAPPERS .....	69
3.4 CLASSIFICAÇÃO.....	72
3.4.1 FUNÇÃO DISCRIMINANTE LINEAR.....	73
3.4.1.1 MÍNIMOS QUADRADOS .....	74
3.4.1.2 DISCRIMINANTE DE FISHER .....	76
3.4.2 SUPPORT VECTOR MACHINES .....	78
3.4.3 EXTREME LEARNING MACHINES.....	83
<b>4.DESENVOLVIMENTO DE UM SISTEMA BCI-SSVEP .....</b>	<b>88</b>
4.1 BASE DE DADOS PÚBLICA.....	88

4.2 CONSIDERAÇÕES .....	96
4.3 BASE DESTINE.....	97
4.3.1 EXPERIMENTO 1: COMPARAÇÃO DE DESEMPENHO DE DIVERSAS TÉCNICAS DE PROCESSAMENTO DE SINAIS CEREBRAIS EM SISTEMAS BCI-SSVEP.....	104
4.3.2 EXPERIMENTO 2: COMPARAÇÃO DE DESEMPENHO DE UMA BCI-SSVEP USANDO TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS TEMPORAIS E ESPECTRAIS .....	113
4.3.3 EXPERIMENTO 3: COMPARAÇÃO DE DESEMPENHO DE SISTEMAS BCI-SSVEP BASEADOS EM ESTÍMULOS VISUAIS CINTILANTES EM DIFERENTES FREQUÊNCIAS – AVALIAÇÃO DE VOLUNTÁRIOS SAUDÁVEIS E PACIENTES QUE SOFRERAM AVC .....	116
4.3.4 EXPERIMENTO 4: COMPARAÇÃO DE DIFERENTES METODOLOGIAS DE FILTRAGEM ESPACIAL PARA REMOÇÃO DE ARTEFATOS DE SINAIS SSVEP.....	120
4.4 CONSIDERAÇÕES FINAIS.....	122
<b>5.PROPOSTA DE FILTRAGEM ESPAÇO-TEMPORAL .....</b>	<b>126</b>
5.1 PROCEDIMENTOS EXPERIMENTAIS .....	131
5.2 FREQUÊNCIAS DE SINTONIA .....	134
5.3 NÚMERO DE ENTRADAS .....	140
5.4 COMPRIMENTO DO SINAL .....	144
5.5 ORDEM DO FILTRO MVDR .....	146
5.6 FILTRO MVDR APLICADO A UMA BCI-SSVEP .....	148
5.7 CONSIDERAÇÕES FINAIS.....	152
<b>6.CONCLUSÕES.....</b>	<b>154</b>
<b>REFERÊNCIAS .....</b>	<b>159</b>
<b>APÊNDICE A .....</b>	<b>171</b>
<b>ANEXO A - PARECER DO COMITÊ DE ÉTICA .....</b>	<b>174</b>
<b>ANEXO B - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO - PACIENTES .....</b>	<b>177</b>
<b>ANEXO C - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO - VOLUNTÁRIOS SAUDÁVEIS .....</b>	<b>179</b>

---

## 1. INTRODUÇÃO

A ideia de desvendar os mecanismos de funcionamento do cérebro sempre exerceu fascínio sobre pesquisadores e filósofos (KRISTENSEN; ALMEIDA; GOMES, 2001). Já nos remotos tempos da medicina de Hipócrates (460-355 a.C.) o cérebro era considerado a parte mais importante do corpo humano e a sede da inteligência. Atualmente, existem sofisticados exames, como a ressonância magnética funcional, tomografia por emissão de pósitrons, tomografia por emissão de fóton único e eletroencefalografia, que permitem identificar com precisão a região de atividade cerebral mais intensa durante a realização de determinada tarefa, permitindo explorar com maior segurança e confiabilidade o comportamento do cérebro. O atual conhecimento que se tem sobre o comportamento fisiológico do cérebro, aliado às tecnologias modernas, permite estabelecer um sistema de transmissão de informação direta entre o cérebro e o computador. A este moderno sistema de comunicação, dá-se o nome de Interface Cérebro-Computador ou BCI (do inglês, *Brain-Computer Interface*). Um sistema BCI contribui não somente para o estudo e compreensão do cérebro, mas também para o desenvolvimento de aplicações inovadoras. Isto alimenta a esperança, ainda que longínqua, de melhoria na qualidade de vida de milhões de pessoas existentes ao redor do mundo que sofrem de alguma deficiência muscular ou ausência de algum membro do corpo. Somente no Brasil, mais de 45 milhões de pessoas declararam ter ao menos um tipo de deficiência (visual, auditiva, motora ou mental), sendo 13 milhões as que atestaram ter alguma deficiência motora. Dentre a população portadora de pelo menos uma deficiência, 20,3 milhões estão inseridas no mercado de trabalho (IBGE, 2010). Estes números tornam nítidos e justificam a motivação deste trabalho em se desenvolver pesquisas que contribuam para um melhor entendimento neurofisiológico e permitam desenvolver tecnologias médico-assistivas, capazes de aumentar a inclusão social, a autonomia e a independência de pessoas com acometimento no sistema nervoso e/ou muscular, facilitando a inserção delas no mercado de trabalho e na convivência social.

A concepção de uma BCI envolve conhecimentos multidisciplinares, tais como neurociência, teoria da informação, física, informática e engenharia. Ainda incipientes, as pesquisas em BCI buscam garantir um sistema autônomo, eficiente e robusto. Este trabalho traz contribuições no escopo da engenharia, indo ao cerne de um dos pontos considerados chave para se aprimorar o desempenho das BCIs, o módulo de processamento de sinais. Este

módulo é responsável não só pela correta interpretação dos sinais cerebrais, mas também pela velocidade de resposta do sistema e pelo tempo necessário de captura do sinal cerebral, que se relacionam diretamente à taxa de transmissão de informação do sistema. Devido à complexidade da tarefa, o trabalho se foca em BCIs baseadas em potenciais visuais evocados em regime permanente (SSVEP, do inglês *Steady-State Visually Evoked Potential*). Em especial, o trabalho explorou o arcabouço de técnicas de processamento de sinais para estudar a resposta SSVEP, comparando o desempenho das BCIs concebidas sob diversos olhares e conceitos, indo desde as técnicas mais clássicas, como a utilização de discriminantes lineares, até técnicas mais recentes, como as máquinas de aprendizado extremo. Todas as etapas do módulo de processamento de sinais – pré-processamento, extração e seleção de características e classificadores – foram avaliadas com diversas ferramentas, algumas das quais nunca haviam sido testadas no contexto de SSVEP. Este trabalho também traz a proposta de uma técnica de filtragem espaço-temporal denominada filtro MVDR (*Minimum Variance Distortionless Response*), o qual pode ser empregado seja na etapa de pré-processamento, para eliminação de interferentes, seja na etapa de extração de características espectrais.

O desenvolvimento deste trabalho está vinculado a dois projetos:

- DESTINE (Desenvolvimento de Tecnologias da Informação para Neurologia), que visou o desenvolvimento de uma cadeira de rodas automática para pacientes que sofreram acidente vascular cerebral (AVC). Este projeto foi aprovado e financiado pela Financiadora de Estudos e Projetos (FINEP). O projeto DESTINE foi aprovado pelo Comitê de Ética em Pesquisa (CEP) da Unicamp em 11/08/2010 sob protocolo CEP 791/2010, CAAE 0617.0.146.000-10 (Anexo A);
- BRAINN (*Brazilian Institute of Neuroscience and Neurotechnology*), focado na investigação dos mecanismos básicos que levam à epilepsia e AVC e que tem como um dos objetivos o desenvolvimento de BCIs no âmbito de aplicações assistivas. O projeto é financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

Os trabalhos gerados durante a realização deste estudo de doutoramento foram:

**Trabalho publicado em periódico:**

1. CARVALHO, S. N.; COSTA, T. B. S.; URIBE, L. F. S; SORIANO, D. C.; YARED, G. F. G.; CORADINE, L. C.; ATTUX, R. R. F. . Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs. *Biomedical Signal Processing and Control (Print)*, v. 21, p. 34-42, 2015.

**Trabalhos publicados ou aceitos para publicação em anais de eventos:**

1. CUNHA, W. L.; LEITE, H. M.; COSTA, T. B.; URIBE, L. S.; SORIANO, D.; ATTUX, R.; CARVALHO, S. N.. Analysis of feature extraction techniques of brain signals for the development of SSVEP BCI systems. In: 3º Brainn Congress, Campinas, 2016.

2. SORIANO, D. C.; SOUTELLO, L. F. M. G.; COSTA, T. B. S.; CARVALHO, S. N.; URIBE, L. F. S.; LEITE, H. M. A., KERSANACH, M. B.; STEFANO-FILHO, C. A.; ATTUX, R.. SSVEP-Based BCIs: the Brain as a Digital Communication Channel. In: 3º Brainn Congress, Campinas, 2016.

3. CARVALHO, S. N.; COSTA, T. B. S.; URIBE, L. F. S; SORIANO, D. C.; ALMEIDA, S. R. M.; MIN, L. L.; CASTELLANO, G.; ATTUX, R. R. F.. Effect of the combination of different numbers of flickering frequencies in an SSVE-BCI for healthy volunteers and stroke patients. In: 7th Annual International IEEE EMBS Conference on Neural Engineering, 2015, Montpellier - France. *Proceedings of 7th Annual International IEEE EMBS Conference on Neural Engineering*, 2015. p. 78-81.

4. TAVARES, T. V.; COSTA, T. B. S.; URIBE, L. F. S.; LEITE, H. M. A.; YARED, G. F. G; SORIANO, D. C.; ATTUX, R. R. F.; CARVALHO, S. N.. Análise de Técnicas de Filtragem Espacial em Sistemas BCI-SSVEP. *Anais do Simpósio de Processamento de Sinais da Unicamp*, 2015.

5. LEITE, H. M. A.; CARVALHO, S. N.; ATTUX, R.; HORNUNG, H.; ARANTES, D. S.. Análise de Interfaces de Estímulos Visuais para BCI/SSVEP. *Anais do Simpósio de Processamento de Sinais da Unicamp*, 2015.

6. SOUTELLO, L. F. M. G.; COSTA, T. B. S; CARVALHO, S. N.; URIBE, L. F. S; SORIANO, D. C; ATTUX, R. R. F.. Análise Preliminar de Diferentes Padrões de

Estimulação em Interfaces Cérebro-Computador Baseadas em SSVEP. Anais do VII Encontro dos Alunos e Docentes do DCA, 2015.

7. COSTA, T. B. S.; CARVALHO, S. N.; URIBE, L. F. S; FERRARI, R.; SOUZA, R. S.; SORIANO, D. C.; CASTELLANO, G.; ATTUX, R. R. F.; ROMANO, J. M. T.; CARDOZO, E. . Online Brain-Computer Interface Based on Steady-State Visually Evoked Potentials. In: 2nd Brainn Congress, Campinas. Journal of Epilepsy and Clinical Neurophysiology, 2015, v. 21, p. 75.

8. SORIANO, D. C.; SLENES, G. F.; BELTRAMINI, G. C.; SILVA, E. L.; CARVALHO, S. N.; COSTA, T. B. S.; CASTELLANO, G.; ATTUX, R. R. F.. Análise de diferentes técnicas de extração de características em interface cérebro-máquina. In: Congresso Brasileiro de Engenharia Biomédica, 2014, Uberlândia. Anais do XXIV Congresso Brasileiro de Engenharia Biomédica, 2014. v. 1. p. 488-491.

9. CORREA JUNIOR, L. A.; COSTA, T. B. S; YARED, G. F. G; SORIANO, D. C.; ATTUX, R. R. F; CARVALHO, S. N.. Análise do desempenho de um classificador linear aplicado a um problema de SSVEP. Anais do Simpósio de Processamento de Sinais da Unicamp, 2014.

10. COSTA, T. B. S; CARVALHO, S. N.; SORIANO, D. C.; ATTUX, R. R. F. Discriminantes lineares para uso em sistemas SSVEP-BCI. Anais do VII Encontro dos Alunos e Docentes do DCA, 2014.

11. COSTA, T. B. S.; CARVALHO, S. N.; SORIANO, D. C.; ATTUX, R. R. F. Linear Classification Applied to SSVEP-BCI Systems: Preliminary Results. In: 1º Congress CEPID BRAINN, 2014, Campinas. Journal of Epilepsy and Clinical Neurophysiology, 2014, v.20. p. 21-22.

12. ATTUX, R. R. F.; COSTA, T. B. S; CARVALHO, S. N.; SORIANO, D. C.. Feature extraction and classification of brain signals for BCI applications. Part II. In: 1º Congress CEPID BRAINN, 2014, Campinas. Journal of Epilepsy and Clinical Neurophysiology, 2014, v.20, p. 11.

---

Para melhor clareza, a escrita deste trabalho foi dividida em seis capítulos. A contextualização histórica e os aspectos relacionados às interfaces cérebro-computador são expostos no Capítulo 2. O Capítulo 3 apresenta o ferramental empregado para análise e implementação das quatro etapas do módulo de processamento de sinais de uma BCI-SSVEP. O Capítulo 4 expõe os experimentos desenvolvidos e discute os resultados. O Capítulo 5 propõe uma técnica de filtragem espaço-temporal e discute seu desempenho na filtragem de sinais EEG-SSVEP. O Capítulo 6 apresenta as conclusões gerais do trabalho, bem como as perspectivas futuras.

---

## 2. INTERFACES CÉREBRO-COMPUTADOR

A outrora fantasiosa ideia de o homem interagir com máquinas usando somente o pensamento tornou-se possível através de sensores que captam a atividade elétrica cerebral e avançadas técnicas que a interpretam e geram sinais de controle para o computador (PARKER, 2004). As interfaces cérebro-computador representam um sistema alternativo de comunicação, que permite identificar padrões cerebrais estáveis de indivíduos durante a execução de determinadas tarefas mentais (WOLPAW et al., 2002).

No século XIX, ocorreram grandes avanços na compreensão do funcionamento cerebral e da fisiologia sensitiva, conforme relatam os trabalhos (FLOURENS, 1825) e (MULLER, 1843). Em 1875, Caton demonstrou a existência de sinal elétrico associado à atividade cerebral e constatou que os padrões fisiológicos cerebrais geram atividade elétrica específica como resposta a determinados estímulos, e que esta pode ser alterada por meio de estimulação sensorial. Em seu experimento, Caton usou um galvanômetro e posicionou dois eletrodos sobre o escalpo de animais. Surgiu assim o conceito de eletroencefalografia (EEG), formado dos termos: *eletro* que indica o registro da atividade elétrica, *encéfalo* referente à emissão de sinais do cérebro e *grafia* que significa escrita, para denotar a atividade elétrica neural do cérebro. Em 1929, Berger realizou o primeiro EEG de um ser humano consciente, por meio de galvanômetros posicionados no escalpo.

Atualmente, sabe-se que o cérebro humano é um órgão do sistema nervoso central composto por cerca de 85 bilhões de neurônios (HERCULANO-HOUZEL, 2009), conectados a fim de desempenhar e regular funções vitais do organismo, tais como respiração, batimento cardíaco, regulação da temperatura, bem como processos relacionados à aprendizagem, memorização, respostas emocionais e instintivas, dentre outras (FRACKOWIAK et al., 2004). Vários cientistas trabalham visando compreender como a interação do indivíduo com o meio externo, seus pensamentos, vontades e processos cognitivos são traduzidos eletricamente por processos neurofisiológicos (BRAZIER, 1961; WALTER, 1964). A Figura 2.1 ilustra o mapa do encéfalo humano, identificando as zonas cerebrais com maior atividade durante a realização de determinadas tarefas, pensamentos e emoções.

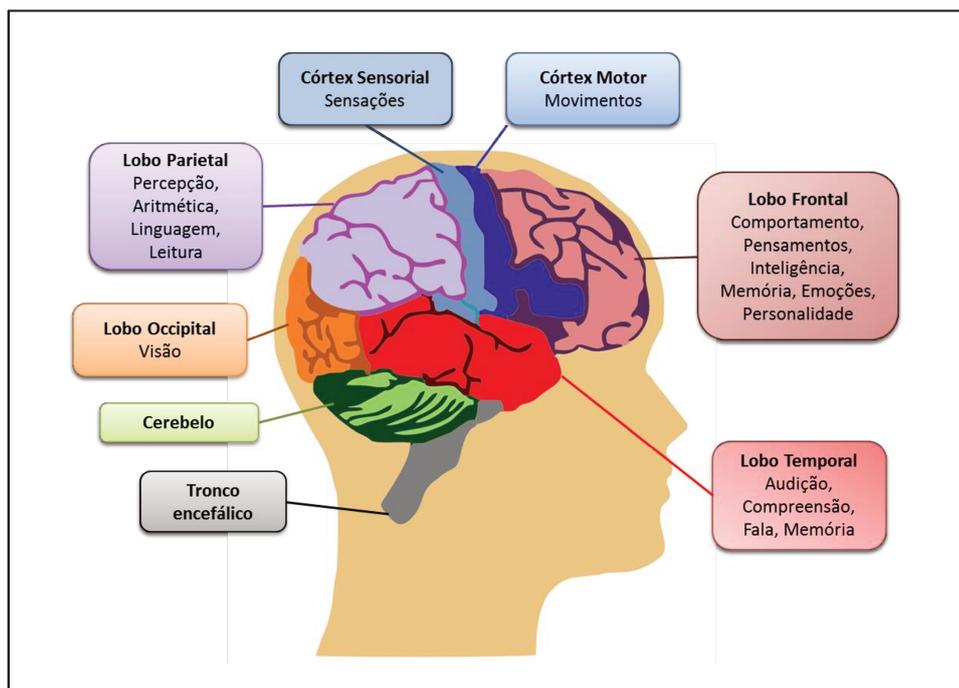


Figura 2.1 – Vista em perspectiva do encéfalo humano.

Embora a complexidade de se extrair informação do sinal cerebral não permita uma codificação direta e refinada da atividade cognitiva desenvolvida pelo indivíduo, a análise das atividades cerebrais associadas a tarefas ou eventos específicos possibilita a definição de sistemas BCIs. Em 1964, o Dr. Grey Walter aproveitou-se da necessidade de realização de uma cirurgia cerebral em um paciente e inseriu eletrodos diretamente ao córtex motor, registrando a atividade elétrica cerebral do paciente durante a cirurgia. Foi solicitado ao paciente que apertasse um botão para avançar os slides de um projetor. Durante a execução desta tarefa, sua atividade elétrica cerebral foi gravada. Dr. Walter utilizou as alterações elétricas cerebrais identificadas durante a realização da tarefa solicitada para implementar um sistema que permitisse que o paciente controlasse o avanço dos slides pelo simples desejo de apertar o botão, mas sem de fato apertá-lo. Apesar de poder ser considerada uma BCI, seu trabalho não foi publicado, havendo poucos registros sobre os procedimentos empregados (GRAIMANN; ALLISON; PFURTSCHELLER, 2010). O primeiro trabalho que relata a implementação de uma BCI foi “*Toward Direct Brain-Computer Communication*” (VIDAL, 1973). À época, tinha-se o conhecimento dos métodos de registros de sinais cerebrais de maneira não invasiva, existindo, inclusive, equipamentos comerciais para realizar a eletroencefalografia. Em seu projeto, desenvolvido na Universidade da Califórnia, Vidal contou com a tecnologia computacional de ponta da década de 70, que permitiu o processamento em tempo de execução dos sinais cerebrais registrados. Na implementação do

sistema BCI, Vidal utilizou o potencial visual evocado para gerar a comunicação homem-máquina, explorando o fato de que os fenômenos neurológicos decorrentes da estimulação externa seguem um padrão específico. Em seu trabalho, não há relatos de taxas de acerto e da capacidade de transmissão de bits, mas ele corrobora a factibilidade da construção de um sistema BCI (VIDAL, 1977). Este projeto de Vidal despertou o interesse de diversos cientistas, abrindo o horizonte para uma melhor compreensão de processos cerebrais, detecção e tratamento de doenças, como a epilepsia, além do interesse no desenvolvimento das mais diversas aplicações, principalmente, para possibilitar uma melhor qualidade de vida para pessoas portadoras de deficiências ou com má formação. O apelo social aliado à evolução nas áreas de aquisição do sinal cerebral, das técnicas de processamento de sinais e de aprendizado de máquina, e respaldados pelo constante desenvolvimento dos recursos computacionais, impactaram num rápido avanço das BCIs. Como consequência, em 1999 ocorreu um marco histórico com a realização do primeiro encontro internacional de pesquisadores da área de BCI, relatado em (WOLPAW et al., 2000). Este evento trouxe contribuições relevantes na área, definindo um vocabulário específico, temas e problemas a serem solucionados e identificando as diretrizes de pesquisas no ramo. Na ocasião, formalizou-se a definição de BCI da seguinte forma:

*“A brain–computer interface is a communication system that does not depend on the brain’s normal output pathways of peripheral nerves and muscles.”* (WOLPAW et al., 2000).

Que em tradução direta é:

*“Uma interface cérebro-computador (BCI) é um sistema de comunicação que não depende dos canais de saída convencionais do cérebro, dos nervos periféricos e músculos.”*

ou seja, uma BCI consiste em um sistema de controle/comunicação em malha fechada na qual o usuário interage gerando os sinais cerebrais que estão associados aos comandos que deseja, tal como nas etapas mostradas na Figura 2.2. Inicialmente, o sinal cerebral é adquirido por meio de sensores, como eletrodos, que medem a diferença de potencial decorrente da atividade elétrica cerebral. Em seguida, opera-se a amplificação e digitalização do sinal elétrico que, originalmente, é da ordem de dezenas de microvolts. Posteriormente, inicia-se o módulo de processamento de sinais, que visa extrair atributos presentes no sinal cerebral a fim de gerar o sinal de controle a ser enviado à operação do dispositivo alvo. Nas seções seguintes

são apresentadas as técnicas de monitoramento e aquisição do sinal cerebral, bem como os diferentes paradigmas de BCI. As técnicas de processamento de sinais, por serem o foco deste trabalho, estão apresentadas mais detalhadamente no Capítulo 3.

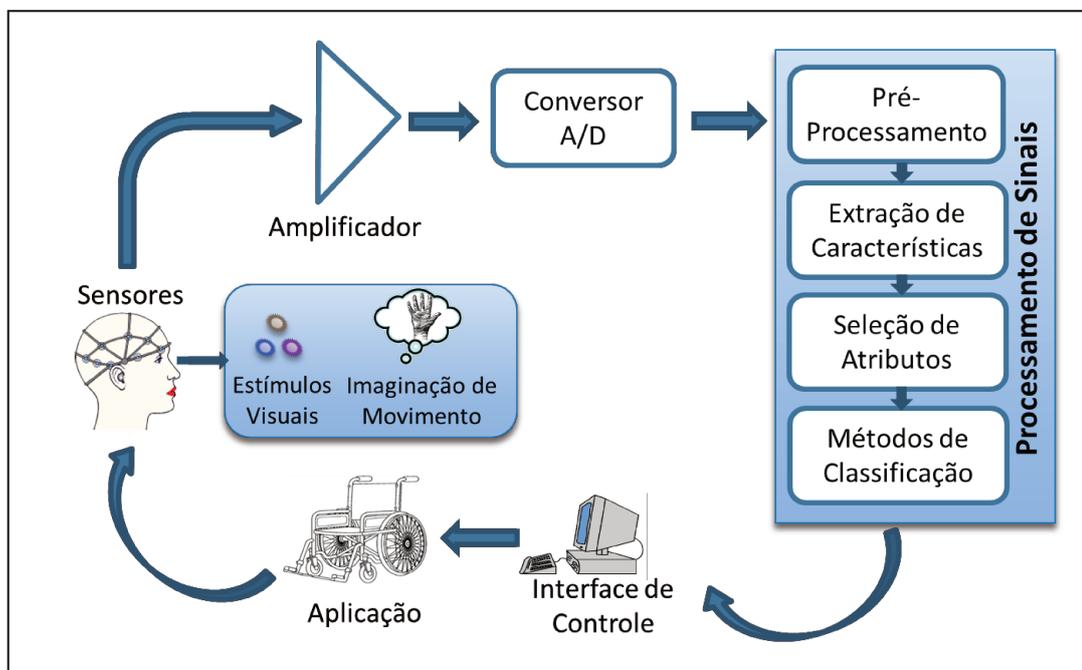


Figura 2.2 – Etapas de uma interface cérebro-máquina.

## 2.1 BASES NEUROFISIOLÓGICAS ASSOCIADAS A SISTEMAS BCIS

O cérebro trabalha com constantes descargas elétricas para codificar, por meio de sequências de pulsos eletroquímicos, as informações advindas das vias sensoriais, dos processos cognitivos e do metabolismo (CATON, 1875), (BRAZIER, 1961) e (WALTER, 1964). As principais atividades elétricas associadas aos neurônios relacionam-se com o potencial de ação (PA) e o potencial pós-sináptico (PPS), os quais são os responsáveis pela origem do sinal de eletroencefalografia.

A origem dos biopotenciais, mais especificamente do potencial de ação, foi intensamente estudada no século XX, tendo o emblemático trabalho de Alan Hodgkin e Andrew Huxley (HODGKIN; HUXLEY, 1952) estabelecido, por meio de um modelo matemático, os fenômenos biofísicos envolvidos na geração e propagação do PA. Uma descrição detalhada e acessível de tal processo é apresentada em (AIDLEY; STANFIELD, 1996) e (HILLE, 2001).

De modo sucinto, no estado de repouso, a membrana do neurônio encontra-se polarizada negativamente, ou seja, o meio intracelular apresenta potencial elétrico inferior ao do meio extracelular, o que se deve, sobretudo, às distribuições assimétricas de íons entre tais meios – principalmente, íons de sódio ( $\text{Na}^+$ ) e potássio ( $\text{K}^+$ ). Esta diferença de potencial é sustentada pela permeabilidade seletiva da membrana e os mecanismos ativos de troca iônica, tais como a bomba de sódio e potássio (HILLE, 2001). Na ausência de estímulos, o potencial da membrana ( $V_m$ ), i.e., o potencial elétrico entre o meio intracelular e extracelular, é de aproximadamente -65 mV, valor bem próximo ao potencial de equilíbrio do íon potássio, tal como calculado pela equação de Nernst (ATKINS; PAULA, 2002). Quando um estímulo suficientemente intenso é aplicado, ocorre a abertura dos canais de sódio, tornando a membrana celular mais permeável a este cátion e levando o potencial  $V_m$  mais próximo ao potencial de equilíbrio do íon de sódio, de cerca de 40 mV. Este fenômeno é conhecido como despolarização celular. A este processo, segue a inativação tempo-dependente dos canais de sódio, a ativação dos canais de potássio e a consequente repolarização da membrana celular em direção ao seu potencial de repouso, definindo assim um ciclo completo do transitório elétrico denominado potencial de ação (AIDLEY; STANFIELD, 1996; HILLE, 2001).

Dentre as principais características fisiológicas neuronais estão sua resposta ativa “tudo ou nada”, i.e., a capacidade de se gerar um potencial de ação mediante a aplicação de um estímulo intenso o suficiente para recrutar a abertura dos canais de sódio de uma massa crítica de neurônios, e a refratariedade, a qual consiste em um intervalo de tempo, após a aplicação do estímulo, para o qual o neurônio é incapaz de disparar um novo potencial de ação mediante um estímulo de igual intensidade e duração (AIDLEY; STANFIELD, 1996).

O PA gerado em um grupo neuronal pode estimular os neurônios vizinhos, que, por sua vez, podem desencadear novos potenciais de ação. Geralmente, o potencial de ação gera um efeito em cascata, o que permite que a informação percorra o cérebro por meio dos impulsos nervosos. A sinapse é a estrutura que permite esta transmissão dos impulsos nervosos entre os neurônios e destes para outras células, como células musculares, sensoriais ou células glandulares (MACHADO, 2005). O neurônio que envia o estímulo é dito pré-sináptico, enquanto o que recebe é chamado de pós-sináptico. Em sinapses químicas, a chegada de um potencial de ação ao axônio do neurônio pré-sináptico provoca a abertura dos canais de cálcio da membrana do terminal pré-sináptico, permitindo que íons de cálcio entrem na célula pré-sináptica e provoquem liberação de neurotransmissores na fenda sináptica. Os

neurotransmissores se ligam aos receptores na célula pós-sináptica gerando um potencial pós-sináptico.

Além disso, os potenciais pós-sinápticos podem não necessariamente gerar novos PAs, mas apenas facilitar ou dificultar tal processo. De fato, os chamados potenciais pós-sinápticos excitatórios, associados ao influxo de íons, principalmente de  $\text{Na}^+$ , na membrana pós-sináptica, bem como os potenciais pós-sinápticos inibitórios associados ao influxo de  $\text{Cl}^-$  ou mesmo ao efluxo de  $\text{K}^+$  da célula pós-sináptica, atuam também como dipolos elétricos e podem gerar diferenças de potenciais passíveis de detecção no meio extracelular, desde que uma massa representativa do tecido neural seja considerada. A dinâmica temporal da atividade dos PPSs é tipicamente mais lenta que a dos PAs, chegando a durar até centenas de milissegundos (SILVA, 2010). Por fim, tem-se que a dinâmica da atividade neuronal gera campos elétricos e magnéticos, os quais, em geral, possuem sua origem nos PAs e nos PPSs. Tais campos elétricos e magnéticos gerados por redes neuronais locais são de extremo interesse, uma vez que revelam informações sobre a atividade de populações neuronais e permitem compreender melhor as funções cerebrais (SILVA, 2010). Estes campos podem ser monitorados de diversas maneiras, conforme relatado na Seção 2.2. Em particular, considerando o fato da atividade elétrica registrada no eletroencefalograma consistir da somatória de milhões de neurônios, tem-se que o sinal registrado recebe contribuições tanto de PAs como de PPSs. Tipicamente, atribui-se aos PPSs maior contribuição nesse processo, uma vez que os PAs se caracterizam por oscilações significativamente mais rápidas e passíveis de cancelamento em tecidos com células dispostas aleatoriamente (SILVA, 2010).

## 2.2 AQUISIÇÃO DO SINAL CEREBRAL

Medir a atividade cerebral de forma eficaz é o primeiro passo crítico no sistema de comunicação cérebro-computador. Existem técnicas de gravação invasivas e não invasivas (GRAIMANN; ALLISON; PFURTSCHELLER, 2010) e (NICOLAS-ALONSO; GOMEZ-GIL, 2012), que permitem monitorar a atividade elétrica do cérebro ao longo do tempo e em diferentes áreas cerebrais.

Os sinais adquiridos por meio das técnicas invasivas possuem boa relação sinal/ruído, alta resolução espacial e captam as atividades nas altas frequências. Entretanto, a necessidade de intervenção cirúrgica esbarra em considerações éticas e financeiras. Além

disso, a morosidade intrínseca dessas técnicas, a pouca flexibilidade na disposição dos eletrodos no cérebro, acrescidos da carência de estudos sobre o tempo de vida útil dos eletrodos implantados, faz com que as técnicas invasivas sejam utilizadas em casos pontuais, nos quais o benefício para o paciente seja conveniente. Não obstante, alguns pesquisadores acreditam que será possível realizar o controle em tempo de execução de BCIs complexas, como braços robóticos ou neuropróteses, somente utilizando métodos invasivos de registros, e concentram seus esforços para o aprimoramento de técnicas que viabilizem BCIs invasivas seguras (MAYNARD; NORDHAUSEN; NORMANN, 1997), (NICOLELIS, 2001), (ANDERSEN; MUSALLAM; PESARAN, 2004), (QIN; DING; HE, 2004) e (WANG et al., 2013).

Todavia, a maioria das pesquisas em desenvolvimento na área empregam técnicas não invasivas de gravação, provavelmente devido ao baixo custo, flexibilidade do experimento e obtenção de resultados satisfatórios (WOLPAW; MCFARLAND, 2004), (MCFARLAND; WOLPAW, 2008), (CINCOTTI et al., 2008).

**Métodos invasivos de registro:** Nos métodos de gravação invasiva, o indivíduo é submetido a uma neurocirurgia para implantar os sensores necessários. As formas mais utilizadas são:

- **Eletrocorticograma (ECoG):** os eletrodos são posicionados na superfície do córtex e o registro compreende a atividade integrada de um conjunto de neurônios que estão na proximidade dos eletrodos (LEUTHARDT et al., 2004).
- **Gravação intracortical:** os eletrodos são inseridos diretamente sobre o tecido cortical, podendo registrar a atividade neural de um único neurônio ou pequenos conjuntos de neurônios (HOCHBERG et al., 2006) e (NICOLELIS, 2001).

#### **Métodos não invasivos de registro**

- **Magnetoencefalografia (MEG):** é uma técnica de neuroimagem funcional que permite mapear a atividade magnética do cérebro (MELLINGER et al., 2007). As correntes elétricas produzidas naturalmente no cérebro geram campos magnéticos que são monitorados usando magnetômetros muito sensíveis. A MEG propicia um grande número de sensores, fornecendo uma resolução espacial maior que a EEG (BRADSHAW; WIJESINGHE; WIKSWO JR, 2001).
- **Ressonância magnética funcional (fMRI):** trata-se, também, de uma técnica de neuroimagem funcional que mede a atividade cerebral utilizando a ressonância

magnética. Ela detecta a alteração do fluxo sanguíneo, pois quando a atividade cerebral de uma região aumenta, o fluxo sanguíneo também aumenta. A principal forma de fMRI se baseia na medida do nível de oxigênio no sangue (BOLD) (SLENES et al., 2013). Esta técnica possui alta resolução espacial, da ordem de milímetros, entretanto apresenta uma baixa resolução temporal, da ordem de segundos, o que dificulta o registro de eventos neurais específicos.

- **Espectroscopia de infravermelho próximo (NIRS):** consiste em uma técnica que utiliza luz na faixa do infravermelho (700 a 1000 nm) para monitorar o fluxo de oxigenação cerebral e o metabolismo de regiões do cérebro (COYLE et al., 2007). Esta técnica fornece resolução espacial da ordem de centímetros. A principal desvantagem da NIRS é sua lentidão relativa, uma vez que depende da latência da resposta hemodinâmica (SITARAM et al., 2007) e (NAGAOKA et al., 2010).
- **Eletroencefalografia:** este método permite monitorar a atividade elétrica do cérebro (HIRSCH; BRENNER, 2010a). O registro gerado pela eletroencefalografia é o eletroencefalograma, que mede, principalmente, a soma dos potenciais pós-sinápticos gerados por milhares de neurônios com a mesma orientação radial em relação ao escalpo. Esta técnica de gravação fornece baixa resolução espacial (ordem de centímetros), mas alta resolução temporal (ordem de milissegundos). Os eletrodos são posicionados sobre o escalpo do indivíduo (JASPER, 1958), permitindo uma configuração rápida e flexível da medição, com enfoque nas regiões cerebrais de interesse. Outro fator positivo é o baixo custo da realização do experimento, em confronto com as demais supracitadas. A eletroencefalografia tem sua aplicação bem consolidada no meio médico-científico, sendo um exame solicitado para diagnóstico de encefalopatias, como a epilepsia, distúrbios do sono e coma (SANEI; CHAMBERS, 2007), (MULERT; LEMIEUX, 2009) e (HIRSCH; BRENNER, 2010b).

### 2.2.1 PARTICULARIDADES ASSOCIADAS AO EEG

A grande maioria dos sistemas BCIs implementados realiza a aquisição dos sinais cerebrais por meio da eletroencefalografia (WOLPAW; MCFARLAND, 2004). A fim de se padronizar os exames de EEG e facilitar a comparação de registros relatados na literatura, o

neurologista Herbert Henri Jasper estudou a melhor forma de dispor os eletrodos sobre o escalpo para realizar o registro EEG. O resultado de seu estudo originou o popular padrão 10-20 (JASPER, 1958). No sistema 10-20, o posicionamento dos eletrodos é dado a partir de duas medidas: a distância náson-ínion e a distância entre os pontos pré-auriculares esquerdo e direito; ambas as medidas devem ser feitas passando pela região central superior do escalpo.

A partir da medida náson-ínion, pode-se marcar cinco pontos ao longo da linha central que liga o náson ao ínion: pré-frontal (Fp), frontal (F), central (C), parietal (P) e occipital (O). O primeiro ponto (Fp) fica posicionado a 10% da distância náson-ínion acima do náson; o ponto F fica a 20% da distância náson-ínion contado a partir do ponto Fp. Os demais pontos distam 20% da distância náson-ínion, a partir do ponto anterior. Desta maneira, o ponto C fica localizado exatamente na metade da distância entre o náson e o ínion. A distância entre os pontos pré-auriculares esquerdo e direito estabelece o posicionamento do ponto temporal (T), o qual está a 10% desta distância do pré-auricular de ambos os lados. Cada posição é denominada através da letra que designa a região e um número, sendo que números ímpares referem-se ao lobo esquerdo e pares, ao lobo direito. A linha média recebe a denominação 'z', referente a zero. O sistema 10-20 permite alocar até 21 eletrodos sobre o escalpo. O avanço de sistemas EEG multicanais e de técnicas de mapeamento da atividade cerebral levou (CHATRIAN; LETTICH; NELSON, 1985) a propor o sistema 10-10, como uma extensão do sistema 10-20, permitindo posicionar 81 eletrodos sobre o escalpo. Geralmente, sistemas BCIs empregam posições mapeadas no sistema 10-10. Entretanto, para uma maior densidade de eletrodos foi proposta por (OOSTENVELD; PRAAMSTRA, 2001) o padrão 10-5, como uma extensão do padrão para 10-10, este sistema permite posicionar até 320 eletrodos (JURCAK; TSUZUKI; DAN, 2007).

Os eletrodos podem ser alocados sobre o couro cabeludo usando gel, pasta ou soluções salinas para melhorar o contato e, conseqüentemente, o monitoramento do potencial elétrico. Os equipamentos mais modernos permitem o uso de eletrodos secos presos a uma touca que garante o contato com o escalpo, esta opção é mais prática e permite um rápido posicionamento dos eletrodos; entretanto, a qualidade na aquisição sofre uma ulterior degradação, com redução na relação sinal-ruído.

Uma vez posicionados os eletrodos, a aquisição do potencial elétrico do sinal cerebral pode ser feito considerando duas modalidades diferentes de medidas (MULERT; LEMIEUX, 2009) e (HIRSCH; BRENNER, 2010a):

- **Referencial:** é capaz de medir potenciais espalhados. Os eletrodos são alocados nas posições nas quais há interesse em se medir a atividade elétrica e o eletrodo de referência é colocado em uma posição de interesse, como uma posição central (Cz), ou em uma posição com pouca atividade elétrica, como os lóbulos das orelhas, processos mastoídes e nariz.
- **Bipolar:** para realizar medições de potencial em regiões específicas. Cada eletrodo tem sua própria referência. O sinal de interesse é a diferença de potencial entre os pares de eletrodos.

O potencial do sinal cerebral adquirido pelo EEG é da ordem de dezenas de microvolts, sendo necessária a sua amplificação por meio de amplificadores de biosinais. A coleta sobre o escalpo, aliada à baixa ordem de grandeza do sinal cerebral, tornam inevitável a presença de artefatos no sinal EEG. Os artefatos podem ser instrumentais ou fisiológicos (AMABILE, 2008). Artefatos instrumentais são os interferentes oriundos de fonte não fisiológica, tais como interferência eletromagnética advinda de equipamentos vizinhos ou dos próprios equipamentos de coleta, interferência da rede elétrica, artefatos de impedância, correntes de fuga, entre outros. Os artefatos fisiológicos são originados pelo próprio indivíduo durante a coleta de dados, como batimentos cardíacos, movimentos musculares, respiração, atividade elétrica muscular, piscar de olhos e, até mesmo, atividades elétricas oriundas de processos cognitivos .

Os sinais de EEG normalmente são classificados em diferentes faixas de oscilações, chamadas “ritmos” (DORNHEGE, 2007) e (SANEI; CHAMBERS, 2007), as quais estão associadas a estados fisiológicos em termos de localização espacial e espectral. Os padrões dos ritmos caracterizam vigília, sonolência e sono e variam nas diferentes faixas etárias. Classicamente, tem-se a seguinte divisão dos ritmos cerebrais medidos pelo EEG (DORNHEGE, 2007):

- **Delta:** ritmo lento (1-4 Hz), com uma amplitude relativamente grande, é encontrado principalmente em adultos durante um sono profundo e em idosos durante a vigília ou em estado de sonolência.
- **Theta:** faixa de 4-7 Hz, observado principalmente durante o estado de sonolência em adultos e na vigília de jovens e crianças pequenas.

- **Alpha:** faixa de 8-12 Hz, aparece principalmente no lobo occipital quando o sujeito está relaxado ou com os olhos fechados.
- **Mu:** banda de 8-12 Hz, trata-se do ritmo alpha avaliado em zonas do córtex motor e sensorio-motor. A amplitude deste ritmo varia quando o sujeito executa movimentos. Está presente em alguns indivíduos normais em vigília e sonolência.
- **Beta:** ritmo relativamente rápido (13-30 Hz), observado em indivíduos acordados e conscientes. Este ritmo também é afetado pelo desempenho de movimentos motores.
- **Gama:** frequências entre 30 Hz e 100Hz. Está associado a funções cognitivas e motoras.

Os ritmos a serem analisados, bem como a disposição dos eletrodos, são determinados pelo paradigma de BCI adotado, conforme se apresenta na Seção 2.3.

## 2.3 PARADIGMAS DE BCI

Uma BCI pode explorar diferentes fenômenos neurofisiológicos para extrair informações dos sinais cerebrais capturados. Basicamente, existem dois mecanismos de geração de sinais:

**Exógenos:** os sinais são gerados inconscientemente pelo indivíduo como resposta a um estímulo externo. As BCIs são baseadas nos potenciais relacionados a eventos (ERP, do inglês *Event-Related Potential*) e são ditas BCIs com atenção seletiva.

**Endógenos:** os sinais são gerados conscientemente pelo usuário, não sendo necessária a estimulação externa. Esta abordagem permite projetar BCIs baseadas na imaginação de tarefas.

Na etapa de desenvolvimento de uma BCI, é crucial determinar se o tipo de interação que o usuário terá com o sistema ocorrerá com ou sem estimulação externa, ou seja, se será exógena ou endógena. A definição do método mais adequado deve considerar não só o escopo da aplicação, mas também as habilidades do usuário, disponibilidade tecnológica e complexidade computacional. A escolha do paradigma adotado influencia não só a forma de interação que o indivíduo terá com a máquina, mas também está intrinsicamente ligada às

técnicas que serão empregadas no processamento dos sinais cerebrais.

### 2.3.1 PARADIGMAS DE BCI BASEADOS EM ATENÇÃO SELETIVA

A atenção seletiva é uma habilidade cerebral que permite ao indivíduo identificar e se concentrar em certos aspectos de interesse dentre os inúmeros estímulos ao qual está exposto em um determinado momento. Ela atua como um filtro cognitivo da grande quantidade de informações sensoriais processadas pelo cérebro. Os estímulos externos recebidos, que podem ser auditivos, somatossensoriais ou visuais, são traduzidos, de maneira inconsciente para o indivíduo, em sinais cerebrais com padrões bem definidos (EASON; HARTER; WHITE, 1969), (PINEDA; ALLISON; VANKOV, 2000) e (CICHOCKI et al., 2008). As características destes potenciais cerebrais podem ser exploradas para idealizar BCIs. No momento, as abordagens mais utilizadas são o P300 e o Potencial Evocado em Regime Estacionário (SSEP, do inglês *Steady-State Evoked Potential*) (AMIRI et al., 2013).

- **P300:** O P300 é um potencial que aparece, principalmente, nos sinais do lobo parietal cerca de 300 ms após o acontecimento de um evento esperado (ver Figura 2.3) (GODÓI, 2010). As primeiras observações da onda P300 foram relatadas em meados da década de 60, em experimentos que utilizaram estímulos visuais. Os principais estudos da época (CHAPMAN; BRAGDON, 1964), (SUTTON et al., 1965), (SUTTON et al., 1967) e (BASHORE; MOLEN, 1991) relatam a detecção da onda P300 para sujeitos visualmente estimulados e constatam que a amplitude do potencial P300 tende a ser maior quanto menos provável for o aparecimento do estímulo e quanto mais relevância ele tiver para o indivíduo estimulado.

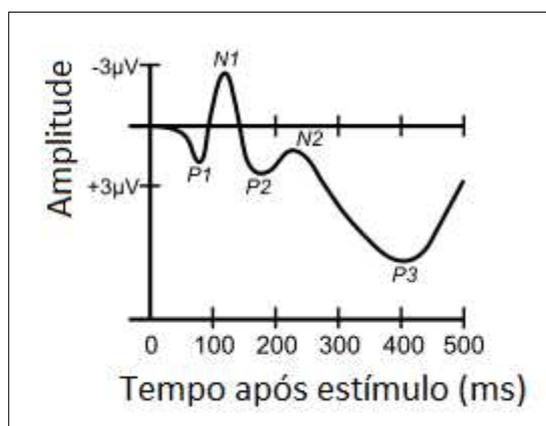


Figura 2.3 – Onda P300.

O paradigma clássico para analisar o P300 é o *oddball*, no qual o estímulo alvo é projetado inesperadamente entre estímulos variados, gerando a resposta evocada P300 com a sua aparição (HUETTEL; MCCARTHY, 2004).

Por ser um sinal cerebral gerado inconscientemente, não se sabe de indivíduos que consigam realizar um bom controle de seus P300. Devido a isto, esta técnica também é empregada em testes de mentiras, monitorando o sinal cerebral dos indivíduos durante o interrogatório (FARWELL; DONCHIN, 1991).

O P300 também pode ser empregado para permitir a comunicação homem-computador. A primeira BCI baseada em P300 foi proposta em 1988 por (FARWELL; DONCHIN) e consistia de um “*speller*”, na qual uma matriz de símbolos 6x6 era projetada, conforme mostra a Figura 2.4. As linhas e colunas da projeção eram destacadas aleatoriamente, de modo que quando a intersecção de linha e coluna realçava o símbolo desejado pelo indivíduo, se evocava a resposta P300. Na Figura 2.4, vê-se realçada a segunda linha e a segunda coluna, destacando a letra ‘H’. Supondo que o usuário estivesse esperando o destaque deste símbolo, 300 ms após este brilho, seria possível verificar o aparecimento da onda P300 (Figura 2.3) no seu sinal cerebral, indicando a sua escolha. O sincronismo entre os destaques e a detecção da onda P300 permite à máquina decodificar a intenção do ser humano que a opera.



A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	0	1	2	3
4	5	6	7	8	9

Figura 2.4 – Matriz de estímulos P300.

Esta mesma aplicação também pode ser desenvolvida utilizando estímulos auditivos ou audiovisuais, em vez de visuais (SCHREUDER;

BLANKERTZ; TANGERMANN, 2010). As principais vantagens de se usar a resposta P300 para projetar BCIs são:

- Confiabilidade na detecção da resposta P300;
- Facilidade de uso da interface, exigindo pouco ou nenhum treinamento prévio;
- Interfaces simples e genéricas que permitem utilização para diversos usuários.
- Alta taxa de transferência de bits (cerca de 30 bits/min) (LENHARDT; KAPER; RITTER, 2008).

Em contrapartida, esta técnica exige a concentração do usuário nos estímulos apresentados.

- **SSEP:** Quando indivíduos são submetidos a estímulos periódicos é possível verificar o potencial cerebral SSEP. Atualmente, a abordagem mais empregada para conceber BCIs é o Potencial Visual Evocado em Regime Estacionário, mas também existem versões usando estímulos auditivos e sensoriais.
- **SSVEP:** A neurofisiologia do sistema visual humano relata que a atividade neuronal das células do córtex visual é alterada por estimulação visual, sendo possível identificar variações da resposta do cérebro relacionadas às propriedades do estímulo visual, tais como luminância, contraste e frequência (HERMANN, 2001). Os neurônios no córtex visual tendem a sincronizar seus disparos para a frequência de intermitência do estímulo visual. As interfaces para as BCI-SSVEP apresentam um conjunto de estímulos visuais, cada um associado a um comando específico a ser executado pela BCI. Em contraste com a abordagem do P300, estes estímulos não piscam sucessivamente, mas sim continuamente com frequências diferentes (entre 5 e 100 Hz) (REGAN, 1977a). Quando o indivíduo foca sua atenção em um dos estímulos, observa-se um aumento de energia nas frequências correspondentes à frequência do estímulo e nas suas harmônicas/sub-harmônicas, principalmente no monitoramento da atividade cerebral da região occipital. A estimulação visual pode ser realizada de diversas maneiras, as mais clássicas são por LEDs ou por projeções em tela (ZHU et al., 2010). Os LEDs apresentam flexibilidade na definição das frequências de estimulação,

possibilitando uma maior possibilidade de comandos; em contrapartida, tendem a gerar um maior desconforto visual aos usuários e geralmente necessitam de um sistema de hardware a mais, dificultando a locomoção do BCI e aumentando o número de interferentes externos. Os estímulos gerados em tela ficam restritos a frequências múltiplas/submúltiplas da taxa de atualização do equipamento utilizado, limitando o número de comandos disponíveis para controlar a aplicação. Em contrapartida, já há o isolamento eletromagnético entre o estímulo e os eletrodos, e é prático alterar as características do estímulo tais como cor, frequência, tamanho, contraste, fase, entre outros.

Alguns trabalhos buscam definir a melhor forma de se estimular visualmente, considerando, além do pico do potencial visual, o conforto e a segurança do indivíduo (SOUTELLO et al., 2015) e (ZHU et al., 2010). As formas mais frequentes são projetando em um monitor o padrão xadrez ou quadrado, ou usando LEDS, e as faixas de frequência mais usadas são de 5 a 30 Hz, por serem seguras e causarem menos desconforto.

A Figura 2.5 ilustra uma interface BCI-SSVEP. Neste exemplo, há quatro estímulos visuais no padrão xadrez que cintilam concomitantemente em diferentes frequências na tela. Cada estímulo está associado a um comando específico, como frente/trás/esquerda/direita, a ser enviado a uma aplicação, por exemplo, um veículo de controle remoto; quando o indivíduo se concentra no padrão visual referente ao comando que deseja operar, torna-se possível identificar o aparecimento do potencial evocado, que se reflete como um aumento de energia na mesma frequência do estímulo visual focado. SSVEPs apresentam uma boa relação sinal-ruído e são robustos a artefatos, uma vez que as faixas de frequência que contém as informações de interesse são conhecidas e estreitas. Todavia, seu uso requer que o indivíduo olhe fixamente para o estímulo visual, o que torna esta abordagem inadequada para pacientes com problemas visuais ou com movimentação dos olhos restrita, além de com o tempo, poder causar fadiga.

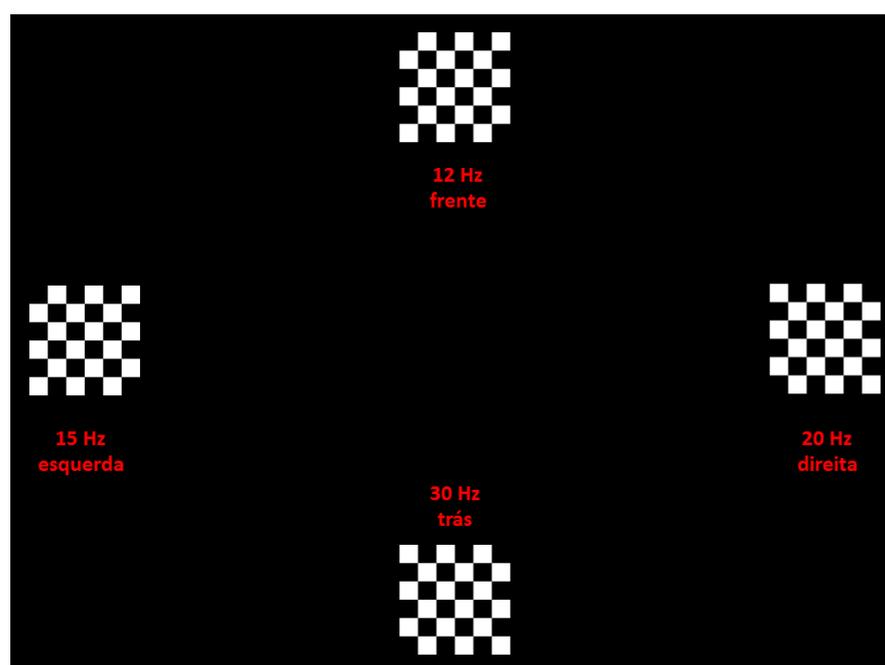


Figura 2.5 – Interface de estímulos visuais – SSVEP.

Outro modo de evocar o potencial cerebral é a abordagem somatossensorial. Neste caso, o indivíduo é estimulado através do tato, aplicando-se uma pressão repetida contra a pele. Pode-se, por exemplo, aplicar estímulos vibratórios em diferentes dedos, cada um referente a um comando específico. O indivíduo é solicitado a se concentrar no dedo que representa o comando desejado, a análise do potencial evocado em estado estacionário nos córtices somatossensoriais primário e secundário permite identificar em qual dedo o sujeito concentrou sua atenção sensitiva. Atualmente, esta abordagem é pouco utilizada, mas é uma opção para pacientes que perderam as habilidades de visão (MULLER-PUTZ et al., 2006).

Também é possível conceber uma BCI explorando o potencial evocado por estimulação auditiva (NIJBOER et al., 2008) e (HIGASHI et al., 2011). Normalmente, o estímulo é gerado por tons senoidais e as respostas auditivas evocadas são encontradas no córtex auditivo (ROSS, PICTON, PANTEV, 2002) e (KIM et al., 2011). As frequências de modulação ótimas, geralmente, estão na faixa de 40 Hz (GALAMBOS, MAKEIG, TALMACHOFF, 1981), (ENGELIEN et al, 2000) e (ROSS et al., 2003) e a atenção do sujeito é medida pela amplitude do sinal evocado.

As modalidades de BCI usando SSEP apresentam diversas vantagens:

- Podem ser utilizadas pela maior parte das pessoas (ALLISON et al., 2010);
- Dependem minimamente da atividade cognitiva, facilitando aplicações assistivas (ALLISON et al., 2008);

- Não requerem treinamento significativo, permitindo a utilização com bom desempenho desde a primeira vez;
- Elevada taxa de transferência de informação, chegando a 75 bits/min (CHENG et al., 2002) e (WANG; WANG; JUNG, 2010).

Entretanto, o uso de estímulos externos pode levar a desconforto e cansaço, uma vez que se exige a concentração do indivíduo.

### 2.3.2 PARADIGMAS DE BCI BASEADOS EM IMAGÉTICA

Sabe-se que a atividade cerebral humana varia de acordo com o estado emocional e físico do indivíduo (CURRAN; STOKES, 2003). Processos cognitivos internos, voluntariamente gerados pelo usuário, geram padrões cerebrais bem definidos. É possível identificar, por exemplo, se o sujeito está em estado de vigília ou de sono, ou diferenciar se ele está imaginando o movimento do pé ou da mão, ou ainda se está concentrado ou em estado de repouso. A imaginação do indivíduo pode ser explorada a fim de se construir uma BCI. Existem duas vertentes para instigar a imaginação e gerar os sinais de controle: a imagética motora e a imagética não motora.

- **Imagética Motora** – A realização de movimentos dos membros produz padrões específicos de atividade no córtex motor bem conhecidos na neurociência (PINEDA; ALLISON; VANKOV, 2000). É possível que um indivíduo gere padrões com o mesmo perfil simplesmente imaginando a realização de movimentos, como da mão direita, da mão esquerda, dos pés e/ou da língua. A investigação dos sinais gerados é analisada no córtex motor, principalmente nas faixas *mu* e *beta* (ver Seção 2.2.1); esta localização bem definida facilita a detecção e o monitoramento do sinal cerebral. A imagética motora permite que o usuário treinado automatize a condução da sua própria imaginação, uma vez que a imaginação de tarefas motoras simples, como abrir e fechar as mãos, tende a se tornar natural. O protocolo padrão de condução de uma BCI por imagética motora é descrito no trabalho de (PFURTSCHELLER, FLOTZINGER, NEUPER, 1994) e permite distinguir o movimento de pés, mão direita, mão esquerda e língua. A primeira BCI implementada usando a imagética motora foi relatada em (WOLPAW et al., 1991), e permitia o controle do movimento do cursor em uma tela. Atualmente, existem

diversos grupos de pesquisas desenvolvendo variadas aplicações de BCIs baseados em imaginação de movimentos, dentre as quais se podem destacar: controle de órtese de mão (PFURTSCHELLER; NEUPER, 2001), controle de robôs (MCFARLAND; WOLPAW, 2008), controle de cadeira de rodas automática (REBSAMEN et al., 2010), controle de quadricóptero no espaço tridimensional (LAFLEUR et al., 2013), controle de jogos imersivos (BONNET; LOTTE; LÉCUYER, 2013).

- **Imagética Não Motora** – A realização de tarefas mentais, como imaginação de figuras geométricas, geração mental de palavras, realização de cálculos mentais e imaginação de música geram variações da atividade cerebral que podem ser monitoradas a fim de conduzirem uma BCI (CURRAN et al., 2004), (PALANIAPPAN, 2005) e (ABBAS; ABO-ZAHHAD; AHMED, 2015). Ainda não há um protocolo definindo acerca de qual seria a melhor tarefa de imagética, de como treinar o usuário e a melhor maneira de se conceber uma BCI usando esta abordagem. Entretanto, existem trabalhos descrevendo BCI com imagética não motora, entre eles pode-se citar: Curran *et al.* (2004) que relatam o uso da imaginação de navegação espacial, na qual o voluntário é solicitado a conduzir uma atividade mental de imaginar os cômodos e suas disposições em um ambiente familiar, como o seu quarto; Meister *et al.*, (2004) que solicitam aos voluntários que toquem piano mentalmente; também há relatos de condução de BCI por meio de cálculos mentais descrito em (POWER; FALK; CHAU, 2010) e por imaginação de música, aonde o voluntário deve imaginar sua melodia favorita ou uma música popularmente conhecida (CURRAN et al., 2004) e (SORIANO et al., 2013).

A imagética não motora exige um maior esforço cognitivo do usuário que a imagética motora, o que a torna mais propensa a interferências com outras operações mentais; por exemplo, compor um manuscrito é muito mais fácil se o escritor não precisar pensar individualmente em cada letra (MCFARLAND e WOLPAW, 2011). Entretanto, alguns estudos (MINER; MCFARLAND; WOLPAW, 1998) e (KENNEDY et al., 2000) apresentam que a automatização da imagética degrada a qualidade do sinal, sendo necessária a concentração do usuário. Desse modo, a imaginação de tarefas cognitivas tende a gerar uma atividade cerebral mais intensa e proporcionar um desempenho melhor ao sistema BCI (CURRAN et al., 2004). Uma dificuldade em se empregar esta abordagem é delinear a região cerebral a ser investigada, uma vez que ela está intrinsecamente relacionada à tarefa cognitiva realizada (SORIANO et al., 2013).

Em ambos os casos, a maneira como a imaginação deve ser realizada não é fixa e cada indivíduo pode desenvolver sua própria técnica. Para aprender a desempenhar funções cognitivas o usuário precisa passar por uma fase de treinamento. Normalmente, o treinamento envolve um ambiente virtual com *feedback* no qual o usuário consegue avaliar quais estratégias mentais são melhores para gerar determinados controles e como ele deve modificar sua atividade cerebral, a fim de controlar melhor o sistema. A fase do treinamento é essencial para garantir um bom desempenho do sistema e pode exigir semanas ou até mesmo meses. Entretanto, controlar uma BCI com sinais espontâneos torna o sistema mais natural e confortável para o usuário.

## 2.4 CONSIDERAÇÕES

O apelo inovador das BCIs tem conquistado muito investimento na área, tanto privado como governamental (BERGER et al., 2008) e (ALLISON, 2011). Atualmente, há muitas pesquisas sendo realizadas nos diversos campos de conhecimento envolvendo médicos, físicos, engenheiros, psicólogos, designers, entre outros, e contribuindo para progressos nas mais diversas áreas do saber. Por exemplo, na área médica, a neurociência está obtendo avanços na compreensão do funcionamento cerebral e da relação entre doenças neuro-musculares com processos neurofisiológicos e atividades cerebrais. Na área psico-comportamental, há aperfeiçoamento no entendimento de como se dá a interação do indivíduo com o meio externo e dos processos que envolvem a resposta do indivíduo aos estímulos externos ou motivações internas. Na área tecnológica, as BCIs abriram um amplo leque de aplicações que contemplam desde jogos imersivos (MASON et al., 2007) a tecnologias assistivas, capazes de agregar qualidade de vida a pessoas que sofrem com paralisia cerebral ou com doenças neuromusculares graves, como a esclerose lateral amiotrófica (ELA), acidente vascular cerebral, paralisia cerebral, ou lesão da medula espinhal. Existem diversos grupos de pesquisas (GUGER; ALLISON; MÜLLER-PUTZ, 2015) engajados no desenvolvimento de aplicações BCIs para as mais diversas finalidades, usando tanto paradigmas de atenção seletiva como de imagética e empregando registros cerebrais obtidos tanto por meio invasivo como de maneira não invasiva. No momento, a grande maioria das BCIs opera em ambiente controlado (MARTINEZ; BAKARDJIAN; CICHOCKI, 2007), (LI et al., 2013), (MULLER et al., 2013) e (WANG et al., 2014) e são desenvolvidas de maneira

específica para determinado indivíduo. Ainda há muitos desafios a serem solucionados para se permitir que os sistemas BCIs se tornem suficientemente robustos, eficientes e confiáveis, de maneira que possam ser disponibilizados em larga escala para a população. Pode-se dizer que uma das principais barreiras é conseguir extrair as informações necessárias, em tempo de execução, de sinais cerebrais registrados em ambientes genéricos, permeados das mais diversas fontes de interferência, e garantir que este processamento seja rápido e confiável, principalmente para aplicações destinadas à área médica-assistiva. Esta tarefa recebe contribuições neste trabalho e, apesar de desafiadora, mostra-se tangível, visto o enorme esforço científico sendo empregado com este fim.

### 3. PROCESSAMENTO DE SINAIS APLICADO A SISTEMAS BCI-SSVEP

Pode-se dizer que o módulo de processamento de sinais é o coração de um sistema BCI. É nesta etapa que o sinal cerebral capturado é interpretado e traduzido para sinais de controle e/ou comunicação. A Figura 3.1 mostra as quatro etapas englobadas no processamento de sinais de uma interface desse tipo. A primeira, o pré-processamento, é responsável por melhorar a qualidade do sinal cerebral aumentando a relação sinal ruído. As etapas de extração e seleção de características são estreitamente ligadas ao paradigma de BCI adotado, sendo responsáveis por extrair os melhores parâmetros que caracterizem o sinal e permitam a discriminação das diversas classes (comandos da aplicação). Na quarta etapa, atua o classificador, que gera, efetivamente, o comando a ser enviado à aplicação final.

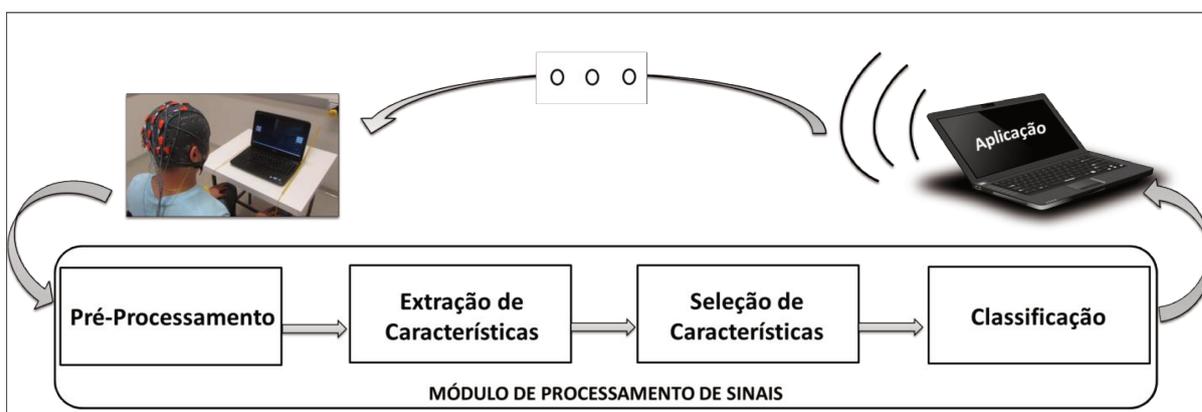


Figura 3.1 – Etapas do módulo de processamento de sinais.

As técnicas empregadas na análise e processamento do sinal impactam diretamente no desempenho do sistema como um todo. Não obstante, elas determinam características importantes da BCI, tais como a capacidade mínima de processamento exigida, a possibilidade de desenvolver dispositivos de controle embarcado, o tempo de resposta e a taxa de transmissão de informação. Nesse sentido, a metodologia utilizada para realizar o processamento de sinais deve ser pensada tendo em vista as possíveis aplicações alvo. O controle de próteses ou equipamentos mecânicos, como uma cadeira de rodas motorizada ou um robô, exige alta taxa de acerto para evitar danos ao usuário; por outro lado, esse controle, devido à inercia mecânica, tolera uma taxa de transmissão mais baixa, da ordem de segundos. Em contrapartida, jogos imersivos requerem que o processamento ocorra de forma rápida,

para que os comandos sejam dados na ordem de milissegundos, mas permitem uma maior flexibilidade na taxa de acerto.

Este trabalho foi norteado para o desenvolvimento de uma BCI-SSVEP direcionada a controlar aplicações assistivas em tempo de execução, mais especificamente, uma cadeira de rodas motorizada destinada a pacientes que sofreram AVC, dentro do projeto DESTINE. O presente capítulo cobre a teoria relacionada às técnicas utilizadas para o desenvolvimento de sistemas BCIs, abrangendo todas as etapas do processamento de sinais – pré-processamento, extração e seleção de atributos e classificação.

### **3.1 PRÉ-PROCESSAMENTO**

Diversas interferências permeiam o sinal de EEG durante a sua aquisição (AMABILE, 2008). Embora as fontes de ruído sejam muito complexas e variem entre os indivíduos, existem técnicas de filtragem que permitem remover os artefatos e melhorar a relação sinal-ruído do sinal EEG. Devido à natureza do sinal SSVEP, cujas informações de interesse se apresentam em frequências bem determinadas, várias fontes de artefatos acabam não prejudicando o desempenho do sistema BCI, tornando o pré-processamento menos penoso que o enfrentado em paradigmas aonde a informação é disseminada em todo o espectro. O maior desafio reside na tarefa de realizá-lo em janelas temporais pequenas, de modo a viabilizar a execução *online*. Neste trabalho, concentrou-se na aplicação de técnicas de filtragem espacial, descritas nas subseções seguintes.

#### **3.1.1 MÉDIA DE REFERÊNCIA COMUM**

Idealmente, a diferença de potencial registrada pelo EEG deveria refletir somente a atividade elétrica neuronal e, para isso, registros de EEG que usam referência comum necessitam que o eletrodo de referência seja posicionado em um local isento de biopotencial. Todavia, é difícil encontrar um local de potencial nulo no corpo humano (RANTA; SALIDO-RUIZ; LOUIS-DORR, 2010) e isso, inevitavelmente, interfere nas gravações EEG (DIEN, 1998). Classicamente, tenta-se reduzir as distorções na gravação posicionando a referência em locais que tendem a neutralizar ou ao menos reduzir a ação dos biopotenciais, como o Cz, extremidade do nariz, processos mastoides ou lóbulos das orelhas. A escolha do

posicionamento depende do mapeamento cerebral que se deseja realizar, por exemplo, a conexão dos dois lóbulos das orelhas ou processos mastóides reduz a probabilidade de ressaltar artificialmente a atividade em um hemisfério cerebral, enquanto que a referência em Cz é vantajosa se os eletrodos estão distribuídos ao seu redor.

A técnica média de referência comum (CAR, do inglês *Common Average Reference*) atua de modo a proporcionar uma referência neutra para os registros EEG. Ela se baseia no princípio de que eventos elétricos geram pólos positivos e negativos, de modo que a integral do campo elétrico gerado em uma esfera condutora resulta em zero, ou seja, se toda a cabeça fosse coberta por eletrodos igualmente espaçados e o potencial fosse gerado por fontes pontuais, o CAR resultaria em uma distribuição de tensão espacial de média zero (BERTRAND; PERRIN; PERNIER, 1985). Como a hipótese de distribuição dos eletrodos de maneira uniforme e de modo a cobrir toda a cabeça, geralmente, não é observada na prática, o CAR fornece uma gravação de EEG que é aproximadamente livre de referência.

O CAR é uma técnica de filtragem espacial que reduz as componentes que estão presentes em maior número de eletrodos. A técnica consiste na subtração, amostra a amostra, entre o valor médio da diferença de potencial calculada para todos os eletrodos e a diferença de potencial aferida em cada eletrodo. Matematicamente, pode-se definir:

$$V_i^{CAR} = V_i^{ER} - \frac{1}{N_e} \sum_{j=1}^{N_e} V_j^{ER} \quad (3.1)$$

onde  $V_i^{ER}$  é o potencial do  $i$ -ésimo eletrodo e  $N_e$  é o número de eletrodos utilizados. Os eletrodos devem usar a montagem referencial.

Apesar da grande simplicidade matemática e computacional, o CAR é capaz de ajustar a referência de potencial dos eletrodos, além de eliminar uma parte dos artefatos presentes no sinal. Isto é possível devido ao fato de que a maioria dos artefatos que prejudicam a resposta SSVEP aparece concomitantemente e com intensidade semelhante em todos os eletrodos, enquanto o sinal de interesse se apresenta de forma mais intensa apenas em alguns eletrodos, principalmente nos eletrodos posicionados na zona occipital (MCFARLAND et al., 1997). Outra vantagem do CAR é que ele atua amostra a amostra, tornando factível a sua utilização em sistemas que devem operar em tempo de execução.

### 3.1.2 COMBINAÇÃO DE MÍNIMA ENERGIA

A técnica de filtragem espacial baseada na combinação de mínima energia (MEC, do inglês *Minimum Energy Combination*) tem como objetivo combinar os eletrodos de modo a cancelar, maximamente, os ruídos, interferências e artefatos (FRIMAN; VOLOSYAK; GRÄSER, 2007) e (NAN et al., 2011).

A diferença de potencial entre o  $i$ -ésimo eletrodo e o eletrodo de referência no instante de tempo  $t$  pode ser descrita em função da frequência de estimulação visual  $f$ , de modo que o sinal lido pelo EEG pode ser descrito como:

$$v_i(t) = \sum_{k=1}^{N_h} a_{i,k} \text{sen}(2\pi kft) + b_{i,k} \text{cos}(2\pi kft) + e_i(t) \quad (3.2)$$

Este modelo linear é composto de duas partes. A primeira modela o potencial evocado visualmente, o qual pode ser entendido como funções senoidais e cossenoidais com amplitudes  $a_{i,k}$  e  $b_{i,k}$ , respectivamente, referentes ao eletrodo  $i$  e a harmônica  $k$ , em um cenário que considera as primeiras  $N_h$  harmônicas. A segunda parte do modelo,  $e_i(t)$ , representa toda a informação que não se refere ao SSVEP, tais como o ruído do ambiente, artefatos e interferências presentes no eletrodo  $i$ , em um dado instante de tempo.

Matricialmente, tem-se:

$$\mathbf{V} = \mathbf{XC} + \mathbf{E} \quad (3.3)$$

onde  $\mathbf{X}$  é uma matriz  $N_a \times 2N_h$  formada pelos pares  $\text{sen}(2\pi kft)$  e  $\text{cos}(2\pi kft)$  nas colunas para cada harmônica,  $\mathbf{C}$  é uma matriz  $2N_h \times N_e$  que contém as amplitudes  $a_{i,k}$  e  $b_{i,k}$  e  $\mathbf{E}$  é a matriz com o conteúdo ruidoso de dimensão  $N_a \times N_e$ , sendo  $N_a$  o número de amostras de um segmento do sinal e  $N_e$  o número de eletrodos utilizados na captura.

O MEC realiza uma combinação linear conveniente dos sinais lidos pelos eletrodos formando os canais  $s(t)$  da seguinte maneira:

$$s(t) = \sum_{i=1}^{N_e} w_i v_i(t) = \mathbf{V}\mathbf{w} \quad (3.4)$$

em representação matricial:

$$\mathbf{S} = \mathbf{V}\mathbf{W} \quad (3.5)$$

onde  $\mathbf{W}$  é uma matriz  $N_e \times N_c$  que contém os pesos de cada combinação em suas colunas e  $N_c$  denota o número de canais formados. Por “combinação linear conveniente”, a técnica MEC entende que a energia do ruído deva ser minimizada. Assim, a chave da combinação linear passa pela definição dos pesos ótimos da matriz  $\mathbf{W}$ , que depende da natureza do sinal SSVEP e do ruído presente no sinal capturado. Uma forma de abordar este problema é realizar uma projeção ortogonal de  $\mathbf{V}$  em relação a  $\mathbf{X}$ , de modo a se obter uma matriz  $\tilde{\mathbf{V}}$  que isole a componente ruidosa do sinal (FRIMAN; VOLOSYAK; GRÄSER, 2007), i.e:

$$\tilde{\mathbf{V}} = \mathbf{V} - \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{V} \quad (3.6)$$

A filtragem MEC consiste, justamente, em determinar o vetor de pesos  $\hat{\mathbf{w}}$ , de norma unitária, que minimize a energia resultante da combinação dos sinais dos eletrodos  $\tilde{\mathbf{V}}\hat{\mathbf{w}}$ . Este problema de otimização pode ser matematicamente escrito como:

$$\min_{\hat{\mathbf{w}}} \|\tilde{\mathbf{V}}\hat{\mathbf{w}}\|^2 = \min_{\hat{\mathbf{w}}} \hat{\mathbf{w}}^T \tilde{\mathbf{V}}^T \tilde{\mathbf{V}} \hat{\mathbf{w}} \quad (3.7)$$

A forma quadrática da expressão (3.7) é limitada pelos autovalores mínimo  $\lambda_1$  e máximo  $\lambda_{N_c}$  da matriz simétrica  $\tilde{\mathbf{V}}^T \tilde{\mathbf{V}}$ .

A solução deste problema de minimização é dada pelo autovetor  $y_1$  associado ao menor autovalor e a energia da combinação resultante é igual ao menor autovalor  $\lambda_1$ . Devido à simetria da matriz  $\tilde{\mathbf{V}}^T \tilde{\mathbf{V}}$ , os autovetores são ortogonais entre si e uma combinação dos sinais dos eletrodos usando o segundo “menor autovetor” produz um segundo canal, que é decorrelacionado do primeiro e que apresenta a segunda menor quantidade de energia. Desta forma, a escolha dos autovetores como colunas da matriz de pesos  $\mathbf{W}$ , leva à obtenção dos canais decorrelacionados com uma energia de ruído crescente. A matriz de pesos pode ser definida como:

$$\mathbf{W} = \left( \frac{y_1}{\sqrt{\lambda_1}} \dots \frac{y_{N_c}}{\sqrt{\lambda_{N_c}}} \right) \quad (3.8)$$

A normalização de cada autovetor com a raiz quadrada do autovalor é conveniente para que os canais resultantes tenham uma energia normalizada, o que facilita a análise. O

critério de escolha do número de autovetores incluídos na matriz de pesos pode ser definido de forma a eliminar um porcentual considerado do ruído. Por exemplo, pode-se calcular a taxa

$$\frac{\sum_{i=1}^{N_c} \lambda_i}{\sum_{j=1}^{N_e} \lambda_j} > 0,1 \quad (3.9)$$

sendo que o denominador contém a energia total do sinal, considerando todos os eletrodos e o numerador contém a energia acumulada pela soma dos canais de menor quantidade de energia. Se a razão for maior que 0,1, cerca de 90% da energia do ruído é eliminada.

Embora a resposta SSVEP também seja afetada pela matriz de pesos, pode-se, *a priori*, considerar que ela é mais facilmente detectável nos primeiros canais, os quais contêm menor nível de ruído.

### 3.1.3 COMBINAÇÃO DE MÁXIMO CONTRASTE

A combinação de máximo contraste (MCC, do inglês *Maximum Contrast Combination*) pode ser vista como uma técnica de filtragem espacial cuja finalidade é maximizar a energia do sinal de interesse, no caso do potencial evocado, e minimizar o ruído (FRIMAN; VOLOSYAK; GRÄSER, 2007). Trata-se de uma abordagem semelhante à MEC, cuja função objetivo é dada por:

$$\max_{\hat{\mathbf{w}}} \frac{\|\mathbf{V}\hat{\mathbf{w}}\|^2}{\|\tilde{\mathbf{V}}\hat{\mathbf{w}}\|^2} = \max_{\hat{\mathbf{w}}} \frac{\hat{\mathbf{w}}^T \mathbf{V}^T \mathbf{V} \hat{\mathbf{w}}}{\hat{\mathbf{w}}^T \tilde{\mathbf{V}}^T \tilde{\mathbf{V}} \hat{\mathbf{w}}} \quad (3.10)$$

A solução desse problema pode ser encontrada dividindo os autovalores e autovetores da matriz simétrica  $\mathbf{V}^T \mathbf{V}$  pelos da matriz  $\tilde{\mathbf{V}}^T \tilde{\mathbf{V}}$ . Os autovetores fornecem a localização dos pontos de máximo enquanto os autovalores indicam os quocientes desses máximos. Por construção, todos os autovalores são maiores ou iguais a 1. Os autovetores correspondentes aos maiores autovalores indicam os canais com melhor relação sinal-ruído. A matriz de pesos  $\mathbf{W}$  pode ser calculada por (3.8) e os canais podem ser determinados por (3.5), de maneira análoga à realizada para o MEC. O número de canais a serem gerados pode ser determinado usando o critério de incluir os autovetores cujos autovalores são maiores que  $\frac{N_a}{N_a - 2N_h}$ , conforme indicado em (FRIMAN; VOLOSYAK; GRÄSER, 2007).

O MEC e MCC são duas técnicas de filtragem espacial, classicamente, utilizadas para tratar sinais SSVEP. Diversos trabalhos, entre eles (FRIMAN; VOLOSAYAK; GRÄSER, 2007), (WANG et al., 2010), (GARCIA-MOLINA; ZHU, 2011), (MORA et al., 2014), (MORA; MUNARI; CIAMPOLINI, 2015) e (TAVARES et al., 2015) apresentam um estudo comparativo entre filtros espaciais e destacam o MEC e o MCC, respectivamente, como sendo as técnicas que possuem melhor desempenho em SSVEP. Desta forma, elas foram aplicadas na base de dados, gerada ao longo deste trabalho, a título de comparação de desempenho da BCI. Ambas as técnicas podem ser utilizadas isoladamente ou como passo sucessivo à filtragem CAR.

### 3.2 EXTRAÇÃO DE CARACTERÍSTICAS

Um dos principais desafios no projeto de um dispositivo de processamento é a definição da forma de representação dos dados de entrada. Geralmente, usar o sinal de entrada diretamente para se obter os valores de saída é uma abordagem de baixo desempenho e alto custo computacional. Para a maioria das aplicações é conveniente mapear o sinal de entrada em outro espaço que permita a representação das informações relevantes de forma compacta e eficiente. Esta etapa denomina-se extração de características. Todavia, encontrar uma boa representação dos dados em um domínio específico não é uma tarefa trivial. Ao mesmo tempo em que se deve tomar cuidado para não se descartarem informações úteis, é necessário reduzir o espaço de características para evitar a maldição da dimensionalidade, isto é, que os dados sejam pouco representativos para a quantidade de material disponível para o treinamento do preditor. Há diversas técnicas que podem ser empregadas para operar a extração de características, tais como transformada de Fourier, transformada Wavelet, decomposição PCA/SVD (*Principal Component Analysis/Singular Value Decomposition*), cálculo de parâmetros estatísticos ou coeficientes autorregressivos, utilização de técnicas de análise de recorrência de dados, entre outras (OPPENHEIM; SCHAFER; BUCK, 1999), (BISHOP, 2006), (DUDA; HART; STORK, 2012).

A representação das características é uma oportunidade de se incorporar conhecimento de domínio aos dados, para uma aplicação específica, e deve ser analisada caso a caso. Para o problema de BCI, a escolha dos atributos a serem extraídos do sinal EEG está fortemente relacionada ao paradigma adotado (DORNHEGE, 2007). Em P300, costuma-se

adquirir os atributos no domínio temporal, aproveitando-se do sincronismo existente entre o evento e a resposta cerebral. Em imaginação de movimento, frequentemente, exploram-se as características espectrais nas bandas de frequências cerebrais, embora seja desejável utilizar-se também das informações temporais ou em outros domínios transformados para enriquecer a análise do sistema (URIBE et al., 2014). Classicamente, em SSVEP, empregam-se técnicas ligadas à extração de informações espectrais, como o cálculo da densidade espectral de potência (PSD, do inglês *Power Spectral Density*) em torno das frequências evocadas. Esta abordagem é imediatamente justificada quando se observa o espectro do sinal EEG. O espectro de uma série temporal descreve como a variância dos dados está distribuída ao longo do domínio de frequência por meio das componentes em frequência na qual o sinal pode ser decomposto.

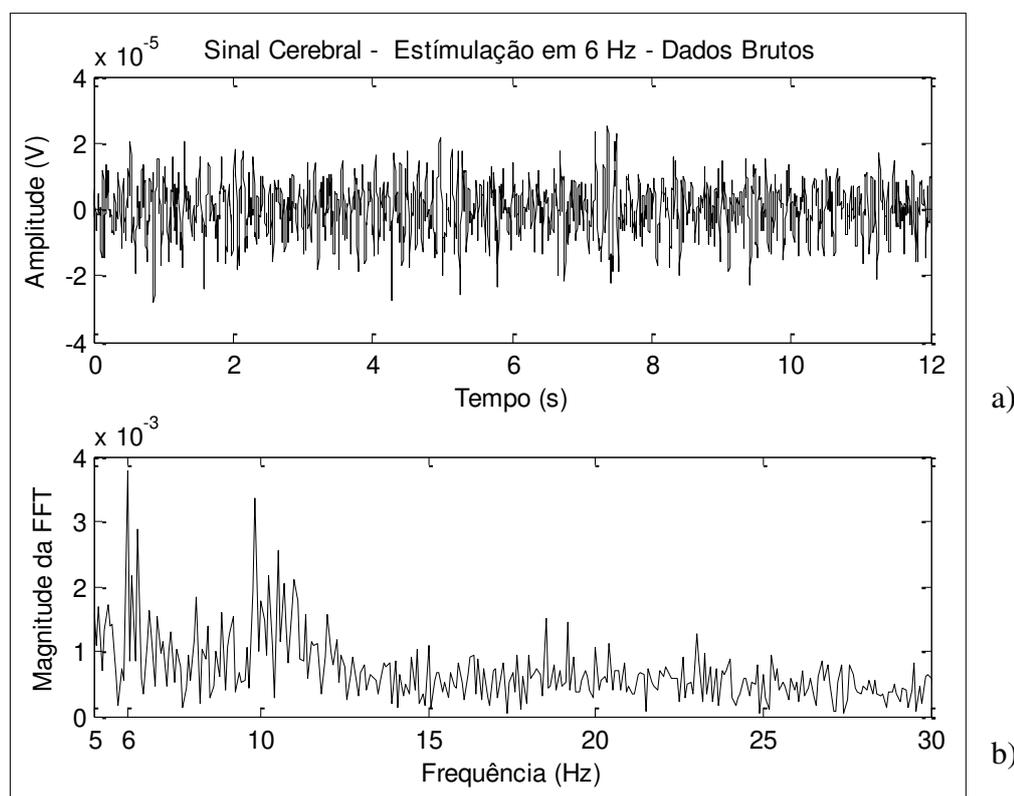


Figura 3.2 – (a) Sinal EEG adquirido em O1 durante estimulação visual em 6 Hz e (b) magnitude da FFT.

A Figura 3.2 mostra a representação no domínio do tempo e da frequência do sinal EEG-SSVEP de um indivíduo exposto à estimulação visual em 6 Hz. Embora ambas as representações contêm informações do sinal cerebral, o espectro de frequência permite uma extração imediata de dados relevantes referentes à qual estímulo visual o indivíduo está concentrado. Observa-se um aumento do conteúdo espectral em torno da frequência de 6 Hz,

i.e., na frequência na qual o indivíduo está sendo estimulado (em torno de 10 Hz também há uma maior densidade de potencia proveniente de interferências). A densidade espectral de potência reflete, justamente, como a potência de uma série temporal está distribuída sobre as diferentes frequências. Se considerarmos que a resposta SSVEP pode ser modelada por um processo estocástico estacionário no sentido amplo, ou seja, um sinal com média constante em todo instante de tempo e com covariância dependente apenas da separação temporal de dois instantes amostrais:

$$\begin{aligned}\mu_X(n) &= E[X(n)] = \mu \quad -\infty < n < \infty \\ c_X[n_1, n_2] &= E[(X(n_1) - \mu_X(n_1))(X(n_2) - \mu_X(n_2))] \\ &= E[(X(n_1)X(n_2))] - \mu^2 \\ &= g(|n_2 - n_1|) \quad -\infty < n_1, n_2 < \infty\end{aligned}\tag{3.11}$$

com  $n_1$  e  $n_2$  inteiros,  $\mu$  uma constante,  $g(\cdot)$  a função que descreve a relação de covariância e  $E[\cdot]$  o operador esperança definido como:

$$E[X] = \sum_n x(n)p_X(x(n))\tag{3.12}$$

onde  $p_X(x(n))$  é a densidade de probabilidade de  $X$ . é possível estimar o valor da potência média em uma banda de frequência de  $x(n)$  a partir do cálculo da densidade espectral de potência, dada por:

$$S_x(\omega) = \lim_{N \rightarrow \infty} \frac{1}{2N + 1} E \left[ \left| \sum_{n=-N}^N x(n)e^{-i\omega n} \right|^2 \right]\tag{3.13}$$

sendo o elemento do operador esperança a transformada de Fourier de tempo discreto (DTFT, do inglês *Discrete Time Fourier Transform*) do sinal de interesse  $x(n)$ , dada por:

$$X(\omega) = \sum_{n=-\infty}^{\infty} x(n)e^{-i\omega n}\tag{3.14}$$

com frequência  $\omega$  limitada pelas frequências de interesse  $\omega_1 \leq \omega \leq \omega_2$  e  $N$  o número de amostras utilizadas no cálculo da transformada de Fourier.

Apesar da popularidade dos métodos de extração de características espectrais na

abordagem de SSVEP, alguns autores, como (BIN et al., 2009), (BRUNNER et al., 2011) e (PORYZALA; MATERKA, 2014), empregam técnicas que exploram as informações contidas no domínio temporal, extraindo características indiretamente, como parâmetros de um modelo de previsão estatística, por exemplo, um modelo autorregressivo (AR) (POLAK; KOSTOV, 1998) e (HAYKIN, 2008) ou realizando a análise de correlação canônica no domínio do tempo (CCA) (HARDOON; SZEDMAK; SHAW-TAYLOR, 2004), (LIN et al., 2006) e (HERCULANO-HOUZEL, 2009), a qual também pode ser considerada uma técnica de filtragem.

As BCI requerem que as características extraídas do sinal cerebral facilitem a tarefa de discriminação realizada na etapa de classificação e, portanto, o desempenho do classificador normalmente é usado para balizar a qualidade dos atributos.

Neste trabalho, foram analisados quatro métodos de extração de características para sinais EEG-SSVEP, sendo três métodos distintos de estimação da potência espectral – banco de filtros, espectrograma e método de Welch, – e um extrator de características no domínio temporal – coeficientes AR pelo método de Burg. Estas técnicas estão descritas nas Subseções 3.2.1 a 3.2.4, respectivamente.

### 3.2.1 BANCO DE FILTROS

O banco de filtros consiste em um conjunto de filtros combinados de maneira a dividir convenientemente o sinal de entrada em múltiplas componentes (HAYKIN, 2008). Esta técnica pode ser empregada para extrair atributos do sinal. Devido às características da resposta SSVEP, que tende a aparecer com um aumento da potência espectral em torno da frequência de cintilação do estímulo visual, um arranjo de filtros banda-passantes permite obter as sub-bandas de interesse, isolando o conteúdo espectral em torno de cada uma das frequências evocadas.

Idealmente, um filtro passa-bandas é definido como:

$$H(\omega) = \begin{cases} 1 & \omega_1 < \omega < \omega_2 \\ 0 & \text{caso contrário} \end{cases} \quad (3.15)$$

ele mantém intactas as componentes na faixa de frequência de interesse,  $\omega_1 < \omega < \omega_2$ , rejeitando completamente as demais componentes.

Todavia, a transição abrupta de 0 para 1 nas frequências de corte ( $\omega_1$  e  $\omega_2$ ) é fisicamente impossível de ser realizada. Na prática, a transição ocorre de maneira gradual e exige uma banda de transição. O projeto de um filtro passa-faixas envolve a especificação de diversos parâmetros, como banda de passagem, faixa de transição, atenuação na banda rejeitada e atenuação na banda passante. Existem diversos tipos de filtro; neste trabalho, utilizaram-se os filtros do tipo Butterworth e equiripple (BUTTERWORTH, 1930) e (OPPENHEIM; SCHAFER; BUCK, 1999). O filtro de Butterworth pode ser concebido de modo a apresentar resposta em frequência plana na banda passante. Já, o filtro equiripple é um filtro do tipo FIR (do inglês, *finite impulse response*) com resposta de fase linear que permite minimizar a amplitude da ondulação tanto na banda de passagem como na banda rejeitada.

A Figura 3.3 mostra os espectros de frequência de um filtro passa-bandas do tipo Butterworth e do tipo equiripple. Ambos os filtros ilustrados foram projetados com especificações idênticas.

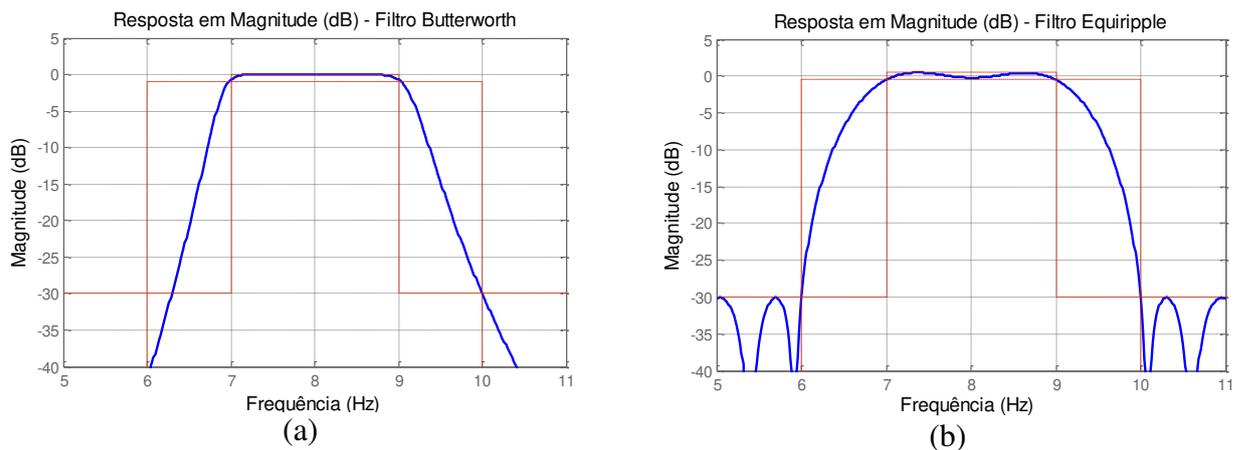


Figura 3.3 – Filtros banda passantes centrados em 8 Hz do tipo (a) Butterworth e (b) equiripple.

Após o projeto do filtro, o sinal filtrado  $y(n)$  pode ser obtido como o resultado da convolução do sinal de entrada  $x(n)$  com a resposta ao impulso do filtro  $h(n)$ :

$$y(n) = x(n) * h(n) \quad (3.16)$$

ou de maneira equivalente, no domínio da frequência, multiplicando o espectro do sinal de entrada pela resposta em frequência do filtro:

$$Y(\omega) = X(\omega)H(\omega) \quad (3.17)$$

em que  $X(\omega)$ ,  $H(\omega)$  e  $Y(\omega)$  são, respectivamente, a transformada de Fourier de  $x(n)$ ,  $h(n)$  e  $y(n)$ .

A potência de saída dos elementos do banco de filtros é considerada como uma estimativa da potência espectral nas frequências centrais, que correspondem às frequências utilizadas para estimulação visual. Como a PSD tende a ser mais intensa em torno da frequência evocada, ela permite distinguir a qual estímulo visual o indivíduo estava exposto. Deste modo, o sinal EEG de entrada pode ser compactamente representado pelos valores da PSD estimados em cada uma das saídas filtradas. Em geral, a técnica de extração de características por meio de banco de filtros considera somente a primeira harmônica da resposta SSVEP.

Para ilustrar a aplicação deste método de extração de características, considere o problema de discriminar dois estímulos visuais, um cintilante em 12 Hz e outro em 15 Hz. O esquema de filtragem, apresentado na Figura 3.4, consiste em dois filtros passa-bandas com respostas ao impulso dadas por  $H_1(j\omega)$  e  $H_2(j\omega)$ , o primeiro com banda de passagem centrada em torno de 12 Hz e o segundo com banda de passagem centrada em torno de 15 Hz. O sinal de EEG  $X(j\omega)$ , adquirido por um eletrodo posicionado em Oz enquanto o indivíduo era estimulado visualmente em 15 Hz, é submetido ao banco de filtros gerando dois sinais de saída  $X_1(j\omega)$  e  $X_2(j\omega)$ . Cada uma das saídas permite obter uma estimativa da PSD em torno das frequências 12 Hz e 15 Hz, respectivamente. Estes valores devem estar rotulados e podem ser empregados no treinamento de uma máquina de aprendizado supervisionada para, posteriormente, o sistema ser capaz de discriminar automaticamente as classes.

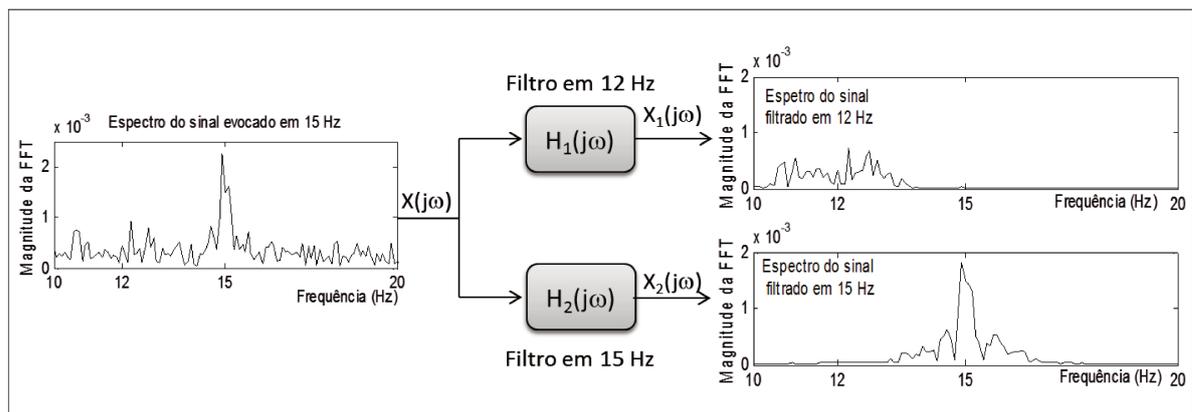


Figura 3.4 – Esquema de banco de filtros para extração de características nas frequências de 12 Hz e 15 Hz.

### 3.2.2 ESPECTROGRAMA

O espectrograma permite analisar a variação do espectro de frequências de um sinal ao longo do tempo. Sua definição matemática decorre do cálculo da transformada de Fourier de tempo curto (STFT, do inglês *Short-Time Fourier Transform*):

$$spectrogram \equiv |X(m, \omega)|^2 \quad (3.18)$$

sendo  $X(m, \omega)$  a STFT do sinal  $x(n)$  calculada em um segmento de comprimento  $m$  e  $\omega$  a frequência angular analisada.

A STFT permite estimar a potência espectral por meio do cálculo da transformada de Fourier sobre segmentos curtos do sinal (OPPENHEIM; SCHAFER; BUCK, 1999). Os valores complexos obtidos fornecem informações a respeito da magnitude e fase de cada ponto no tempo e na frequência, a função de transformação é dada por:

$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x(n)w(n-m)\exp(-j\omega n) \quad (3.19)$$

Trata-se de uma das formas mais clássicas de análise de sinais no domínio tempo-frequência. Entretanto, a relação inversa tempo-frequência demonstra que é impossível de se obter precisão ótima no domínio do tempo e da frequência concomitantemente. Quanto mais estreito for o janelamento temporal, maior será a precisão no domínio do tempo, porém menor a precisão na representação em frequência. Em contrapartida, uma janela maior proporciona uma representação mais precisa no domínio da frequência em detrimento da precisão temporal. Devido a esta limitação, a STFT deve ser empregada para análise de sinais cujo espectro varia lentamente com o tempo, ou seja, para sinais que sejam, ao menos, quase estacionários (KAY, 2006). A hipótese de estacionariedade é plenamente plausível quando se trata de resposta SSVEP, tornando a análise do espectrograma uma ferramenta adequada. Não obstante, para SSVEP, há interesse na avaliação do espectrograma em frequências pontuais, correspondentes à taxa de cintilação dos estímulos visuais. Neste caso, o algoritmo de Goertzel (GOERTZEL, 1958) torna-se uma maneira eficiente para a estimação do espectrograma (JACOBSEN; LYONS, 2003). Esta alternativa calcula uma única saída DFT (*Discrete Fourier Transform*) dentro da resolução espectral estabelecida para cada  $N$  amostras temporais. As frequências especificadas são arredondadas para o  $k$ -ésimo intervalo da DFT, considerando a resolução do sinal. A DFT é definida como sendo:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-i2\pi nk/N} \quad (3.20)$$

em que  $k$  é um número inteiro no intervalo  $0 \leq k \leq N - 1$ .

O algoritmo de Goertzel também pode ser visto como um filtro IIR de segunda ordem com a seguinte função de transferência no domínio- $z$  (BECK; DEMPSTER; KALE, 2001):

$$H_{Goertzel}(z) = \frac{1 - e^{-i2\pi k/N} z^{-1}}{1 - 2 \cos\left(\frac{2\pi k}{N}\right) z^{-1} + z^{-2}} \quad (3.21)$$

com os zeros posicionados em  $z = e^{-i2\pi k/N}$  e  $z = 0$  e os polos em  $z = e^{-i2\pi k/N}$  e  $z = e^{+i2\pi k/N}$ , sendo que o par de polos e zeros em  $z = e^{-i2\pi k/N}$  se cancelam. A Figura 3.5 ilustra o diagrama de polos e zeros, considerando  $N = 256$  e  $k = 20$ .

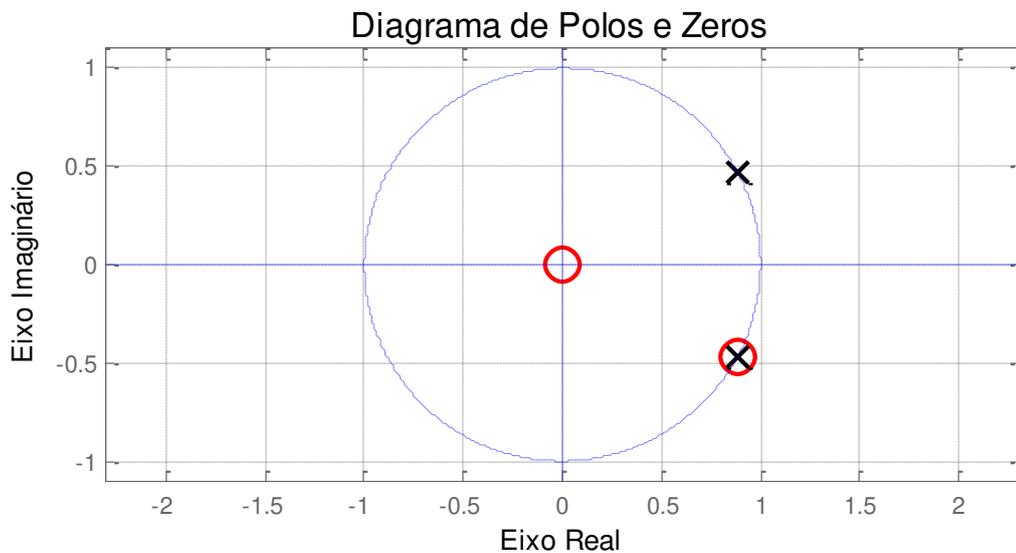


Figura 3.5 – Diagrama de polos e zeros do filtro de Goertzel.

A resposta em magnitude deste filtro é estreita e com ressonância centrada na frequência normalizada de  $2\pi k/N$ . A Figura 3.6 mostra a resposta em magnitude e fase do filtro de Goertzel considerando  $N = 256$  e  $k = 20$ .

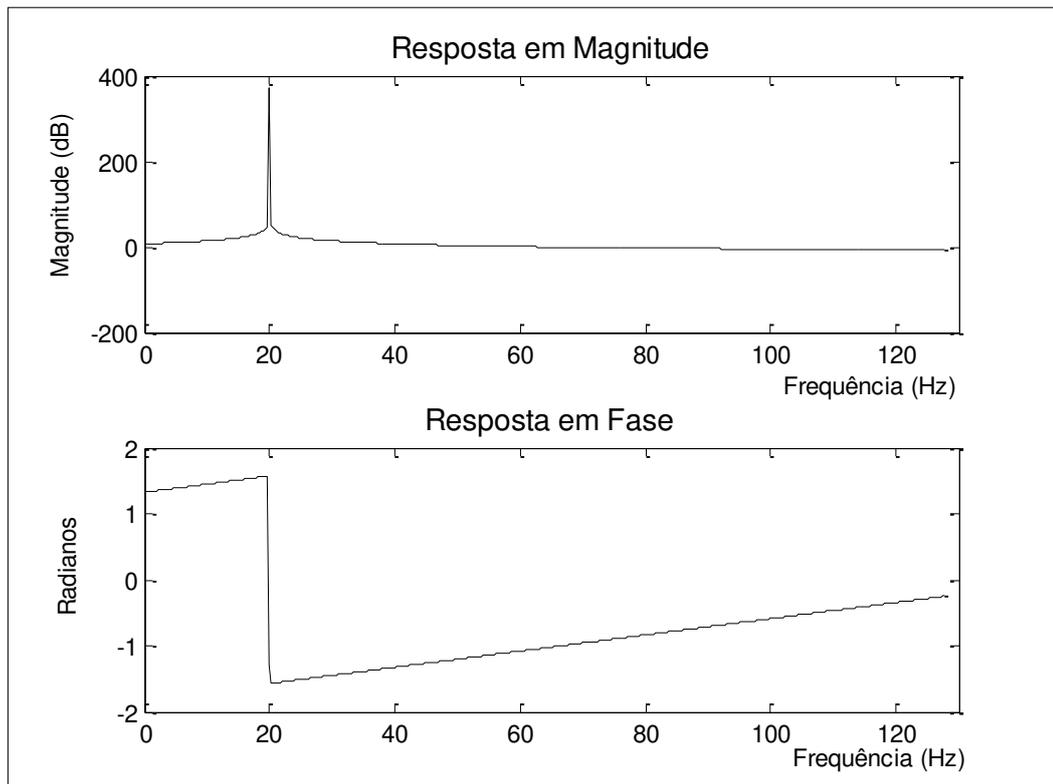


Figura 3.6 – Resposta em magnitude e fase do filtro de Goertzel.

É possível notar das Figuras 3.5 e 3.6 que o espectrograma permite caracterizar as componentes frequenciais de maneira pontual, fornecendo atributos que carregam informações relevantes na caracterização da frequência evocada de sinais SSVEP.

### 3.2.3 MÉTODO DE WELCH

Em 1967, Peter Welch propôs uma técnica para estimar a densidade espectral de potência de segmentos do sinal por meio de periodogramas (WELCH, 1967). O método de Welch se baseia no cálculo da média de periodogramas modificados e pode ser descrito por:

$$\hat{S}(\omega) = \frac{1}{KNU} \sum_{k=1}^K \left| \sum_{n=1}^N w(n)x(n+kD)\exp(-j\omega n) \right|^2 \quad (3.22)$$

sendo  $x(n)$  o vetor que contém o sinal de entrada amostrado. Este sinal é dividido em  $K$  segmentos de comprimento  $N$  cada um, com sobreposição de  $D$  amostras. Devido à segmentação do sinal  $x(n)$  ser realizada utilizando um tamanho fixo, os dados à direita do vetor de entradas, que não podem ser incluídos no  $k$ -ésimo segmento, são descartados. O valor

da sobreposição pode ser ajustado para evitar que muitos dados sejam perdidos, entretanto, foi comprovado que a taxa de sobreposição que oferece melhor compromisso entre estabilidade e resolução para segmentação de tamanho fixo é 50% (NUTTALL; CARTER, 1980). A função de janelamento  $w(n)$  deve ter o mesmo comprimento do segmento do sinal a ser analisado. Podem ser empregadas diversas funções janelantes, como retangular, Hanning, Hamming, Blackman e Bartlett (OPPENHEIM; SCHAFER; BUCK, 1999). Neste trabalho, empregou-se o janelamento de Hamming, descrito por:

$$w(n) = 0,54 - 0,46 \cos\left(\frac{2\pi n}{N}\right), \quad 0 \leq n \leq N \quad (3.23)$$

A Figura 3.7 apresenta a função janela de Hamming no domínio do tempo e da frequência, considerando  $N = 256$ .

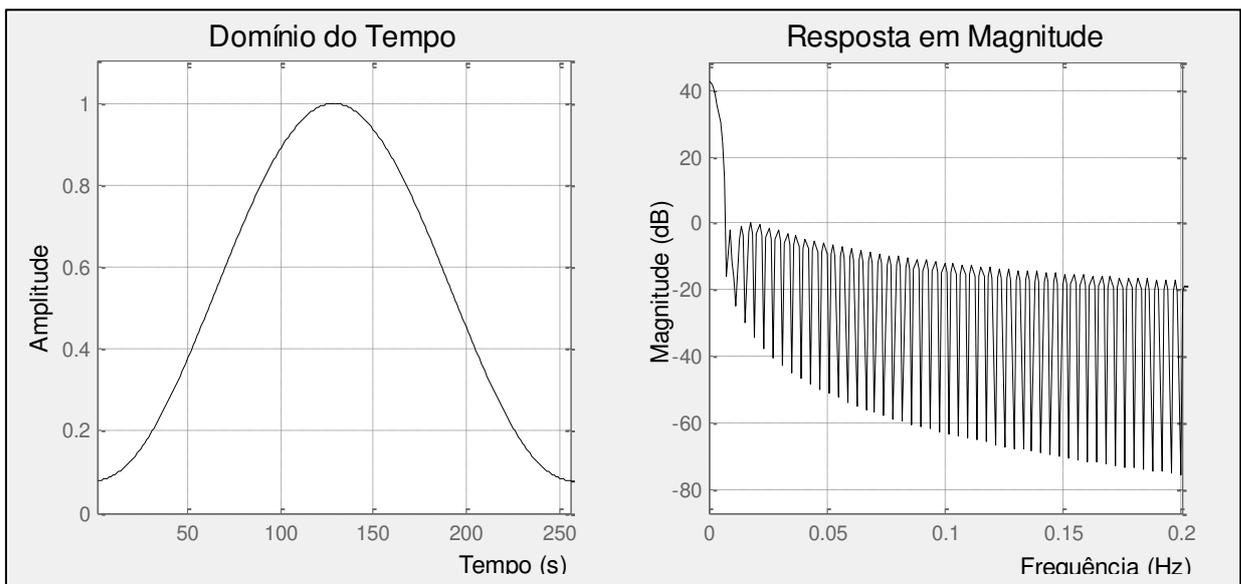


Figura 3.7 – Função temporal e resposta em magnitude da janela de Hamming.

A constante de normalização  $U$ , na expressão (3.22), é inserida de modo a remover ou atenuar o viés do janelamento na estimação do espectro. Para janelas retangulares,  $U$  assume o valor 1, enquanto que para outros janelamentos, a constante pode assumir valores entre  $0 < U < 1$ , considerando que  $w(n)$  está normalizado para um valor máximo de 1. De maneira geral, o valor de  $U$  pode ser determinado por:

$$U = \frac{1}{N} \sum_{n=1}^N |w(n)|^2 \quad (3.24)$$

Para ilustrar como a extração de características de sinais EEG pode ser operada pelo método de Welch, considere um caso em que se deseja discriminar dois estímulos visuais, um cintilante em 12 Hz e outro em 15 Hz. Aplicando o períodograma modificado de Welch em cada sinal em torno dessas duas faixas de frequência, é possível verificar a distribuição de potência espectral. Conforme mostra a Figura 3.8(a), a resposta SSVEP corresponde a um aumento da potência espectral em torno das frequências evocadas em 12 Hz (azul) e em 15 Hz (vermelho). Se considerarmos um único canal, no caso O<sub>2</sub>, cada segmento do sinal fornece um par (x,y) de características normalizadas, sendo:

$$x = \frac{PSD_{12Hz}}{PSD_{12Hz} + PSD_{15Hz}} \quad (3.25)$$

$$y = \frac{PSD_{15Hz}}{PSD_{12Hz} + PSD_{15Hz}}$$

A Figura 3.8(b) apresenta o espaço das características espectrais extraídas da resposta SSVEP observada no canal O<sub>2</sub>. É possível notar que os atributos extraídos pelo método de Welch possibilitam uma razoável discriminação entre as classes de frequências evocadas.

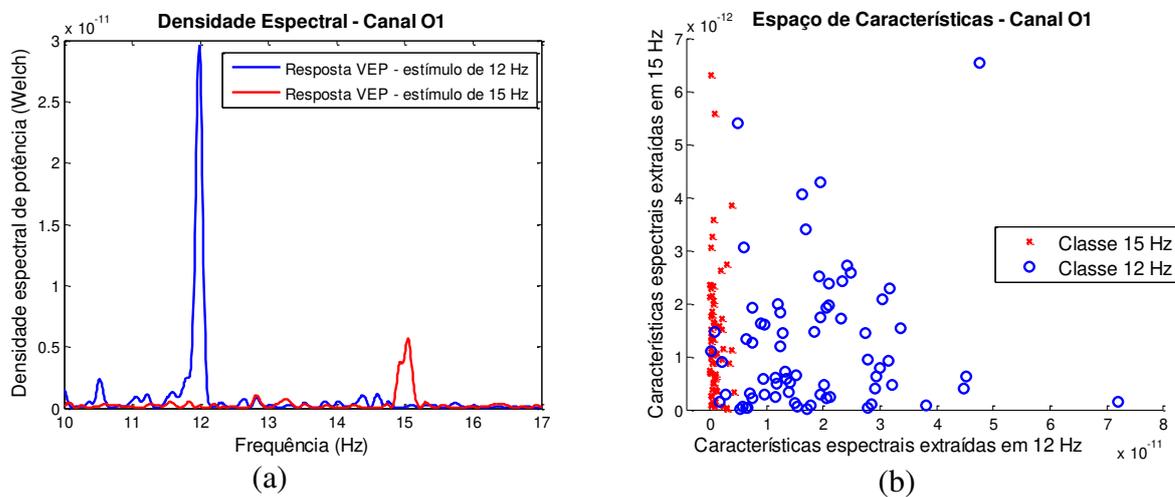


Figura 3.8 – Extração de características da resposta SSVEP em 12 e 15 Hz, (a) densidade espectral de potência, (b) espaço de características considerando somente um canal.

### 3.2.4 COEFICIENTES DO MODELO AUTORREGRESSIVO – MÉTODO DE BURG

Outra possibilidade interessante de extração de características de sinais SSVEP é por meio da construção de modelos autorregressivos (AR). Os modelos AR são largamente utilizados para desenvolver sistemas variados que exigem monitoramento do sinal, detecção

de defeitos ou diagnóstico. No que tange a sinais EEG, relatos na literatura mostram que modelos AR são empregados com sucesso em variadas aplicações, tais como para o monitoramento do sinal cerebral durante neurocirurgias (CERUTTI, LIBERATI, MASCELLANI, 1985), análise dos sinais EEG durante crises epiléticas (GATH et al., 1992), quantificação de lesões cerebrais (GOEL et al., 1996), entre outros (SENHADJI; BELLANGER; CARRAULT, 1997), (MUTHUSWAMY; THAKOR, 1998).

Os modelos AR permitem determinar os parâmetros ótimos por meio de uma expressão bem definida atuando diretamente sobre o sinal EEG no domínio temporal (HAYKIN, 2008). Para um modelo de ordem  $p$ , a saída atual  $y(n)$  é uma combinação linear das  $p$  saídas anteriores acrescidos de um termo de erro de predição  $e(n)$ , sendo:

$$y(n) = \sum_{k=1}^p a(k)y(n-k) + e(n) \quad (3.26)$$

em que  $a(k)$  é o  $k$ -ésimo coeficiente do modelo AR.

As etapas necessárias para se estimar o espectro utilizando modelos AR envolvem:

**1. Determinar a ordem ótima do modelo:** A escolha do número de parâmetros  $p$ , que deve ser usado para descrever o sinal é um ponto crucial. Ordens muito baixas tendem a suavizar o espectro real, enquanto que ordens muito altas tendem a introduzir picos espúrios no espectro de potência. Não há uma maneira direta de se determinar a ordem ótima. Estratégias possíveis incluem o modelo do valor eficaz (RMS, do inglês *Root Mean Square*) (PHINYOMARK; LIMSAKUL; PHUKPATTARANONT, 2009), o Critério de Informação de Akaike (AIC, do inglês *Akaike Information Criterion*) (AKAIKE, 1974) e ou o canônico esquema de validação cruzada (BISHOP, 2006).

**2. Estimar os parâmetros AR:** Existem diversas estratégias de estimação dos coeficientes AR; as duas principais são o método de Yule-Walker e o método de Burg (JANSEN; BOURNE; WARD, 1981).

O método de Yule Walker determina os coeficientes autorregressivos por meio da solução do sistema de equações linear:

$$\begin{bmatrix} R_1 \\ R_2 \\ \vdots \\ R_p \end{bmatrix} = \begin{bmatrix} R_0 & R_1 & \dots & R_{p-1} \\ R_1 & R_0 & \dots & R_{p-2} \\ & \vdots & \ddots & \vdots \\ R_{p-1} & R_{p-2} & \dots & R_0 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} \quad (3.27)$$

sendo  $R$  a matriz de elementos constituída das estimativas da função de autocovariância:

$$R_i = \frac{1}{N} \sum_{n=i+1}^N y[n]y[n-i] \quad (3.28)$$

O algoritmo recursivo de Levinson-Durbin permite determinar rapidamente a solução deste sistema de equações (PHAM; LE BRETON, 1991).

Já o método de Burg estima os parâmetros AR por meio de mínimos quadrados. Os coeficientes de Burg  $b_p(n)$  são calculados pela expressão:

$$b_p(n) = \sum_{k=0}^p a_p^*(k)y(n-p+k) \quad (3.29)$$

para  $p < n < N - 1$ , onde  $a_p^*(k)$  é o complexo conjugado de  $a_p(k)$ , sendo  $a_p(0) = a_p^*(0) = 1$ . O algoritmo de Burg pode ser resumido como apresentado no Quadro 3.1 (MUTHUSWAMY; THAKOR, 1998):

**Quadro 3.1 – Algoritmo de determinação dos coeficientes AR pelo método de Burg.**

1. Inicialização: Determine a autocorrelação de  $\mathbf{y}(\mathbf{n})$  para um atraso nulo, dado por:

$$E_0 = \frac{1}{N} \sum_{k=1}^N |y(k)|^2$$

e para um atraso unitário:

$$E_1 = \frac{1}{N} \sum_{n=0}^{N-2} y(n)y(n+1)$$

2. Inicialize os parâmetros  $\mathbf{a}_{11} = -\frac{E_1}{E_0}$  e  $\sigma_1^2 = (1 - |\mathbf{a}_{11}|^2)E_0$

3. Nas iterações sucessivas, para  $i = 2, 3, \dots, p$ . Faça:

3.1. Determine o parâmetro  $\mathbf{a}_{ii}$  dado por:

$$\mathbf{a}_{ii} = \frac{-2 \sum_{k=1}^{n-1} \mathbf{b}_{i-1,k-1}^* \mathbf{e}_{i-1,k}}{\sum_{k=1}^{N-1} (|\mathbf{b}_{i-1,k-1}|^2 + |\mathbf{e}_{i-1,k}|^2)}$$

com  $\mathbf{b}$  dado por (3.29) e  $\mathbf{e}_{i-1,k}(\mathbf{n}) = \sum_{k=0}^{i-1} \mathbf{a}_{i-1}(\mathbf{k})x(\mathbf{n} - \mathbf{k})$ .

3.2. Encontre os outros parâmetros AR para a ordem  $p = i$  por meio das equações de recursão de Levinson:

$$\mathbf{a}_{ki} = \mathbf{a}_{k-1,j} + \mathbf{a}_{kk} \mathbf{a}_{k-1,k-1}^*$$

$$\sigma_k^2 = (1 - |\mathbf{a}_{kk}|^2) \sigma_{k-1}^2$$

com  $k = 2, 3, \dots, i$ .

3.3. Após a estimação dos parâmetros AR para a ordem em questão, os erros de predição linear direto e inverso podem ser atualizados, retorna-se ao passo (2) até que a ordem do modelo correto seja alcançada.

---

O método de Burg assume que a sequência de dados é estacionária no sentido amplo, hipótese plausível para sinais cerebrais coletados no paradigma SSVEP. O algoritmo é capaz de garantir precisão estatística para sinais que seguem a distribuição Gaussiana de média de zero e é capaz de realizar uma boa aproximação para sinais com distribuição diferente. Além de ser computacionalmente rápido, o método de Burg garante estabilidade,

robustez e precisão para registros de dados curtos sendo, portanto, preferido ao método de Yule-Walker (BELL; PERCIVAL, 1991) e (DE HOON et al., 1996).

**3. Estimar a densidade espectral de potência utilizando os parâmetros AR:** Uma vez encontrados os coeficientes autorregressivos, a potência espectral da sequência de dados pode ser estimada da seguinte maneira, considerando a abordagem do método de Burg:

$$P_{AR}(f) = \frac{\sigma_p^2 T_s}{|1 + \sum_{k=0}^p a_p(k) \exp(-i2\pi f k T_s)|^2} \quad (3.30)$$

em que  $\sigma_p^2$  é a predição direta da energia do erro na frequência  $f$  para um modelo de ordem  $p$ , considerando que o sinal apresenta um período de amostragem dado por  $T_s$ .

Neste trabalho, os coeficientes autorregressivos foram diretamente empregados como atributos do modelo, não sendo executado o passo 3.

### 3.3 SELEÇÃO DE CARACTERÍSTICAS

Em problemas de aprendizado de máquina, é comum se ter um número elevado de variáveis para descrever determinado conjunto de dados. A etapa de seleção de características visa determinar as características mais informativas a serem usadas para se conceber o sistema de classificação. O seletor de atributos é delineado por três objetivos: melhorar o desempenho do classificador, proporcionar preditores mais rápidos e mais eficazes e permitir uma melhor compreensão do processo que gerou os dados (BISHOP, 1995) e (GUYON; ELISSEEFF, 2003). Vários benefícios podem ser alcançados quando se realiza uma boa seleção de características, como simplificar o modelo para uma melhor compreensão do problema, proporcionar uma melhor definição da função objetivo, facilitar a visualização e entendimento dos dados, reduzir o tempo de treinamento do classificador, reduzir o tamanho da memória necessária para o armazenamento de dados, evitar a maldição de dimensionalidade melhorando o desempenho do preditor, aprimorar a generalização do modelo reduzindo *overfitting*, entre outros (BISHOP, 1995).

Em um primeiro momento, poder-se-ia pensar em uma abordagem de seleção exaustiva das características, testando-se todos os possíveis subconjuntos para encontrar aquele que minimiza a taxa de erro do classificador. Entretanto, esta abordagem é computacionalmente intratável para a maioria dos problemas, devido ao elevado número de

combinações a serem testadas. Pode-se dizer que existem duas grandes estratégias de seleção de atributos empregadas na prática: filtros e *wrappers* (KOHAVI; JOHN, 1997) e (GUYON; ELISSEEFF, 2003). Nas Subseções 3.3.1 e 3.3.2 estas estratégias são descritas, juntamente com duas técnicas de aplicação de filtros – Coeficientes de Correlação de Pearson e Índice de Davies-Bouldin –, e uma técnica de aplicação de *wrappers* conhecida como *forward wrapper* ou *wrapper* incremental.

### 3.3.1 FILTROS

A ideia de um filtro é encontrar e ranquear todas as características potencialmente relevantes usando métricas extraídas do próprio conjunto de dados, sem receber o *feedback* do classificador que irá empregar este conjunto de características. O seletor de características nada mais é do que uma função que indica a relevância de um dado subconjunto de características no universo do inteiro conjunto de dados para realizar uma determinada tarefa, no caso para discriminar entre as diferentes classes (FORMAN, 2003).

Há vários indicadores estatísticos que podem ser considerados para nortear o ranqueamento dos atributos, como informação mútua, coeficiente de correlação de Pearson, distância interclasses e intraclasses, significância estatística para combinações de classes e características, entropia e distância probabilística.

Filtros formam, provavelmente, o método mais simples de se operar no espaço de características, uma vez que a atuação é independente do classificador, evidenciando somente as relações entre as características. Esta técnica permite uma seleção mais rápida e computacionalmente menos custosa que *wrappers*. Não obstante, proporciona uma solução subótima na construção do preditor, principalmente se há variáveis redundantes. Geralmente, o resultado da seleção por filtros não é um subconjunto das melhores características, e sim o ranqueamento das características mais informativas. O ponto de corte, ou seja, o número de atributos a serem empregados, pode ser determinado por validação cruzada.

### 3.3.1.1 COEFICIENTE DE CORRELAÇÃO DE PEARSON

Coefficientes de correlação são uma das formas mais frequentes de se medir a relevância de um subconjunto de características. O coeficiente de correlação de Pearson (BISHOP, 2006) e (THEODORIDIS; KOUTROUMBAS, 2010) define um tipo de estratégia de filtro no qual o vetor de entrada de características  $x_i$  é associado com as classes  $y$  da seguinte forma:

$$R_i = \frac{cov(x_i, y)}{\sqrt{var(x_i)var(y)}} \quad (3.31)$$

sendo  $cov(.)$  a covariância e  $var(.)$  a variância. A correlação  $R_i$  é igual a  $\pm 1$  se a  $i$ -ésima característica é linearmente dependente das classes e 0 se elas forem completamente descorrelacionadas. Esta estratégia primeiramente avalia a correlação  $R_i$  para  $i = 1, \dots, M$ , sendo  $M$  o número de atributos e, posteriormente, ranqueia as características utilizando o critério de maximizar os valores de  $R_i$ . Como a correlação é uma medida estatística de segunda ordem, este coeficiente é capaz de capturar somente a dependência linear entre os atributos. No entanto, devido à sua simplicidade computacional, ele pode ser utilizado como uma métrica inicial para compreender o espaço de características.

### 3.3.1.2 ÍNDICE DE DAVIES-BOULDIN

O índice de Davies-Bouldin (DB) é uma medida de clusterização que tenta quantificar a separabilidade de diferentes classes, considerando dois dos principais aspectos relevantes da clusterização de dados: a minimização da distância dentro de uma classe e a maximização da distância entre as classes (DAVIES; BOULDIN, 1979).

Sejam  $s_i$  a distância média entre cada ponto da classe  $i$  e o centroide da classe correspondente, e  $s_j$  a dispersão do mesmo vetor, mas agora em torno da média da classe  $j$ . Seja ainda,  $d_{ij}$  uma medida de dissimilaridade simétrica entre duas classes, por exemplo, a distância Euclidiana entre os centroides das classes  $i$  e  $j$ . Pode-se definir uma medida de separação entre dois *clusters*  $C_i$  e  $C_j$  como:

$$DB_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (3.32)$$

Este indicador de similaridade apresenta as seguintes propriedades (DAVIES; BOULDIN, 1979):

- a) É não negativo:  $DB_{ij} \geq 0$ ;
- b) É simétrico:  $DB_{ij} = DB_{ji}$ ;
- c) Quando ambos os *clusters* colapsam em um único ponto, a similaridade é nula, ou seja, se  $s_i = 0$  e  $s_j = 0$ , então  $DB_{ij} = 0$ ;
- d) Um *cluster*  $C_i$  que dista igualmente dos *clusters*  $C_j$  e  $C_k$  é mais similar ao cluster com maior dispersão, ou seja, se  $s_j > s_k$  e  $d_{ij} = d_{ik}$ , então  $DB_{ij} > DB_{ik}$ ;
- e) Se dois *clusters*  $C_j$  e  $C_k$  são igualmente dispersos, mas possuem diferentes distâncias entre-classes, o cluster  $C_i$  será mais similar ao que apresentar menor distância, ou seja, se  $s_j = s_k$  e  $d_{ij} < d_{ik}$ , então  $DB_{ij} > DB_{ik}$ .

Se considerarmos  $K$  classes, o índice DB pode ser descrito pela razão:

$$DB = \frac{1}{K} \sum_{i=1}^K \left( \max_{j=1, \dots, K, j \neq i} \frac{s_i + s_j}{d_{ij}} \right) \quad (3.33)$$

Valores grandes de DB representam clusters espalhados e com centroides pouco distantes, enquanto valores pequenos indicam clusters com classes pouco dispersas e com centroides distantes, facilitando a tarefa de separação de classes.

O inverso deste índice (DBinv) pode ser utilizado para ranquear as melhores características. Neste sentido, a heurística de seleção de características deve procurar por atributos com alto índices DBinv, uma vez que estes se referem a classes com centroides distantes e pouco dispersos e, portanto, promissores para serem usados para discriminação entre as classes (DAVIES; BOULDIN, 1979).

A Figura 3.9 ilustra qualitativamente um problema com duas classes,  $C_1$  e  $C_2$ . Os atributos das classes do primeiro quadro (esquerda) são menos dispersos que os atributos das classes do segundo quadro (direita) e os centroides das classes  $C_1$  e  $C_2$  são mais distantes no primeiro quadro do que no segundo. Desta maneira, pode-se dizer que, segundo os critérios de

Davies-Bouldin, os atributos do primeiro quadro são mais facilmente separáveis que os atributos do segundo quadro.

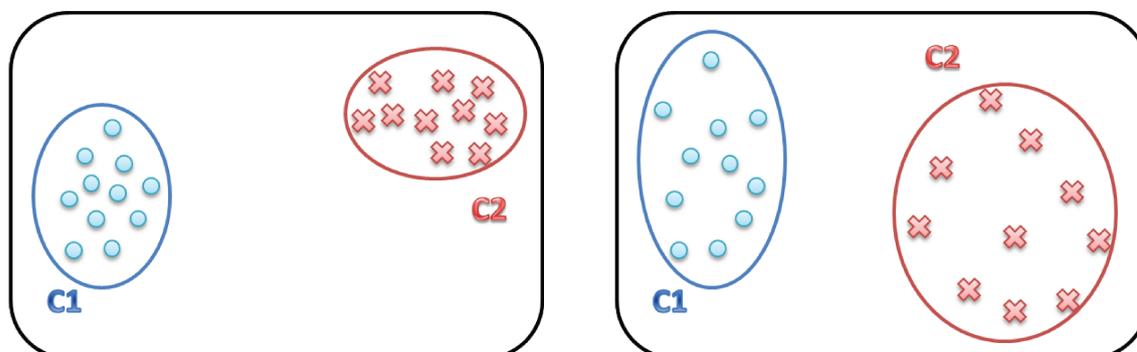


Figura 3.9 – Exemplo do índice de Davies Bouldin para atributos de duas classes.

### 3.3.2 WRAPPERS

O objetivo dos *wrappers* é selecionar um subconjunto de características que forneçam informações úteis para a discriminação das classes pelo classificador. Cada subconjunto é usado para treinar um modelo, que posteriormente é testado com amostras não utilizadas no treinamento. A taxa de erro do classificador serve para ranquear os melhores subconjuntos de características. O algoritmo de busca de subconjuntos, no espaço de todas as possíveis características, e a avaliação de cada combinação faz com que um *wrapper* seja, certamente, um seletor de características computacionalmente mais custoso e mais lento que um filtro. Entretanto, a seleção por *wrappers* tende a garantir um melhor desempenho do sistema de classificação, apesar de não haver garantia de convergência para o ótimo global.

Três aspectos definem a implementação do seletor *wrapper* (KOHAVI; JOHN, 1997):

- i) Estratégia de busca: esta etapa consiste na realização de uma busca eficiente no espaço de características, que é da ordem de  $2^M - 1$ , sendo  $M$  o número de características. Existem muitas opções para realizar a busca como, algoritmos genéticos, arrefecimento simulado (*simulated annealing*) ou heurística gulosa (BLUM; LANGLEY, 1997). Neste estudo, foi adotada uma heurística gulosa com base na seleção incremental; na abordagem, supõe-se que os atributos são mais bem correlacionados por uma incorporação progressiva.
- ii) O critério de parada varia de acordo com o algoritmo adotado. Possíveis abordagens são: (a) se atingir a taxa de acerto estipulada para determinado

subconjunto; (b) se o tempo de busca exceder um limite máximo; (c) heurística gulosa incremental: se a inclusão de uma nova característica não agregar melhoria. Esta última abordagem pode, no entanto, levar a um máximo local. Um critério um pouco mais robusto considera a não melhoria do desempenho do classificador após a incorporação de  $k$  novas características.

- iii) A estrutura do classificador exerce uma forte influência na seleção de características por meio de *wrappers*, uma vez que seu desempenho é avaliado constantemente e consiste no *feedback* utilizado para se obter o melhor subconjunto de atributos. Praticamente todas as estruturas de classificação permitem que se trabalhe com *wrappers*.

O Quadro 3.2 descreve as etapas do algoritmo de seleção por um *wrapper* incremental.

**Quadro 3.2 – Algoritmo de seleção de atributos *forward wrapper***

Considere  $k$  como sendo a variável que indica o número de iterações em que não houve melhoria no desempenho do sistema. Considere ainda três conjuntos:  $T$  que contém todas as  $M$  características,  $S$  que contém as características selecionadas e  $O$  que contém as características que estão em análise.

Inicialmente,  $k = 0$ ,  $T = \{1, 2, \dots, M\}$ ,  $S = \emptyset$  e  $O = \emptyset$ .

1. O primeiro passo consiste em avaliar o desempenho do classificador, por validação cruzada, para cada uma das características que pertencem ao conjunto  $T$ . Ao final da análise coloque em  $S$  a que apresentou o melhor desempenho e remova-a de  $T$ .
2. Em seguida, considere todos os recursos presentes nos conjuntos  $S$  e  $O$  e teste o desempenho do classificador por validação cruzada, com a inclusão, uma a uma, das características pertencentes a  $T$ .
3. Se o desempenho do classificador aumentar, insira o atributo que forneceu o melhor desempenho em  $S$  e remova-o de  $T$ .
  - 3.1. Se  $k = 1$ , coloque os elementos de  $O$  em  $S$ , faça  $O = \emptyset$  e  $k = 0$ .
  - 3.2. Se  $T$  não é o conjunto nulo, retorne para o passo (2). Caso contrário, finalize.
4. Se o desempenho do classificador diminuiu e  $k = 0$ , coloque em  $O$  a nova característica, para a qual o classificador apresentou o melhor desempenho, remova-a de  $T$  e faça  $k = 1$ .
  - 4.1. Se  $T$  não é o conjunto nulo, retorne para o passo (2). Caso contrário, finalize.
5. Se não houve melhora no desempenho do classificador e  $k = 1$ , ocorreu um segundo decréscimo consecutivo no desempenho, então finalize.

Ao final da iteração, o conjunto  $S$  conterà as características selecionadas.

---

### 3.4 CLASSIFICAÇÃO

A tarefa de classificação pode ser vista como uma função que mapeia os dados de entrada nas possíveis classes considerando a similaridade entre os objetos. Para se construir a função de mapeamento, geralmente se utiliza um conjunto de características extraídas da base de dados. Essas características devem ser tais que permitam que cada padrão corresponda de maneira unívoca a uma determinada classe ou conjunto de classes. Na maioria dos casos, as classes são consideradas disjuntas, de modo que cada dado de entrada corresponde a uma única classe. O espaço de entradas é dividido em regiões de decisão, cujos limites são denominados de fronteiras ou superfícies de decisão. Os classificadores podem ser lineares ou não lineares, dependendo da natureza do mapeamento realizado. Quando as regiões de decisão são definidas por hiperplanos, diz-se que as classes são linearmente separáveis. Caso contrário, trata-se de um problema de classificação não linear.

Geralmente, em problemas de classificação, a variável dependente é discreta. Assim, uma vez que se tenha um vetor de características de dimensão  $k$ , o objetivo é projetar um classificador tal como uma superfície de decisão em  $R^k$ , de modo que, dado os valores do vetor de características, seja possível determinar o padrão ou classe correspondente.

Um sistema de classificação supervisionado é composto por três etapas: treinamento, validação e classificação. Na etapa de treinamento, são determinadas as fronteiras de decisão, por meio das associações entre os padrões dos dados de entradas e as classes correspondentes. Existem duas abordagens para realizar a etapa de validação: autovalidação ou validação cruzada. A primeira mede a taxa de desempenho do classificador empregando dados já utilizados durante o treinamento. Esta abordagem fornece uma estimativa superestimada do desempenho do sistema e não permite mensurar a capacidade de generalização do classificador. A segunda técnica, validação cruzada, submete dados não empregados na etapa de treinamento para verificar o desempenho do sistema. Dessa forma, obtém-se um panorama do desempenho do sistema mais fiel à realidade. A validação cruzada também fornece um indicativo da capacidade de generalização do classificador e permite ajustar eventuais parâmetros do sistema. Na última etapa do sistema de classificação, opera-se a classificação em si, associando dados de entrada desconhecidos a uma classe, de acordo com o modelo de associação gerado.

No contexto deste trabalho, os dados de entrada do sistema de classificação são os

atributos extraídos do sinal cerebral e as classes são os possíveis comandos dado pelo usuário do sistema BCI que estão associados aos diferentes estímulos visuais. O desempenho do classificador é determinado pela taxa de acerto entre o comando identificado, a partir das características extraídas do sinal EEG, e o comando realmente desejado pelo usuário do sistema. Os sistemas BCI podem ser concebidos empregando tanto classificadores lineares, tais como o discriminante de Fisher (FISHER, 1936) e a função discriminante de mínimos quadrados, quanto não lineares, como redes neurais (BISHOP, 1995) e *Support Vector Machines* (SVM) (BURGES, 1998). Cada uma destas estruturas de classificação é discutida nas Subseções seguintes.

### 3.4.1 FUNÇÃO DISCRIMINANTE LINEAR

Uma função discriminante pode ser vista como uma combinação linear do tipo:

$$g(x) = \mathbf{w}^T \mathbf{x} + w_0 \quad (3.34)$$

onde  $\mathbf{w}$  é o vetor de pesos e  $w_0$  é o bias. Esta função discriminante determina a seguinte regra de decisão para duas classes  $C_1$  e  $C_2$ :

$$\begin{cases} \mathbf{w}^T \mathbf{x} > w_0 & \Rightarrow \mathbf{x} \in C_1 \\ \mathbf{w}^T \mathbf{x} < w_0 & \Rightarrow \mathbf{x} \in C_2 \end{cases} \quad (3.35)$$

Note que a orientação do hiperplano  $g(x)$  é definida pela norma do vetor de pesos  $\mathbf{w}$ .

A Figura 3.10 ilustra um caso de separação dos atributos de duas classes por um hiperplano de separação  $g(x)$ .

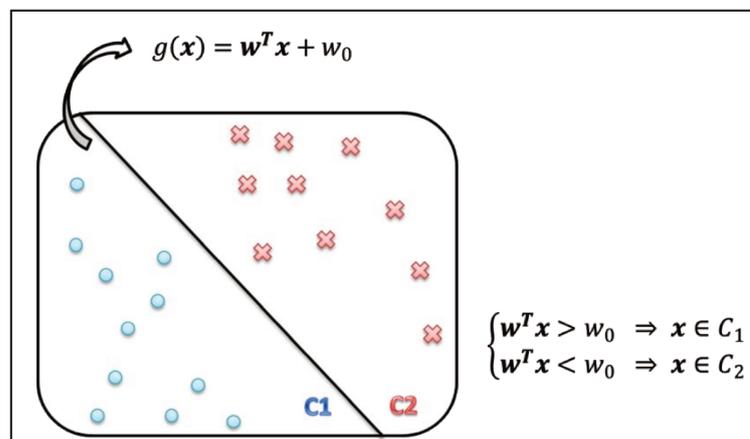


Figura 3.10 – Hiperplano de classificação de duas classes.

Para o caso de  $N$  classes, pode-se definir a função discriminante linear de forma mais genérica, como:

$$g(\mathbf{x}) = \sum_{i=0}^N \mathbf{w}_i \mathbf{x}_i \quad (3.36)$$

com  $x_0 = 1$ , de modo que  $w_0$  represente o valor de *offset* do hiperplano.

Existem diversos critérios para se determinar o vetor de pesos e, com isso, a direção da superfície de separação. Neste trabalho, são empregadas duas técnicas: mínimos quadrados e discriminante de Fisher. A técnica dos mínimos quadrados leva a um hiperplano capaz de separar de maneira ótima os dados do conjunto de treinamento. Já a abordagem de Fisher visa separar maximamente as classes no espaço de saída. Apesar de as funções objetivo serem distintas, é possível mostrar que, para um problema de duas classes, o critério de Fisher emerge como um caso especial da técnica de mínimos quadrados (DUDA; HART; STORK, 2012).

### 3.4.1.1 MÍNIMOS QUADRADOS

O método dos mínimos quadrados (MSE, do inglês *Minimum Squared-Error*) é frequentemente utilizado em problema de regressão e classificação. Neste trabalho, o MSE foi empregado em dois contextos de classificação: função discriminante linear e máquina de aprendizado extremo (ELM, do inglês *Extreme Learning Machine*). No primeiro caso, o MSE define um hiperplano de separação entre as classes. No segundo, o MSE foi empregado para designar os pesos da camada de saída da rede neural. Para maior clareza na exposição, esta seção apresenta a técnica de mínimos quadrados focada na construção do classificador linear; a Seção 3.4.3 discute com maior especificidade a técnica aplicada à rede ELM.

No caso linear, retomando a equação (3.34), tem-se que:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$$

A associação entre os dados de entrada  $\mathbf{x}$  e o valor de saída do classificador  $g(\mathbf{x})$  é determinada pelo vetor de pesos  $\mathbf{w}$ , o qual fornece a direção do hiperplano separador. De modo mais específico, os atributos extraídos dos dados, que formam o conjunto de entradas  $\mathbf{x}$ , definem a matriz de atributos  $\mathbf{H}$ , e estão associados ao vetor de rótulos  $\mathbf{d}$ , identificando os

dados do conjunto de treinamento com as respectivas classes. De modo que se pode escrever:

$$\mathbf{d} = \mathbf{w}^T \mathbf{H} \quad (3.37)$$

O critério da técnica dos mínimos quadrados permite determinar o vetor de pesos  $\mathbf{w}$  que define o “melhor hiperplano” capaz de separar as classes, realizando a minimização do erro de classificação do conjunto de treinamento. Têm-se o seguinte problema de otimização:

$$\min_{\mathbf{w}} \|\mathbf{H}\mathbf{w} - \mathbf{d}\|^2 \quad (3.38)$$

cuja solução pode ser encontrada utilizando o cálculo da matriz pseudo-inversa de Moore-Penrose (THEODORIDIS; KOUTROUMBAS, 2010). Se a base de dados de treinamento possui  $N$  amostras, as quais se associam a uma das  $m$  classes possíveis, e o vetor de atributos  $\mathbf{H}$  é constituído por  $k$  características pode-se considerar três casos:

1. O caso mais frequente em problemas de classificação ocorre quando o modelo tem um número de graus de liberdade inferior ao número de pontos disponíveis, sendo  $N > k$ ; nesta situação, a solução do hiperplano de separação das classes pode ser encontrada por:

$$\mathbf{w} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{d} \quad (3.39)$$

já que a matriz  $\mathbf{H}^T \mathbf{H}$  é não singular.

2. Quando  $k > N$ , o problema é mal condicionado e apresenta várias soluções possíveis. Como a matriz  $\mathbf{H} \mathbf{H}^T$  é não singular, o vetor de pesos pode ser determinado por:

$$\mathbf{w} = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T)^{-1} \mathbf{d} \quad (3.40)$$

3. Quando  $k = N$ , têm-se exatamente uma entrada na matriz de atributos para amostra. Nesse caso as duas soluções acima se tornam equivalentes, pois a matriz de atributos  $\mathbf{H}$  passa a ser quadrada e, portanto, a matriz pseudo-inversa de Moore-Penrose coincide com a matriz inversa convencional, de modo que:

$$\mathbf{w} = \mathbf{H}^{-1} \mathbf{d} \quad (3.41)$$

### 3.4.1.2 DISCRIMINANTE DE FISHER

Uma alternativa ao método dos mínimos quadrados é a técnica do discriminante de Fisher, proposta pelo professor Ronald Fisher em 1936 quando tentava solucionar o problema de classificação de flores (FISHER, 1936). O discriminante de Fisher também é conhecido como Análise do Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*), sendo que, no LDA, assume-se distribuição Gaussiana multivariada para as funções densidade de probabilidade condicional que descrevem a probabilidade dos valores de entrada dadas as classes, e considera-se ainda, que as covariâncias das classes são idênticas.

A ideia do discriminante de Fisher é projetar todos os pontos de dados em um novo espaço, normalmente de dimensão menor, de modo a maximizar a distância entre classes diferentes e minimizar a variância intraclasse, permitindo, desta maneira, determinar uma combinação linear  $\mathbf{w}$  que melhor separe as classes.

Retomando a expressão (3.34) da função discriminante linear:

$$y = \mathbf{w}^T \mathbf{x}$$

e considerando o caso de duas classes  $C_1$  e  $C_2$ , com  $N_1$  e  $N_2$  amostras, respectivamente, os critérios para se obter o vetor de pesos  $\mathbf{w}$  ótimo, segundo Fisher, pode ser descrito pela seguinte função objetivo:

$$\max_{\mathbf{w}} \frac{|\mathbf{w}^T (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)|^2}{\sigma_1^2 + \sigma_2^2} \quad (3.42)$$

sendo  $\boldsymbol{\mu}_1$  e  $\boldsymbol{\mu}_2$  o valor da média amostral de cada classe, dada por:

$$\boldsymbol{\mu}_i = \frac{1}{N_i} \sum_{n \in C_i} \mathbf{x} \quad (3.43)$$

e  $\sigma_1^2$  e  $\sigma_2^2$  o valor das variâncias intraclasses, calculadas como:

$$\sigma_i^2 = \sum_{y \in C_i} (y - \mathbf{w}^T \boldsymbol{\mu}_i)^2 \quad (3.44)$$

O problema de otimização definido por (3.42), pode ser reescrito explicitando a dependência de  $\mathbf{w}$ , como:

$$\max_w \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (3.45)$$

sendo  $\mathbf{S}_B$  a matriz de covariância entre classes, dada por:

$$\mathbf{S}_B = (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)(\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)^T \quad (3.46)$$

e  $\mathbf{S}_W$  a matriz de covariância intraclasses, dada por:

$$\mathbf{S}_W = \sum_{n \in C_1} (\mathbf{x}_n - \boldsymbol{\mu}_1)(\mathbf{x}_n - \boldsymbol{\mu}_1)^T + \sum_{n \in C_2} (\mathbf{x}_n - \boldsymbol{\mu}_2)(\mathbf{x}_n - \boldsymbol{\mu}_2)^T \quad (3.47)$$

O máximo de (3.45) pode ser determinado derivando esta expressão com respeito à  $\mathbf{w}$  e igualando a zero, isto resulta em:

$$(\mathbf{w}^T \mathbf{S}_W \mathbf{w})(\mathbf{S}_B \mathbf{w}) = (\mathbf{w}^T \mathbf{S}_B \mathbf{w})(\mathbf{S}_W \mathbf{w}) \quad (3.48)$$

Para se evitar o crescimento da magnitude do vetor de pesos, impõe-se a restrição de norma unitária. Desta forma a magnitude do vetor  $\mathbf{w}$  não interfere na solução do problema. Assim, os fatores escalares  $(\mathbf{w}^T \mathbf{S}_B \mathbf{w})$  e  $(\mathbf{w}^T \mathbf{S}_W \mathbf{w})$  podem ser cancelados, resultando em:

$$(\mathbf{S}_B \mathbf{w}) = \alpha (\mathbf{S}_W \mathbf{w}) \quad (3.49)$$

onde  $\alpha$  é uma constante. Multiplicando ambos os lados da expressão (3.49) por  $\mathbf{S}_W^{-1}$ , obtém-se:

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{w} = \alpha \mathbf{w} \quad (3.50)$$

A expressão (3.46) indica que  $\mathbf{S}_B \mathbf{w}$  está sempre na direção de  $\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1$ , então o vetor de pesos é dado por:

$$\mathbf{w} \propto \mathbf{S}_W^{-1} (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1) \quad (3.51)$$

A extensão da teoria da análise do discriminante linear de Fisher para mais de duas classes pode ser consultada em (DUDA; HART; STORK, 2012) e (BISHOP, 2006). Neste trabalho, para lidar com múltiplas classes, projetaram-se vários classificadores binários em paralelo, de modo a classificar cada elemento como pertencendo ou não a determinada classe.

### 3.4.2 SUPPORT VECTOR MACHINES

As máquinas de vetores de suporte (SVMs) são estruturas muito úteis para solucionar problemas de classificação e regressão no contexto de aprendizagem de máquina e reconhecimento de padrões. Um sistema de classificação SVM segue dois estágios: treinamento e classificação. No treinamento, os dados rotulados são usados para determinar um hiperplano ótimo que permita a separação das classes. Uma vez definido o hiperplano ótimo, a SVM é capaz de operar a classificação de dados novos. Entretanto, determinar a superfície ótima de separação não é um problema trivial. Em 1965, Vapnik apresentou os conceitos envolvidos na definição do hiperplano ótimo como sendo uma função que permita distinguir as classes com máxima margem, conforme mostra a Figura 3.11 (VAPNIK, 1982).

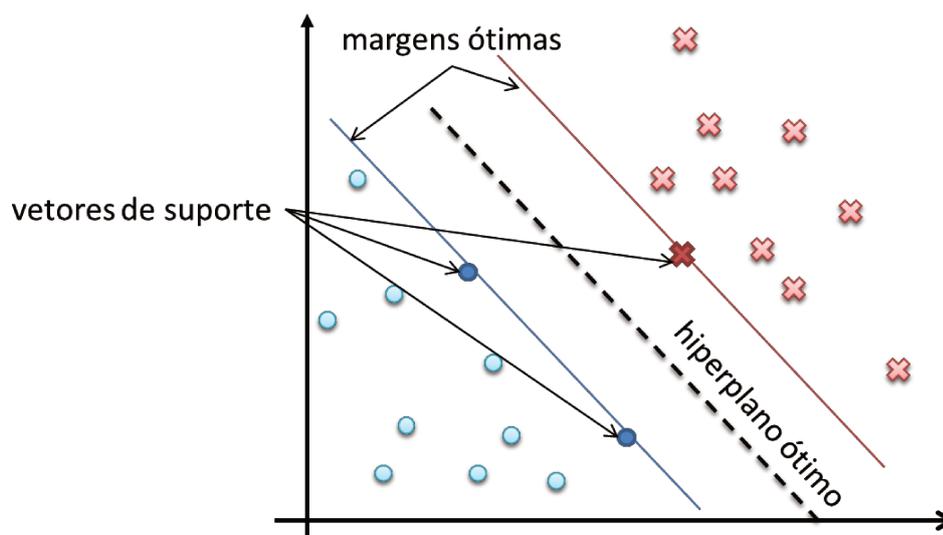


Figura 3.11 – Separação de duas classes utilizando SVM.

Vapnik demonstrou que o hiperplano ótimo pode ser projetado usando somente os vetores de suporte, ou seja, os dados do vetor de treinamento que determinam as margens das classes. Esta solução assegura alta capacidade de generalização da SVM (CORTES; VAPNIK, 1995).

Para melhor compreensão, considere o problema de separação de duas classes, no qual o conjunto de dados de treinamento é linearmente separável. Seja  $x_i$  a  $i$ -ésima entrada da matriz de dados e  $y_i$  o rótulo correspondente, que pode assumir valores  $+1$  e  $-1$ . Então, existe um classificador com parâmetros  $w$  e  $b$  tal que:

$$\begin{cases} \mathbf{w}\mathbf{x}_i + b \geq +1 \Rightarrow y_i = +1 \\ \mathbf{w}\mathbf{x}_i + b \leq -1 \Rightarrow y_i = -1 \end{cases} \quad (3.52)$$

Combinando as duas desigualdades, obtém-se:

$$y_i(\mathbf{w}\mathbf{x}_i + b) - 1 \geq 0 \quad \forall i \quad (3.53)$$

Se os dados são linearmente separáveis, os dados limites se transformam nas igualdades da expressão (3.52), ou seja, os vetores de suporte são tais que satisfazem:

$$y_i(\mathbf{w}\mathbf{x}_i + b) = 1 \quad (3.54)$$

Desta forma, o hiperplano ótimo, capaz de separar os dados de treinamento com a máxima margem, é dado por:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0 \quad (3.55)$$

sendo a distância entre as projeções das duas classes dada por:

$$D(\mathbf{w}, b) = \min_{\{x:y=1\}} \frac{\mathbf{x} \cdot \mathbf{w}}{\|\mathbf{w}\|} - \max_{\{x:y=-1\}} \frac{\mathbf{x} \cdot \mathbf{w}}{\|\mathbf{w}\|} \quad (3.56)$$

O termo da minimização e maximização definem os vetores de suporte, para as classes  $y_i = +1$  e  $y_i = -1$ , respectivamente. Note que há uma normalização com respeito ao vetor de pesos, dividindo-se por  $\|\mathbf{w}\|$ , de modo a evitar distorções na análise. Assim, para SVM, o hiperplano ótimo que maximiza a margem é aquele que, obedecendo às restrições de (3.52), possui norma mínima para o vetor de pesos  $\mathbf{w}$ :

$$\rho(\mathbf{w}_o, b_o) = \frac{2}{\|\mathbf{w}_o\|} \quad (3.57)$$

O projeto de um classificador deste tipo leva a um problema de otimização de ordem quadrática, cuja solução pode ser encontrada por meio do lagrangiano:

$$L(\mathbf{w}, b, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \lambda_i (y_i(\mathbf{w}^T \mathbf{x}_i + b) - 1) \quad (3.58)$$

onde  $\boldsymbol{\lambda}$  é o vetor dos multiplicadores de Lagrange e  $N$  é o número de dados do conjunto de treinamento. A obtenção dos parâmetros passa por um processo de minimização com respeito aos parâmetros do classificador  $\mathbf{w}$  e  $b$  e por uma maximização com respeito aos multiplicadores de Lagrange, conforme segue:

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N \lambda_i y_i \mathbf{x}_i = \mathbf{0} \quad (3.59)$$

e

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N \lambda_i y_i = 0 \quad (3.60)$$

A equação (3.59) permite obter a expressão que determina o vetor de pesos ótimos como sendo uma combinação linear dos dados para os quais os multiplicadores de Lagrange são não nulos:

$$\mathbf{w}_o = \sum_{i=1}^N \lambda_i y_i \mathbf{x}_i \quad (3.61)$$

Substituindo as expressões (3.59) e (3.60) em (3.58), tem-se:

$$L(\boldsymbol{\lambda}) = \sum_{i=1}^N \lambda_i - \frac{1}{2} (\mathbf{w}_o^T \mathbf{w}_o) \quad (3.62)$$

A tarefa do projeto do classificador de máxima margem é equivalente a maximizar a expressão (3.62) com a restrição dada por (3.60) e a restrição determinada pela desigualdade  $\lambda_i > 0$ ,  $i = 1, \dots, N$ . Existem diferentes metodologias para solucionar esse problema, conforme apresentam (CRISTIANINI; SHAWE-TAYLOR, 2000) e (CORTES; VAPNIK, 1995).

A formulação do classificador linear de máxima margem fornece a base conceitual à teoria de SVMs. Como nem sempre as classes são linearmente separáveis no espaço original, a ideia da SVM é mapear um vetor de entrada  $n$ -dimensional em um espaço de alta dimensão, no qual as classes sejam linearmente separáveis. O mapeamento é definido por uma função não linear que projeta cada ponto  $x_i$  do vetor de entradas, em uma imagem  $\phi(x_i)$  no espaço de características. Diferentes mapeamentos constroem diferentes SVMs. A Figura 3.12 ilustra um processo de classificação linear no espaço de características.

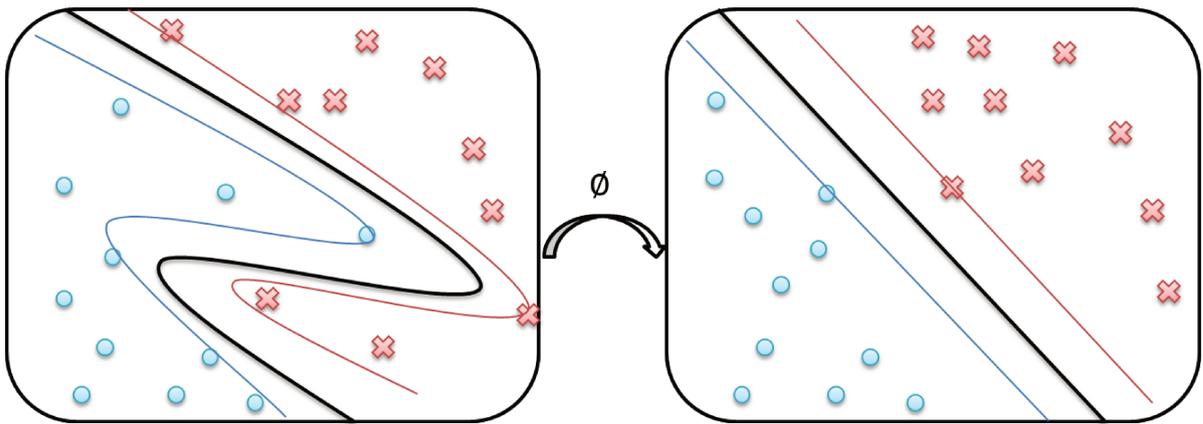


Figura 3.12 – Mapeamento do vetor de entrada em um espaço de alta dimensão para ilustrar a operação de uma SVM baseada em kernels.

No espaço na qual as classes são linearmente separáveis, o SVM simplesmente procura pelo hiperplano de máxima margem. Desta forma, a saída do classificador pode ser determinada por:

$$f(\mathbf{x}) = \mathbf{w}\phi(\mathbf{x}) + b \quad (3.63)$$

e o vetor de pesos ótimos passa a ser:

$$\mathbf{w}_o = \sum_{i=1}^N \lambda_i y_i \phi(\mathbf{x}_i) \quad (3.64)$$

de modo que a expressão do classificador pode ser reescrita como:

$$f(\mathbf{x}) = \sum_{i=1}^N \lambda_i y_i \phi^T(\mathbf{x}_i) \phi(\mathbf{x}) + b \quad (3.65)$$

Desta forma a operação do classificador depende da realização de produtos escalares  $\phi^T(\mathbf{x}_i)\phi(\mathbf{x})$  em um espaço de alta dimensão. Em 1992, (BOSER; GUYON; VAPNIK) mostraram que, para se evitar o alto custo computacional de se trabalhar com os dados em um espaço de alta dimensão, era possível trabalhar com funções de kernel. Na prática, a etapa de treinamento de uma SVM é realizada no espaço de dados original usando funções de kernel. Uma função de kernel pode ser definida como:

$$K(\mathbf{u}, \mathbf{v}) = \phi^T(\mathbf{u})\phi(\mathbf{v}) \quad (3.66)$$

O teorema de Mercer (CORTES; VAPNIK, 1995) apresenta uma condição necessária e suficiente para assegurar que a função de kernel, realmente, defina o produto escalar. Deve-se garantir que:

$$\iint K(\mathbf{u}, \mathbf{v})g(\mathbf{u})g(\mathbf{v})d\mathbf{u}d\mathbf{v} > 0 \quad (3.67)$$

é satisfeito para todo  $g$  tal que:

$$\int g^2(\mathbf{u})d\mathbf{u} < \infty \quad (3.68)$$

Existem inúmeras funções de kernel que podem ser usadas no contexto de SVM, como:

- Kernel polinomial:

$$K(\mathbf{x}, \mathbf{y}) = 1 + \mathbf{x}^T \mathbf{y} \quad (3.69)$$

- Kernel função de base radial (RBF):

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(\frac{-(\mathbf{x} - \mathbf{y})^T(\mathbf{x} - \mathbf{y})}{2\sigma}\right) \quad (3.70)$$

com  $\sigma \geq 0$ .

- Kernel multilayer perceptron (MLP):

$$K(\mathbf{x}, \mathbf{y}) = \tanh(P_1 \mathbf{x}^T \mathbf{y} + P_2) \quad (3.71)$$

com  $P_1 \geq 0$  e  $P_2 \leq 0$ .

Após a escolha de uma função de kernel, a superfície de decisão pode ser definida como:

$$f(\mathbf{x}) = \sum_{i=1}^N \lambda_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (3.72)$$

Desta maneira, pode-se construir o classificador aplicando-se toda a dedução vista para se determinar os hiperplanos de máxima margem. A diferença é que a matriz de dados de entrada, ao invés de ser determinada por  $D_{ij} = y_i y_j \mathbf{x}_i^T \mathbf{x}_j$ , passa a ser dada por  $D_{ij} = y_i y_j K(\mathbf{x}_i, \mathbf{x}_j)$ .

O número de vetores de suporte no modelo resultante é, geralmente, muito menor que o número de pontos do conjunto de treinamento. Uma vantagem da SVM é que, embora o treinamento envolva otimização não linear, a função objetivo é convexa e, portanto, a solução de otimização é relativamente direta.

### 3.4.3 EXTREME LEARNING MACHINES

A origem do termo rede neural emerge da modelagem matemática que tenta descrever o processamento de informação em sistemas biológicos (MCCULLOCH; PITTS, 1943) e (ROSENBLATT, 1962). Por rede neural entende-se uma estrutura formada por interconexões de neurônios que permitem processar informações. Estes modelos foram extrapolados para o contexto de aprendizado de máquinas e reconhecimento de padrões permitindo a solução de problemas nas mais variadas áreas do conhecimento que incluem: análise de imagens e áudio, biometria, reconhecimento de fala, mineração de dados e recuperação de informação. Sob o olhar matemático, os neurônios podem ser representados por elementos que integram a estimulação de entrada, a eficiência sináptica pelos valores dos pesos da rede neural e a função de ativação, que insere a não linearidade no modelo, configura o comportamento dual do neurônio de disparo ou ausência de disparo a um determinado estímulo.

Existem vários tipos de redes neurais, mas as mais utilizadas são as do tipo *feedforward*. Elas apresentam uma camada de entrada responsável por receber os estímulos externos, uma ou mais camadas ocultas que processam os dados e uma camada de saída que retorna o resultado da rede para o ambiente externo, conforme apresenta a Figura 3.13.

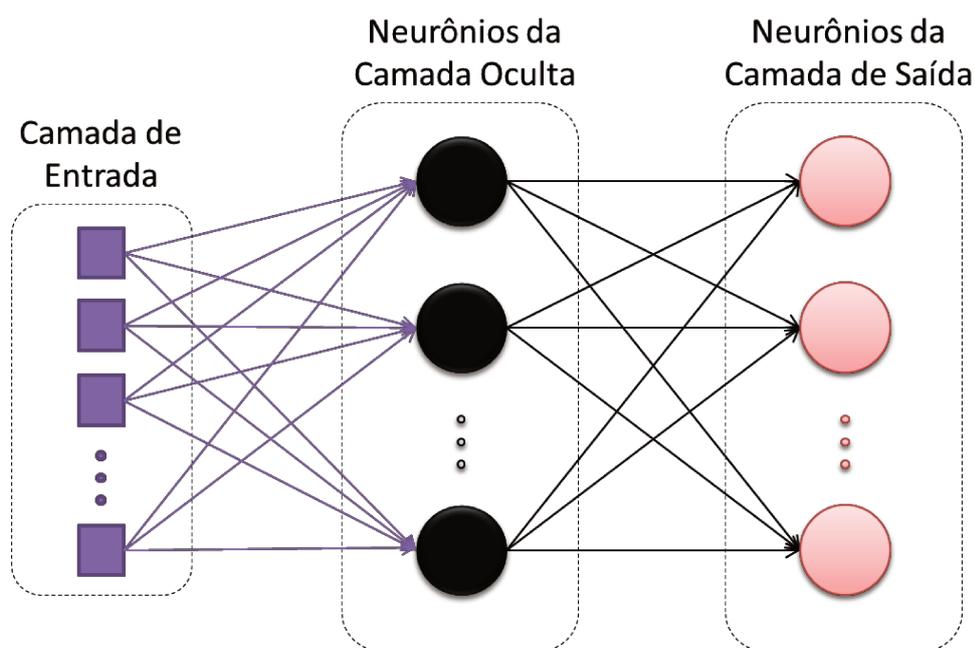


Figura 3.13 – Estrutura básica de uma rede neural *feedforward*.

Abordagens clássicas de redes *feedforward* incluem o Perceptron Multicamadas (MLP, do inglês *Multi Layer Perceptron*) e a rede baseada em funções de base radial (RBF, do inglês *Radial Basis Function*). Ambas utilizam algoritmos para determinar os pesos de cada neurônio, seja das camadas intermediárias, seja da camada de saída, de modo que todos os parâmetros da rede estejam sintonizados de maneira iterativa. Outra rede neural do tipo *feedforward* é a ELM, proposta em 2004 por (HUANG; ZHU; SIEW). Ao contrário das abordagens clássicas que empregam algoritmos pesados para determinar os pesos de cada neurônio da rede, na ELM, os pesos da camada oculta são atribuídos de forma aleatória, gerando um sistema linear, cuja solução representa os pesos da camada de saída. O processo de treinamento da camada de saída é equivalente à adaptação de um classificador linear. A escolha do número de neurônios ideal para compor a camada oculta pode ser determinada por métodos de validação cruzada. É imediato intuir que uma atribuição arbitrária dos pesos dos neurônios da camada oculta permite uma maior velocidade na estruturação de uma rede neural, entretanto pode-se questionar sobre a eficácia de uma estrutura não linear cujos pesos não são atribuídos de maneira sintonizada com toda a rede. Este questionamento foi respondido por (HUANG; ZHU; SIEW, 2004), que demonstraram a capacidade de aproximação universal da ELM bem como sua capacidade de generalização. Não obstante, a aleatoriedade dos pesos e o maior número de neurônios na camada oculta fazem com que a ELM evite alguns problemas que acontecem nas redes MLP e RBF, como o *overfitting* e soluções presas em máximos ou mínimos locais. Comparado com as redes neurais clássicas MLP e RBF, a ELM tende a apresentar um erro de treinamento satisfatório e pode garantir que a norma do vetor de pesos da camada de saída seja mínima (HUANG et al., 2012). Em contrapartida, a escolha aleatória dos pesos de entrada e do bias podem resultar em uma matriz de pesos da camada oculta de ranque não completo, o que torna o sistema linear insolúvel, impossibilitando a determinação do vetor de pesos da camada de saída (WANG; CAO; YUAN, 2011). Isto pode ser evitado com a regularização dos pesos gerados aleatoriamente.

Para iniciar o tratamento matemático das ELMs, considere a arquitetura da rede apresentadas na Figura 3.13. Trata-se de um arranjo de rede *feedforward* com camada de entrada, camada oculta e camada de saída.

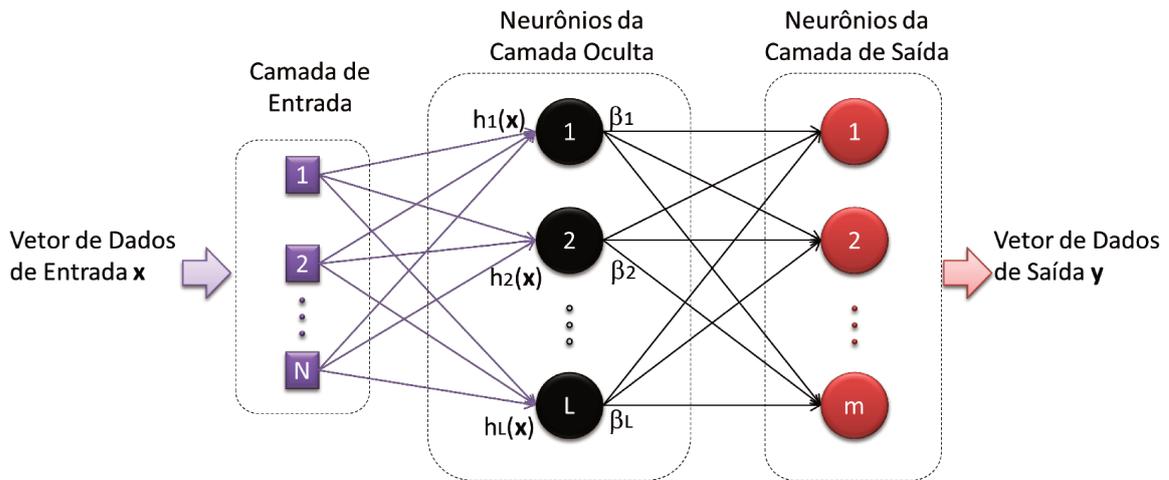


Figura 3.14 – Arquitetura de uma ELM.

A rede apresentada na Figura 3.14 possui  $N$  nós de entrada, os quais recebem as entradas do vetor  $\mathbf{x}$ , mapeando-as nos  $L$  neurônios na camada oculta, seguindo a não linearidade imposta pela função de ativação. As saídas da rede são determinadas pelos neurônios da camada de saída considerando o problema a ser resolvido e suas restrições. A função gerada por uma ELM com uma saída pode ser determinada por:

$$\mathbf{y}(\mathbf{x}) = \sum_{i=1}^L \beta_i h_i(\mathbf{x}) = \mathbf{h}(\mathbf{x})\boldsymbol{\beta} \quad (3.73)$$

sendo  $\boldsymbol{\beta} = (\beta_1, \dots, \beta_L)^T$  o vetor de pesos da camada de saída e  $\mathbf{h}(\mathbf{x}) = (h_1(\mathbf{x}), \dots, h_L(\mathbf{x}))$  a função de ativação que mapeia o vetor de entradas no espaço de características da rede ELM, sendo  $h_i(\mathbf{x})$  a saída do  $i$ -ésimo neurônio da camada oculta e

$$h_i(\mathbf{x}) = F(\mathbf{a}_i, b_i, \mathbf{x}) \quad (3.74)$$

com  $\mathbf{a}_i \in \mathbb{R}^D$  e  $b_i \in \mathbb{R}$  os parâmetros da função de ativação que independem dos dados de treinamento. Existem várias funções de ativação que podem ser empregadas, como:

- Função tangente hiperbólica:

$$F(\mathbf{a}, b, \mathbf{x}) = \frac{1 - \exp(-(\mathbf{a}^T \mathbf{x} + b))}{1 + \exp(-(\mathbf{a}^T \mathbf{x} + b))} \quad (3.75)$$

- Função sigmoidal:

$$F(\mathbf{a}, b, \mathbf{x}) = \frac{1}{1 + \exp(-(\mathbf{a}^T \mathbf{x} + b))} \quad (3.76)$$

- Função Gaussiana:

$$F(\mathbf{a}, b, \mathbf{x}) = \exp(-b\|\mathbf{x} - \mathbf{a}\|) \quad (3.77)$$

A ELM não exige que a função de ativação seja diferenciável, ao contrário das abordagens clássicas baseadas em treinamento via método do gradiente. Após o mapeamento dos dados de entrada na camada intermediária o vetor de pesos  $\boldsymbol{\beta}$  dos neurônios da camada de saída pode ser determinado minimizando o erro quadrático, de modo que:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{L \times m}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{d}\|^2 \quad (3.78)$$

sendo  $m$  o número de neurônios da camada de saída ( $m \geq 1$ ) e  $\mathbf{H}$  é a matriz de saída da camada intermediária.

$$\mathbf{H} = \begin{bmatrix} \mathbf{h}(\mathbf{x}_1) \\ \vdots \\ \mathbf{h}(\mathbf{x}_N) \end{bmatrix} = \begin{bmatrix} h_1(\mathbf{x}_1) & \cdots & h_L(\mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ h_1(\mathbf{x}_N) & \cdots & h_L(\mathbf{x}_N) \end{bmatrix}_{N \times L} \quad (3.79)$$

e  $\mathbf{D}$  é a matriz que contém os rótulos dos dados usados para o treinamento:

$$\mathbf{D} = [\mathbf{d}_1 \quad \cdots \quad \mathbf{d}_N] = \begin{bmatrix} d_{11} & \cdots & d_{1m} \\ \vdots & \ddots & \vdots \\ d_{N1} & \cdots & d_{Nm} \end{bmatrix}_{N \times m} \quad (3.80)$$

A solução ótima de (3.78) é dada por:

$$\boldsymbol{\beta}^* = \tilde{\mathbf{H}}\mathbf{D} \quad (3.81)$$

sendo  $\tilde{\mathbf{H}}$  a inversa generalizada da matriz  $\mathbf{H}$  determinada pelo método de Moore-Penrose (THEODORIDIS; KOUTROUMBAS, 2010). O cálculo da pseudo-inversa definida por Moore-Penrose (ver Seção 3.4.1.1) é dada por:

$$\begin{cases} \tilde{\mathbf{H}} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T, & \text{se } \mathbf{H}^T \mathbf{H} \text{ é não singular.} \\ \tilde{\mathbf{H}} = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T)^{-1}, & \text{se } \mathbf{H} \mathbf{H}^T \text{ é não singular.} \end{cases} \quad (3.82)$$

O primeiro caso, o mais frequente em problemas de classificação, ocorre se há maior número de amostras para o treinamento que neurônios na camada oculta ( $N > L$ ). Já no

segundo, ocorre a situação inversa, e  $N < L$ . Quando  $N = L$  ambas as expressões levam a soluções equivalentes, pois a matriz  $\mathbf{H}$  passa a ser quadrada. O uso da pseudo-inversa de Moore Penrose permite a obtenção de soluções ótimas no sentido de mínimos quadrados com a norma mínima para o vetor de pesos da camada de saída garantindo uma rede com bom desempenho e capacidade de generalização. Para aumentar a estabilidade e generalização da solução pode-se utilizar o método de regularização de Tikhonov (GOLUB; VON MATT, 1997) adicionando um termo positivo à diagonal das matrizes  $\mathbf{H}^T \mathbf{H}$  ou  $\mathbf{H} \mathbf{H}^T$  antes do cálculo do vetor de pesos de saída  $\boldsymbol{\beta}$ .

O problema de minimização a ser resolvido passa a ser:

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^{L \times m}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{d}\|^2 + \lambda \|\boldsymbol{\beta}\|^2 \quad (3.83)$$

cuja solução ótima é:

$$\begin{cases} \boldsymbol{\beta} = \left( \frac{\mathbf{I}}{\lambda} + \mathbf{H}^T \mathbf{H} \right)^{-1} \mathbf{H}^T \mathbf{D}, \text{ se } \mathbf{H}^T \mathbf{H} \text{ é não singular.} \\ \boldsymbol{\beta} = \mathbf{H}^T \left( \frac{\mathbf{I}}{\lambda} + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{D}, \text{ se } \mathbf{H} \mathbf{H}^T \text{ é não singular.} \end{cases} \quad (3.84)$$

A determinação do parâmetro  $\lambda$  não é uma tarefa trivial. A proposta de Huang *et al.* (2012) é que fossem atribuídos diversos valores  $\lambda$ , varrendo um conjunto discreto do tipo  $\{2^{-25}, 2^{-24}, 2^{-23}, \dots, 2^{23}, 2^{24}, 2^{25}\}$ , e avaliando o desempenho da rede com os dados disponíveis para validação. Após a determinação da magnitude do valor de  $\lambda$ , uma solução mais pontual poderia ser determinada considerando valores reais em torno do valor encontrado (KULAIIF; ZUBEN, 2013).

As ELMs vêm sendo empregadas com sucesso para solução de problemas em diversas áreas, conforme relatado em (HUANG *et al.*, 2015). Entretanto, no momento da concepção deste trabalho, não havia relatos na literatura da aplicação de ELMs em sistemas BCIs-SSVEP (CARVALHO *et al.*, 2015). Acredita-se que esta análise seja valiosa, uma vez que a ELM possui um processo de treinamento simples, de baixo custo computacional e rápido, permitindo a implementação de sistemas BCIs robustos, com boa capacidade de generalização e eficientes para operarem em tempo de execução.

---

## 4. DESENVOLVIMENTO DE UM SISTEMA BCI-SSVEP

Este Capítulo tem como objetivo descrever os experimentos desenvolvidos visando a implementação de sistemas BCI-SSVEP capazes de operar em tempo de execução de modo robusto. Inicialmente, relatam-se os estudos realizados em uma base de dados pública de sinais EEG disponibilizada por (BAKARDJIAN; TANAKA; CICHOCKI, 2010). Os resultados desta primeira avaliação permitiram estabelecer estratégias de aquisição do sinal EEG, bem como moldar algumas combinações de técnicas de extração de características e classificação capazes de permitir a identificação do estímulo visual ao qual o indivíduo está exposto. Este estudo inicial serviu de base para a formação da base de dados DESTINE constituída por registros eletroencefalográficos de voluntários saudáveis e pacientes que sofreram AVC coletados no âmbito dos projetos DESTINE-FINEP e BRAINN-FAPESP. Esta base de dados permitiu uma extensa análise dos padrões neurofisiológicos decorrentes de estimulação visual com a aplicação de diferentes técnicas nas etapas de pré-processamento, extração de características, seleção de características e classificação. As simulações visavam determinar a combinação de técnicas mais eficiente na concepção de uma BCI-SSVEP. Ao longo da Seção 4.3 são descritos os experimentos realizados na base DESTINE seguindo a estrutura: Metodologia, Resultados e Discussão e Contribuições e Conclusões. É importante ressaltar que a ordem de apresentação não corresponde à ordem cronológica de realização das análises, mas foram organizadas de maneira que a apresentação ficasse mais clara e intuitiva.

### 4.1 BASE DE DADOS PÚBLICA

A análise dos sinais EEG da base de dados do professor Bakardjian permitiu a familiarização com as características dos sinais cerebrais, especialmente no que diz respeito aos padrões neurofisiológicos associados à estimulação visual. Os detalhes do protocolo de aquisição e do procedimento experimental podem ser consultados em (BAKARDJIAN, 2010). Os estímulos visuais consistiam em imagens no padrão xadrez que alternavam de forma reversa entre o preto/branco nas frequências de 8, 14 e 28 Hz. Cada estímulo foi projetado individualmente na tela de um monitor CRT (*Cathodic Ray Tube*) de 21 polegadas. Os indivíduos foram orientados a fixarem o olhar por 15 segundos em cada um dos estímulos

enquanto se realizava a eletroencefalografia. O procedimento de coleta foi realizado com quatro indivíduos e repetido cinco vezes para cada frequência de estimulação, totalizando 60 sessões. O EEG empregou 128 eletrodos de modo a mapear todos os lobos cerebrais (ver Figura 4.1). A taxa de amostragem foi de 256 Hz.

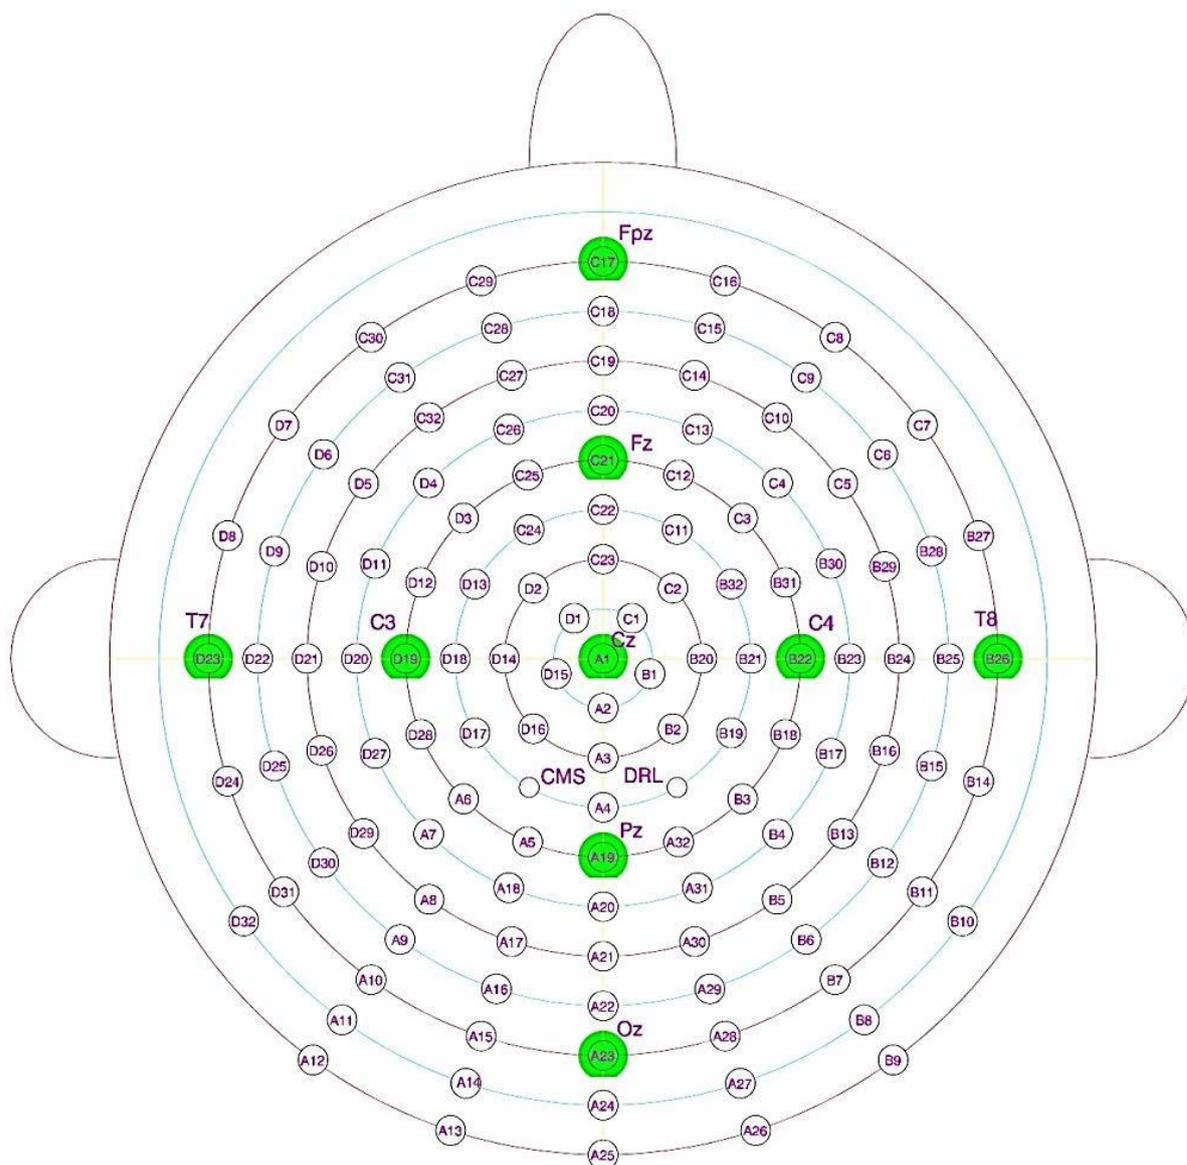


Figura 4.1 – Disposição dos 128 eletrodos.  
Fonte: (BAKARDJIAN; TANAKA; CICHOCKI, 2010).

A Figura 4.2 apresenta o sinal EEG adquirido na posição  $O_1$  durante a primeira sessão realizada com o indivíduo 1. A representação no domínio temporal (Figura 4.2(a)), embora carregue todas as informações do sinal, não permite uma distinção imediata do estímulo ao qual o indivíduo está exposto. Em contrapartida, a representação frequencial, mostrada na Figura 4.2(b), evidencia esta informação. Nota-se uma maior energia espectral em torno da frequência evocada e de suas harmônicas, principalmente no gráfico referente à frequência de 8 Hz (Figura 4.2(b)). Observa-se também uma redução do pico de energia para frequências mais elevadas, sendo que o maior pico ocorre em 8 Hz, um pico de valor intermediário é observado em 14 Hz e em 28 Hz a resposta ao estímulo torna-se praticamente indistinguível do resto do sinal.

É interessante ressaltar que esses dados haviam sido filtrados utilizando técnicas de separação cega de fontes para a eliminação de ruídos e artefatos. Geralmente, o espectro do sinal apresenta picos de energia em outras frequências não relacionadas à estimulação visual e isto se reflete como um aumento das oscilações no domínio temporal.

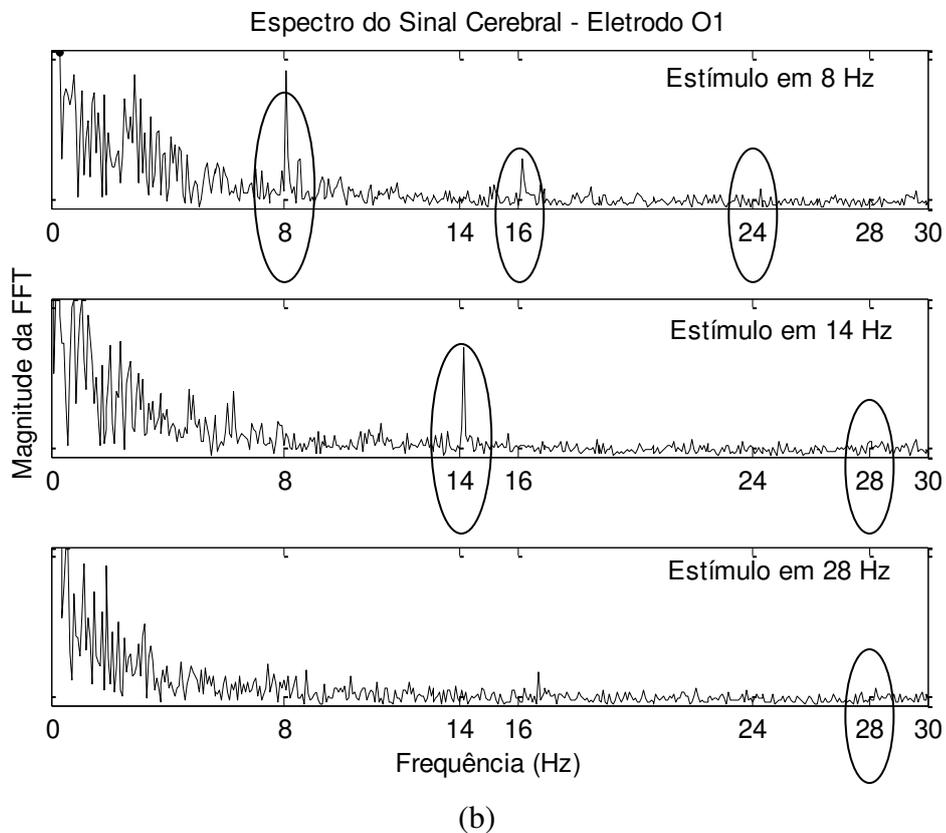
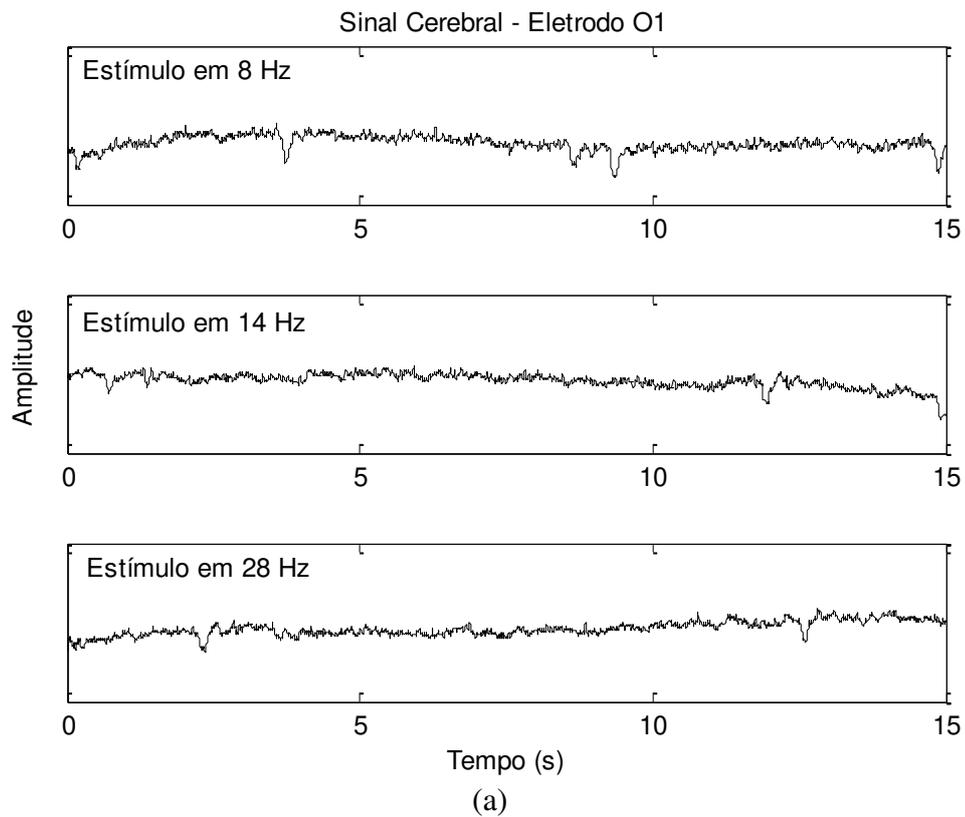


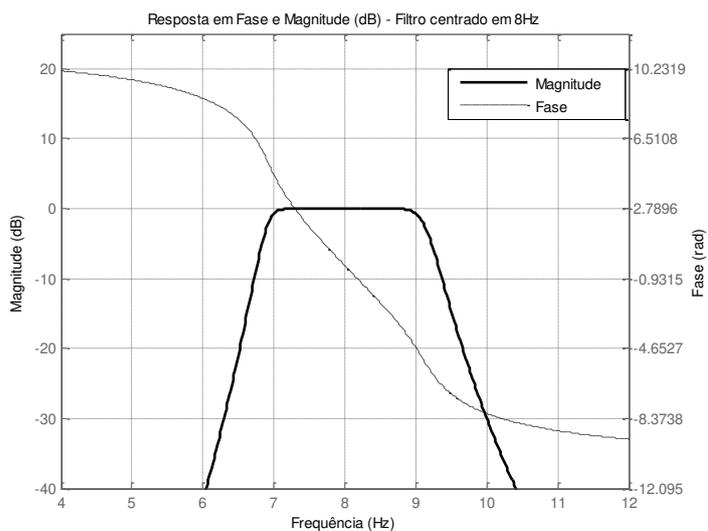
Figura 4.2 – Sinal cerebral adquirido em O<sub>1</sub> durante estimulação visual em 8, 14 e 28 Hz, (a) domínio do tempo e (b) domínio da frequência.

Os dados EEG da base pública foram analisados tanto no domínio do tempo como no da frequência. Em ambas as abordagens, explorou-se o caráter estacionário do paradigma SSVEP, o que permitiu que cada *trial* de 15 s fosse segmentado em *sub-trials* de 125 ms ou 1 s. Este janelamento visa tratar o sinal em condições semelhantes aos de sistemas que funcionam de maneira *online*.

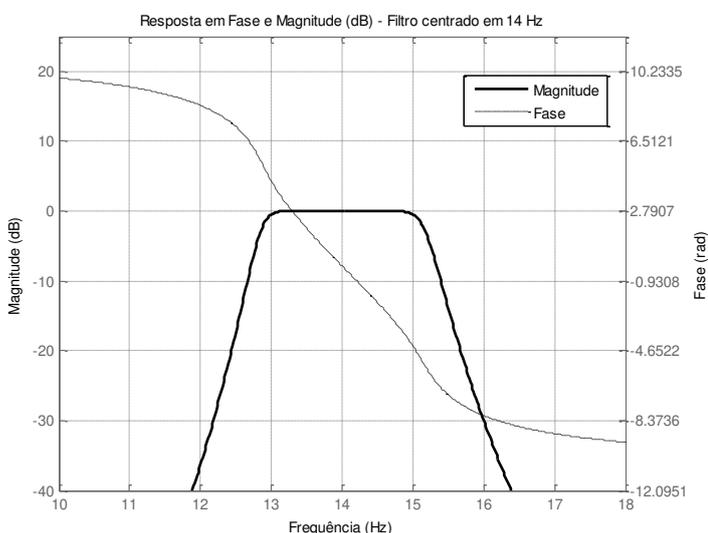
No domínio temporal, as características foram extraídas de cada *sub-trial* por meio de modelos autorregressivos usando a técnica de Burg (BELL; PERCIVAL, 1991), (POLAK; KOSTOV, 1998) e (WAELE; BROERSEN, 2000). A ordem  $p$  do modelo AR foi determinada por validação cruzada como sendo igual a 2. Ordens maiores foram testadas, mas não acarretavam melhoria de desempenho, provavelmente devido ao pré-processamento e normalização aplicados ao sinal disponibilizado (BAKARDJIAN, 2010).

No domínio da frequência, cada *sub-trial* foi filtrado por um banco de filtros do tipo *Butterworth* passa-faixas, conforme mostra a Figura 4.3. Os filtros foram projetados com largura de banda de 2 Hz, estando centrados em torno de cada uma das frequências evocadas (8, 14 e 28 Hz) e com atenuação de 30 dB na faixa rejeitada. A extração de características foi definida como sendo a densidade espectral de potência resultante da filtragem em cada faixa de interesse.

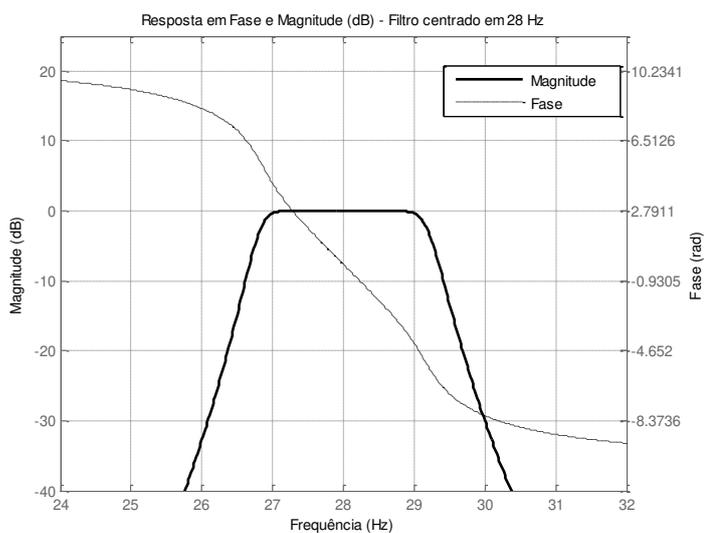
As características extraídas no domínio temporal e espectral foram submetidas a três diferentes estruturas de classificação (ver Seção 3.4): (1) função linear baseada no método dos mínimos quadrados, (2) ELM/mínimos quadrados e (3) ELM/Fisher, gerando seis diferentes cenários para comparações. O classificador linear usou o método dos mínimos quadrados para distinguir entre as três classes de estímulos. A discriminação foi feita para cada estímulo de maneira binária, no esquema “pertence ou não pertence à determinada classe”. Nos casos em que o sinal era classificado como pertencente a mais de uma classe, a decisão era tomada de modo que o sinal fosse atribuído à classe para a qual apresentasse maior afinidade, ou seja, menor erro quadrático médio. De maneira equivalente, nos casos em que o sinal não era classificado como pertencente a nenhuma classe, ele era atribuído à classe à qual apresentasse menor erro quadrático médio.



(a)



(b)



(c)

Figura 4.3 – Resposta em fase e magnitude dos filtros passa-bandas centrados em (a) 8 Hz, (b) 14 Hz e (c) 28 Hz.

As redes neurais ELMs foram projetadas utilizando dois critérios diferentes na estimação dos parâmetros da camada de saída. Uma primeira abordagem utilizou o método dos mínimos quadrados, operando de forma equivalente ao projeto do classificador linear. A outra abordagem utilizou o critério de Fisher para discriminar de maneira binária se o sinal pertencia ou não a determinada classe. Este esquema binário permite generalizar o classificador para distinguir entre  $N$  classes sem aumentar a complexidade matemática e computacional do problema de discriminação multiclases (DUDA; HART; STORK, 2012). Para ambos os casos, a camada de saída da rede neural foi projetada com três neurônios, sendo cada um responsável por uma frequência evocada (classe). O número de neurônios da camada intermediária da ELM foi determinado por validação cruzada. A Figura 4.4 mostra o diagrama da rede ELM projetada.

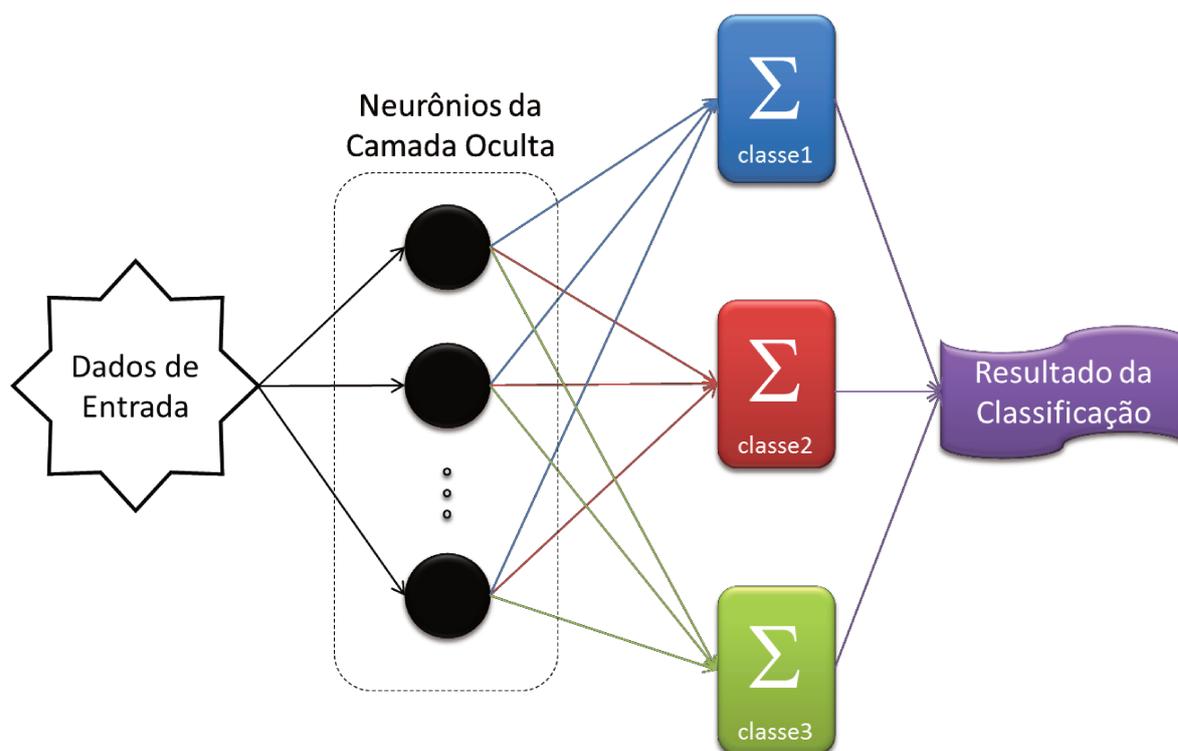


Figura 4.4 – Estrutura de classificação das três classes usando a rede ELM.

Todos os classificadores foram treinados utilizando o equivalente a 4 *trials* de dados para o treinamento e 1 *trial* para a validação. Quando a segmentação do sinal se deu com janelas de 1 s, cada estrutura de classificação utilizou 60 *sub-trials* para treinamento e 15 *sub-trials* para validação. Para janelamentos de 125 ms, 480 *sub-trials* foram usados no treinamento e 120 para validação.

Como cada pessoa responde aos estímulos visuais com um padrão

neurofisiológico específico, o projeto dos classificadores foi realizado de forma individual. Foi aferida a taxa de acerto de cada um dos quatro sistemas utilizando os dados de validação. O desempenho da ELM foi definido como sendo a média da taxa de acerto de 20 realizações para cada indivíduo, de modo a diluir o efeito do caráter aleatório na formação da camada intermediária desta rede neural. O número de neurônios da rede neural foi determinado por validação cruzada.

A Tabela 4.1 mostra o desempenho médio dos quatro indivíduos em cada uma das configurações testadas, bem como elenca os eletrodos dos quais foram extraídas as características.

**TABELA 4.1 – DESEMPENHO DO SISTEMA EM CADA UM DOS CENÁRIOS.**

Sistema de Classificação	Características						Canais
	Janelamento (s)	Neurônios	p	Taxa de Acerto (%)			
				8 Hz	14 Hz	28 Hz	
Potência Espectral	0,125	-	-	99,1	62,8	87,5	O1, O2, Oz
Classificador linear – mínimos quadrados	0,125	-	-	100	99,5	100	O1, O2, Oz, D9, C1, C3
Potência Espectral	0,125	180	-	88,5	85,3	75,9	O1, O2, Oz
ELM – mínimos quadrados	0,125	180	-	98,2	90,8	90,9	O1, O2, Oz, D9, C1, C3
Potência Espectral	0,125	180	-	86,8	84,8	83,8	O1, O2, Oz
ELM– Fisher	0,125	180	-	98,1	97,6	95,4	O1, O2, Oz, D9, C1, C3
Coeficientes AR Classificador linear – mínimos quadrados	0,125	-	2	74,9	48,9	81,0	O1, O2, Oz
	0,125	-	2	82,0	75,0	94,5	O1, O2, Oz, D9, C1, C3
	0,125	-	2	87,6	86,8	76,1	All 128
	1,000	-	2	88,3	55,8	92,5	O1, O2, Oz
Coeficientes AR ELM – mínimos quadrados	0,125	50	2	56,2	52,0	77,9	O1, O2, Oz
	0,125	50	2	77,0	69,2	91,2	O1, O2, Oz, D9, C1, C3
	1,000	50	2	86,0	58,8	93,8	O1, O2, Oz
Coeficientes AR ELM– Fisher	0,125	50	2	66,9	66,9	73,5	O1, O2, Oz
	1,000	50	2	77,7	73,6	86,4	O1, O2, Oz

## 4.2 CONSIDERAÇÕES

Os experimentos revelaram o comportamento da resposta SSVEP nas perspectivas temporal e no domínio da frequência. Foi possível verificar que a dispersão das características, em ambos os domínios, é passível de separação por modelos lineares no espaço de atributos. Entretanto, há uma superioridade na qualidade das características espectrais, justificando a popularidade da aplicação da análise espectral em sinais SSVEP. Por uma simples inspeção do espectro de frequência, já é possível inferir qual foi a frequência evocada, uma vez que a densidade espectral de energia, que emerge em torno da frequência evocada e de suas harmônicas, é significativa. De fato, em todos os cenários testados, os sistemas que empregaram a densidade espectral de potência como fonte de atributos de discriminação obtiveram uma taxa de acerto superior àquele alcançado utilizando os coeficientes AR. Todavia, a extração de características temporais não deve ser desconsiderada, uma vez que alguns trabalhos relatam sucesso usando esta metodologia (SENHADJI; BELLANGER; CARRAULT, 1997), (POLAK; KOSTOV, 1998), (SEMMLow, 2004), (GOLLEE et al., 2010) e (MILLÁN et al., 2010). Também é importante frisar que, por se tratar de dados pré-processados oriundos de uma base pública, a modelagem temporal do sinal foi, de certa forma, limitada à ordem  $p = 2$ , uma vez que ordens maiores do modelo de regressão não agregavam ao desempenho do sistema. A baixa ordem do modelo AR torna-se aceitável, tendo em vista que o sinal cerebral SSVEP filtrado se aproxima de um sinal senoidal.

Em relação aos classificadores, as três estruturas de classificação testadas – classificador linear, ELM/mínimos quadrados e ELM/Fisher – apresentaram desempenho semelhante e mostraram-se eficientes para serem incorporadas a uma BCI-SSVEP. Em particular, a estrutura não linear ELM revelou-se promissora, ao operar com a robustez de classificadores lineares, mas acrescentando um grau de flexibilidade ao modelo. É interessante ressaltar que a taxa de acerto da ELM foi equivalente para ambos os critérios de treinamento da camada de saída da rede neural – Fisher e mínimos quadrados – indicando que as características de cada classe apresentam um comportamento regular. Obteve-se taxa de acerto superior a 95% na discriminação entre as três classes de estímulos, quando se usaram características espectrais, mesmo para janelas pequenas de 125 ms e com somente 6 eletrodos. O desempenho alcançado usando como características os coeficientes AR, com janelamento de 1 s, também foi considerado satisfatório ficando em torno de 80%.

Deve-se ressaltar que a inclusão de características extraídas dos sinais EEG coletados em diferentes posições do escalpo impactou diretamente no desempenho do sistema, resultando em um aumento na taxa de acerto do classificador. Isso se deu especialmente para os sinais advindos dos lobos parietais e centrais, além dos da zona occipital.

Os resultados apresentados são motivadores na perspectiva de implementação de aplicações BCIs que funcionem em tempo de execução, uma vez que as técnicas testadas podem ser diretamente incorporadas ao sistema, desde que haja uma etapa de pré-processamento capaz de operar em tempo de execução.

Estes primeiros testes permitiram avaliar o comportamento dos sinais EEG-SSVEP levando a importantes resultados, os quais, juntamente com o respaldo da literatura da área, permitiram o estabelecimento de um protocolo de aquisição de sinais EEG-SSVEP. A geração de uma base de dados própria era imprescindível para se conceber um sistema BCI operante em tempo de execução e se avaliar a influência e atuação de cada etapa do bloco de processamento de sinais.

### **4.3 BASE DESTINE**

Um grupo de pesquisa, constituído de pesquisadores do DSPCom/FEEC/UNICAMP (*Laboratory of Digital Signal Processing for Communications*), atua ativamente, desde 2013, na análise de registros encefalográficos visando o desenvolvimento de sistemas BCI. Atualmente, a base de dados de EEG-SSVEP do grupo é composta por registros coletados em nove indivíduos saudáveis, sendo sete homens e duas mulheres com idade média de  $25,4 \pm 3,2$  anos e dois pacientes que sofreram AVC, ambos do sexo masculino, com idade média de  $69,5 \pm 0,5$  de anos. Todos os indivíduos apresentavam visão normal ou corrigida para normal no momento da coleta. A Tabela 4.2 apresenta o perfil dos indivíduos que participaram da coleta de dados EEG.

TABELA 4.2 – PERFIL DOS INDIVÍDUOS DA BASE DE DADOS.

Indivíduo	Sexo	Idade (anos)
Voluntário 1	Masculino	29
Voluntário 2	Masculino	21
Voluntário 3	Masculino	25
Voluntário 4	Masculino	22
Voluntário 5	Feminino	29
Voluntário 6	Feminino	29
Voluntário 7	Masculino	29
Voluntário 8	Masculino	24
Voluntário 9	Masculino	21
Paciente 1	Masculino	70
Paciente 2	Masculino	69

Os pacientes foram acompanhados por especialistas no Hospital de Clínicas da UNICAMP. A gravidade do AVC foi classificada usando a Escala do AVC do Instituto Nacional de Saúde (NIHSS, do inglês *National Institute of Health Stroke Scale*), e o nível de incapacidade usando a escala de Rankin (ver Tabelas 4.3 e 4.4). O Paciente 1 foi avaliado 27 dias após o ictus, tendo sofrido isquemia no lobo frontal. Seu AVC foi classificado como NIHSS 3 e Rankin 1, ou seja, sem deficiência significativa, sendo capaz de realizar todas as tarefas e atividades habituais. O Paciente 2 foi avaliado 89 dias após o AVC, com isquemia nos lobos frontal, parietal e temporal no hemisfério direito. Ele apresentava déficit motor com hemiplegia, sua classificação é NIHSS 5 e Rankin 4, ou seja, ele tinha mobilidade reduzida nas extremidades superiores e inferiores, sendo incapaz de andar sem ajuda e de atender às suas próprias necessidades corporais sem assistência.

TABELA 4.3 – ESCALA NIHSS.

Escala NIHSS	Descrição de gravidade do AVC
0	Sem sintomas
1-4	Deficiência ligeira
5-15	Deficiência moderada
16-20	Deficiência grave
21-42	Deficiência severa

TABELA 4.4 – ESCALA RANKIN MODIFICADO.

Escala Rankin	Descrição de gravidade do AVC
0	Sem sintomas.
1	Nenhuma deficiência significativa, capaz de conduzir todos os deveres e atividades habituais.
2	Leve deficiência: incapaz de conduzir todas as atividades habituais, mas é capaz de cuidar dos próprios afazeres sem assistência.
3	Deficiência moderada: requer alguma ajuda, mas é capaz de caminhar sem assistência.
4	Deficiência moderadamente severa: incapaz de caminhar sozinho e de desempenhar as necessidades fisiológicas sem assistência.
5	Deficiência severa: confinado à cama, requer cuidados e atenção constante de enfermagem.
6	Óbito.

Tanto os voluntários como os pacientes foram adequadamente esclarecidos sobre a pesquisa e o protocolo experimental, e assinaram o termo de consentimento aprovado pelo comitê de ética em Pesquisa da UNICAMP, parecer número 791/2010 CAAE 0617.0.146.000-10, apresentados nos Anexos A, B e C.

A interface de estímulos, mostrada na Figura 4.5, consiste em dois padrões xadrez, com 3,8 cm de lado, que cintilam em diferentes frequências alternando entre as cores preto/branco. Os estímulos visuais foram posicionados um à esquerda e outro à direita de uma tela de fundo preto. A projeção dos estímulos se deu em um monitor de 14 polegadas com taxa de *refresh* de 60 Hz. Para garantir a precisão da alternância entre os padrões direto e reverso do estímulo, adotaram-se frequências de atualização submúltiplas da taxa de *refresh* do monitor, a saber: 6, 7,5, 12, 15, 20 e 30 Hz. Optou-se por não trabalhar com frequências superiores a 30 Hz, devido à baixa amplitude da resposta VEP (HERMANN, 2001), e por não utilizar frequências inferiores a 5 Hz devido ao alto conteúdo de artefatos e interferentes. A frequência de 10 Hz também não foi utilizada devido à presença de interferência espectral de fonte desconhecida.



Figura 4.5 – Interface de estímulo visual.

As coletas foram realizadas em ambiente controlado e de baixa luminosidade, para minimizar a presença de interferentes externos e garantir a boa qualidade do sinal. Durante a aquisição, os indivíduos ficaram sentados a uma distância entre 60 cm e 100 cm do monitor e foram orientados a se concentrarem e permanecerem imóveis durante os intervalos de aquisição, de modo a evitar artefatos mecânicos.

Inicialmente, o protocolo experimental consistia no registro EEG durante intervalos de 3 minutos para cada estímulo. Entretanto, os voluntários relataram fadiga e desconforto visual. Não obstante, notou-se que a intensidade do potencial evocado não se mantinha constante, sendo mais intensa nos primeiros segundos, provavelmente, devido a uma maior concentração do indivíduo e ao fenômeno de habituação do indivíduo a um estímulo repetitivo ao longo do tempo (REGAN, 1977b) e (KRUEGER-BECK, 2011). A Figura 4.6 mostra o gráfico de contorno do sinal EEG registrado na posição O1, quando para um voluntário estimulado visualmente em 20 Hz, observa-se uma queda na potência espectral ao longo do tempo de aquisição. Nota-se que o sinal SSVEP não é estritamente estacionário, variando a intensidade da resposta VEP ao longo do tempo.

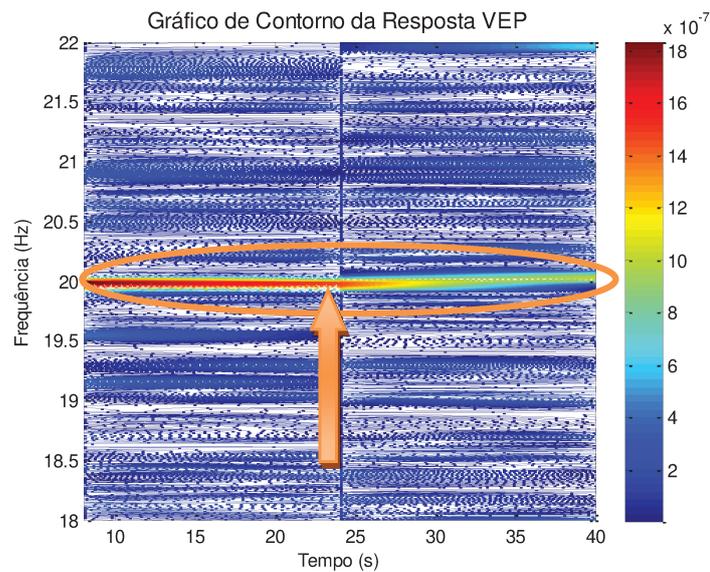


Figura 4.6 – Gráfico de contorno da resposta VEP ao estímulo visual de 20 Hz.

Desta forma, optou-se por realizar coletas em pequenos intervalos temporais. O protocolo de aquisição é ilustrado na Figura 4.7. O indivíduo foi orientado a se concentrar em cada um dos seis estímulos por 12 s, sendo informado oralmente sobre o final de cada período. A sétima aquisição foi realizada com o indivíduo mantendo os olhos fechados e em seguida houve um tempo para descanso. O ciclo de coleta recomeçava quando o indivíduo sinalizava estar pronto. O processo foi repetido oito vezes para cada indivíduo, totalizando 616 aquisições (11 indivíduos x (6 estímulos visuais + olho fechado) x 8 sessões).

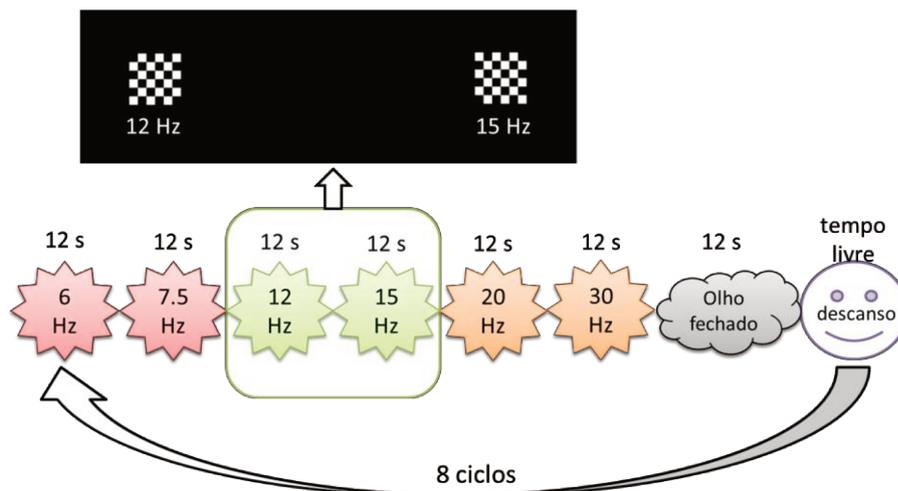


Figura 4.7 – Protocolo de aquisição dos sinais EEG.

Os sinais cerebrais foram coletados utilizando uma touca de 16 eletrodos secos do tipo g<sup>®</sup>.SAHARAsys e um amplificador de biosinais g.USBamp (GTEC), conforme mostra a Figura 4.8.

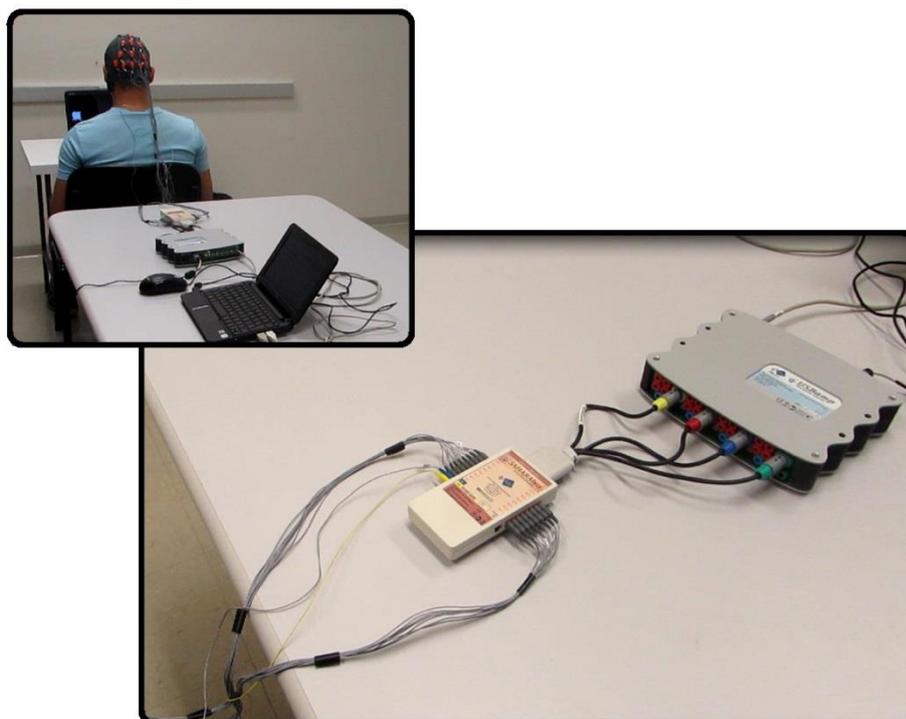


Figura 4.8 – Equipamentos utilizados para capturar os sinais EEG.

A touca foi posicionada de modo que a identificação das posições respeitasse o padrão 10-10. A Figura 4.9 mapeia os dezesseis eletrodos empregados: O1, O2, Oz, POz, Pz, PO3, PO4, PO7, PO8, P1, P2, Cz, C1, C2, CPz, FCz. Além do lobo occipital, foram mapeados os lobos parieto-occipital, parietal e central, uma vez que os testes preliminares realizados com a base do Prof. Bakardjian indicaram que havia informações relevantes para a tarefa de discriminação do potencial evocado. O canal de terra do sistema e a referência foram posicionados nos processos mastoideis.

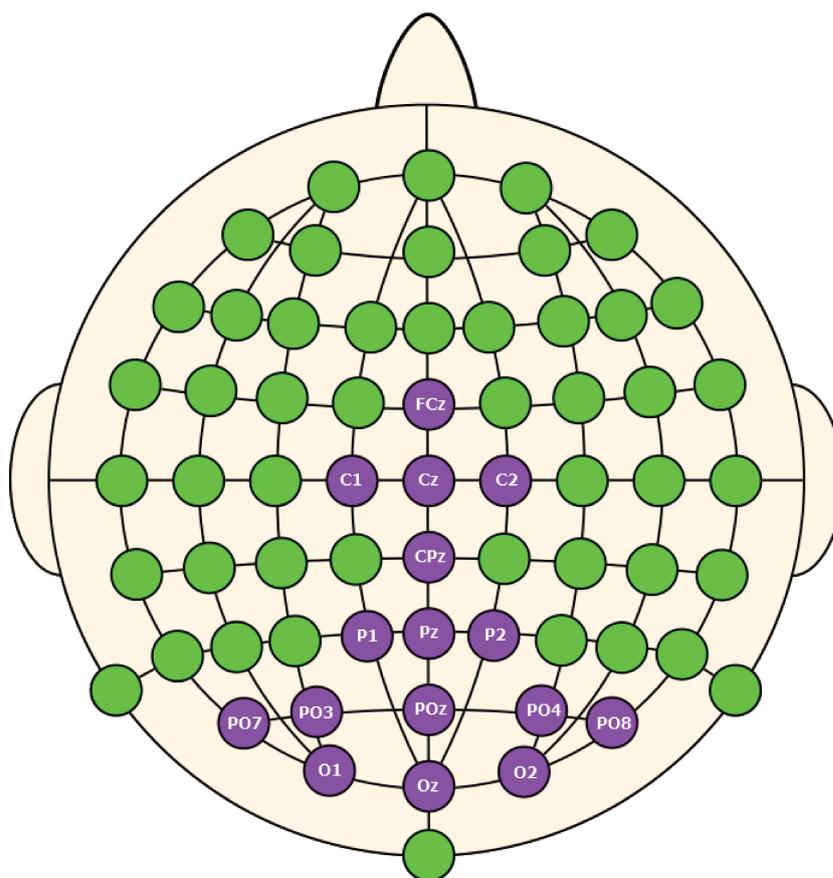


Figura 4.9 – Disposição dos 16 eletrodos no escalpo para aquisição do sinal de EEG.

Ao início de cada coleta, os equipamentos eram calibrados, de modo que a impedância dos canais e dos eletrodos estivesse entre 0,5 e 5,0 k $\Omega$ . O sinal cerebral foi digitalizado a uma taxa de amostragem de 256 Hz e usando 24 bits para quantização (GTEC). Foi aplicada uma filtragem utilizando um filtro do tipo *notch* na faixa de 58 a 62 Hz, para eliminar a interferência da rede e um filtro passa banda do tipo Butterworth de oitava ordem no intervalo 5 a 60 Hz. Os dados amostrados foram transferidos por meio da API (*Application Programming Interface*) fornecida pelo fabricante para o MATLAB<sup>®</sup> 2012b.

Várias análises foram realizadas sobre esta base de dados, permitindo contribuições à área de processamento de sinais cerebrais e ao projeto de uma BCI-SSVEP *online* com uma taxa de acerto superior a 80%. Na sequência, são descritos os experimentos realizados. Note que a ordem de apresentação não corresponde à ordem cronológica, mas visa tornar a compreensão dos resultados mais intuitiva. Isto justifica o porquê da diferença entre o número de indivíduos e de estímulos, os quais foram sendo coletados ao longo de todo o processo levando em conta as observações e descobertas realizadas.

### 4.3.1 EXPERIMENTO 1: COMPARAÇÃO DE DESEMPENHO DE DIVERSAS TÉCNICAS DE PROCESSAMENTO DE SINAIS CEREBRAIS EM SISTEMAS BCI-SSVEP

**Metodologia:** As teorias de processamento de sinais, aprendizado de máquina e reconhecimento de padrões apresentam um vasto ferramental que pode ser empregado no projeto do módulo de processamento de sinais de uma BCI. A combinação harmoniosa entre as técnicas pode agregar eficiência e confiabilidade ao sistema. Neste experimento, realizou-se uma análise comparativa do desempenho de uma BCI-SSVEP para 36 cenários, resultado da combinação de diversas técnicas de extração de características, seleção de atributos e classificação (ver Figura 4.10). Cada cenário foi avaliado usando o mesmo conjunto de dados EEG coletados em sete voluntários saudáveis durante estimulação visual nas frequências de 12 e 15 Hz. A gravação EEG seguiu o protocolo de aquisição do DSPCom, apresentado na Seção 4.3.

Na etapa de pré-processamento, os artefatos foram tratados aplicando-se a técnica de CAR. Em seguida, o sinal foi segmentado em janelas temporais de 3 s com sobreposição de 2 s, vislumbrando simular processos factíveis de operarem em tempo de execução.

Explorando a boa caracterização no domínio da frequência do sinal SSVEP, empregaram-se três diferentes técnicas para extrair os atributos em cada janela: banco de filtros, espectrograma e periódograma de Welch.

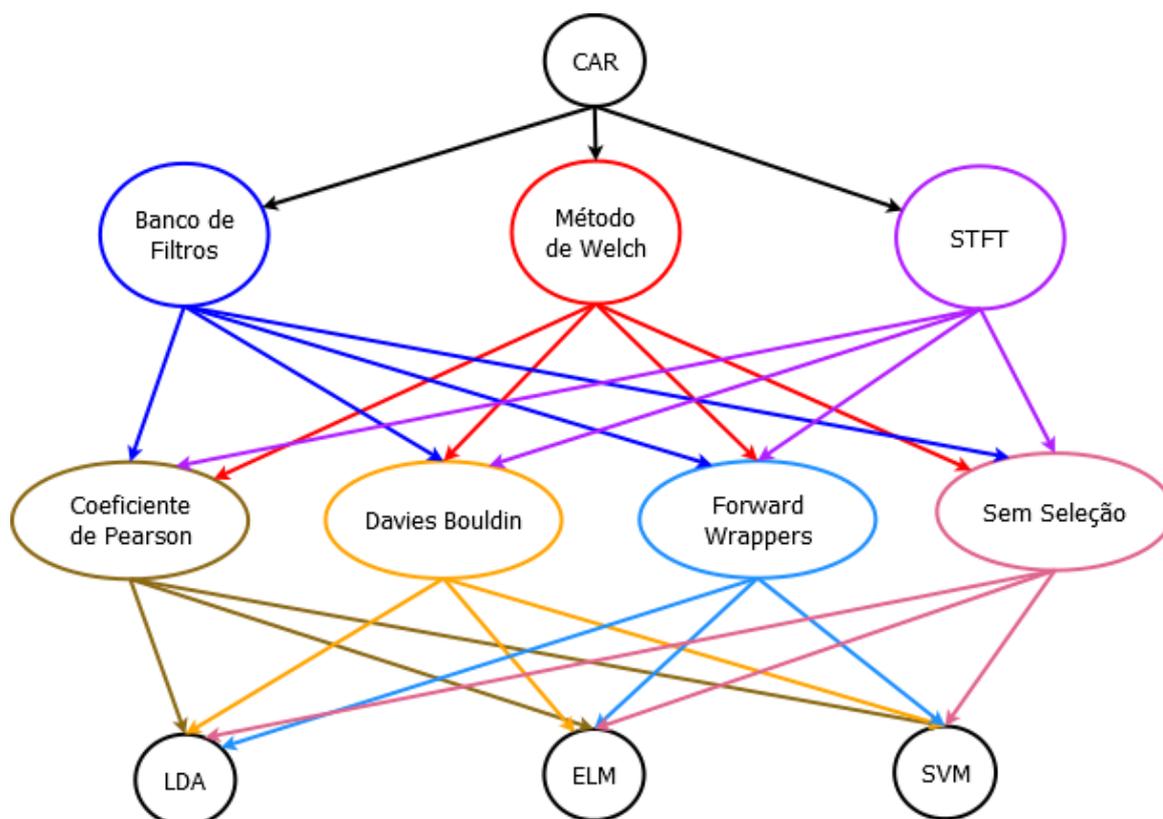
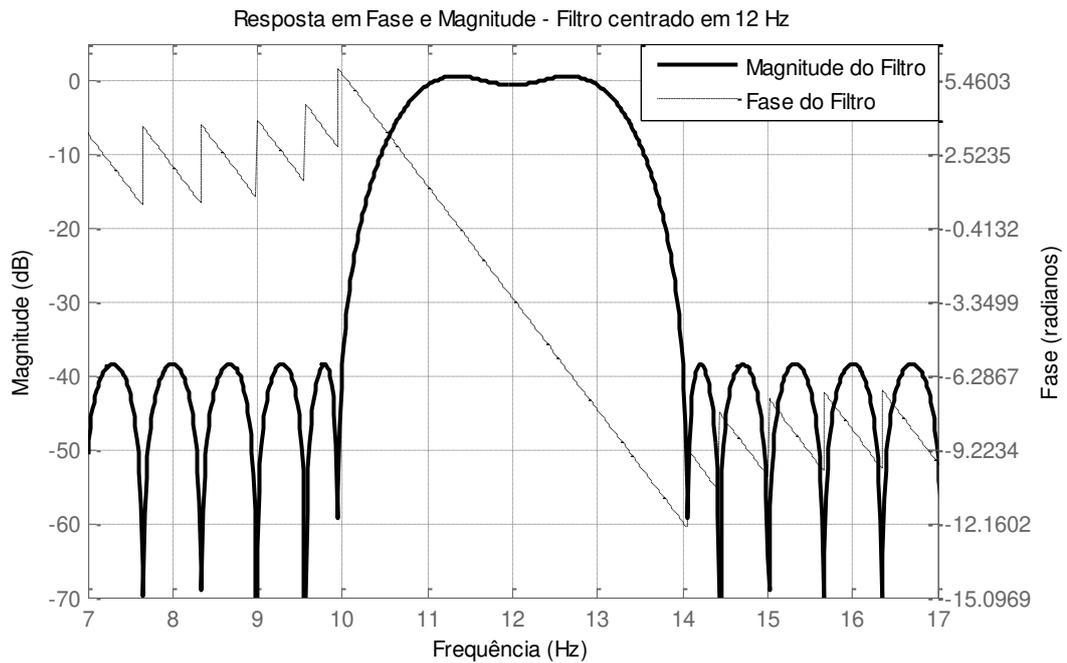


Figura 4.10 – Técnicas de processamento de sinais comparadas.

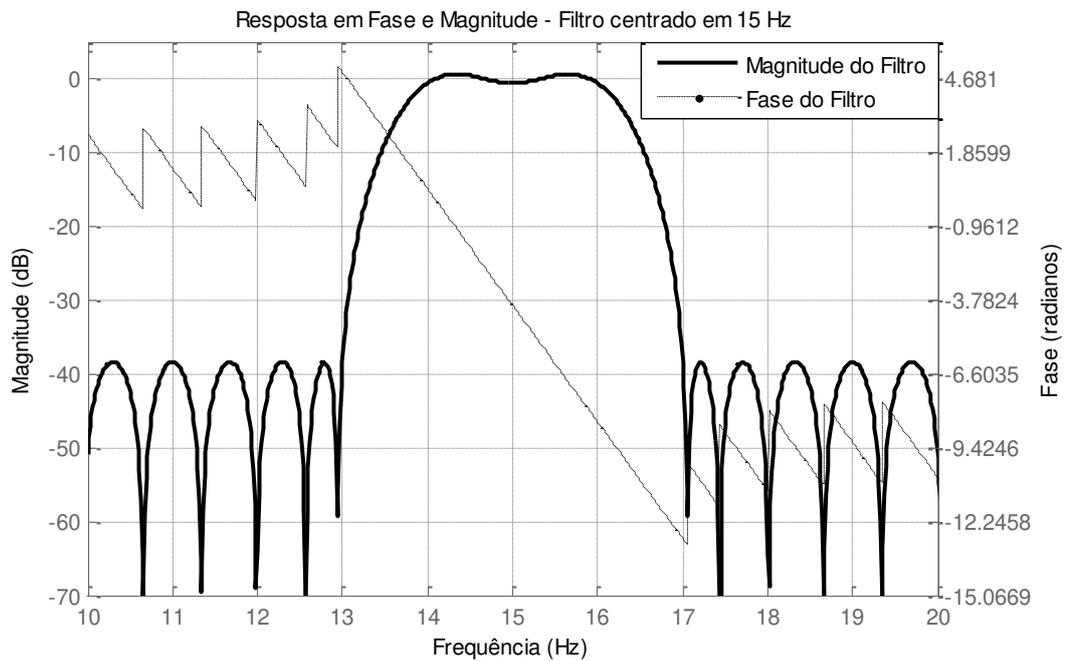
O banco de filtros consistia de dois filtros passa banda *equiripple*, cada um deles centrado em torno de uma frequência evocada (12 e 15 Hz), com largura de banda de passagem de 2 Hz, banda de transição de 1 Hz e atenuação de 40 dB fora da faixa de passagem; mais detalhes do projeto podem ser vistos na Figura 4.11. As características extraídas dos sinais foram as potências espectrais resultantes da filtragem. Apesar de a informação de interesse estar contida na magnitude espectral do sinal, tomou-se o cuidado de utilizar filtros do tipo FIR com fase linear.

A técnica de extração via STFT empregou a expressão do espectrograma, conforme apresentado na Seção 3.2.2. Nesta abordagem, as características foram definidas como sendo o valor da energia normalizada do sinal verificado pontualmente em cada uma das frequências evocadas.

A terceira técnica de extração de características estimou a densidade espectral de potência por meio do periodograma modificado de Welch. O sinal de 12 s foi janelado em 3 s com sobreposição de 2 s. Nesta abordagem, a característica foi definida como o valor normalizado da energia espectral contida entre 11,5 Hz -12,5 Hz e 14,5 Hz - 15,5 Hz, considerando o algoritmo de Goertzel.



(a)



(b)

Figura 4.11 – Resposta dos filtros passa-bandas. Faixa de passagem centrada em torno das frequências evocadas (a) 12 Hz e (b) 15 Hz.

As características extraídas por cada metodologia foram selecionadas antes de serem submetidas ao classificador. Para enriquecer a análise comparativa, duas vertentes conceituais de técnicas de seleção de características foram adotadas: filtros e *wrappers* (ver Seção 3.3). Considerou-se também o caso em que não houve seleção de atributos. As

estratégias de filtro empregadas foram: coeficiente de correlação de Pearson (BISHOP, 2006) e clusterização de Davies-Bouldin (DAVIES; BOULDIN, 1979), em ambos os casos, foi realizado um ranqueamento dos melhores eletrodos e analisado o desempenho do sistema com a inclusão progressiva das características até verificar um decréscimo no desempenho do sistema. A técnica de *wrappers* empregou a heurística gulosa incremental, também conhecida como *forward wrapper* (KOHAVI; JOHN, 1997). O critério de parada consistiu na observação de dois decréscimos sucessivos no desempenho do sistema.

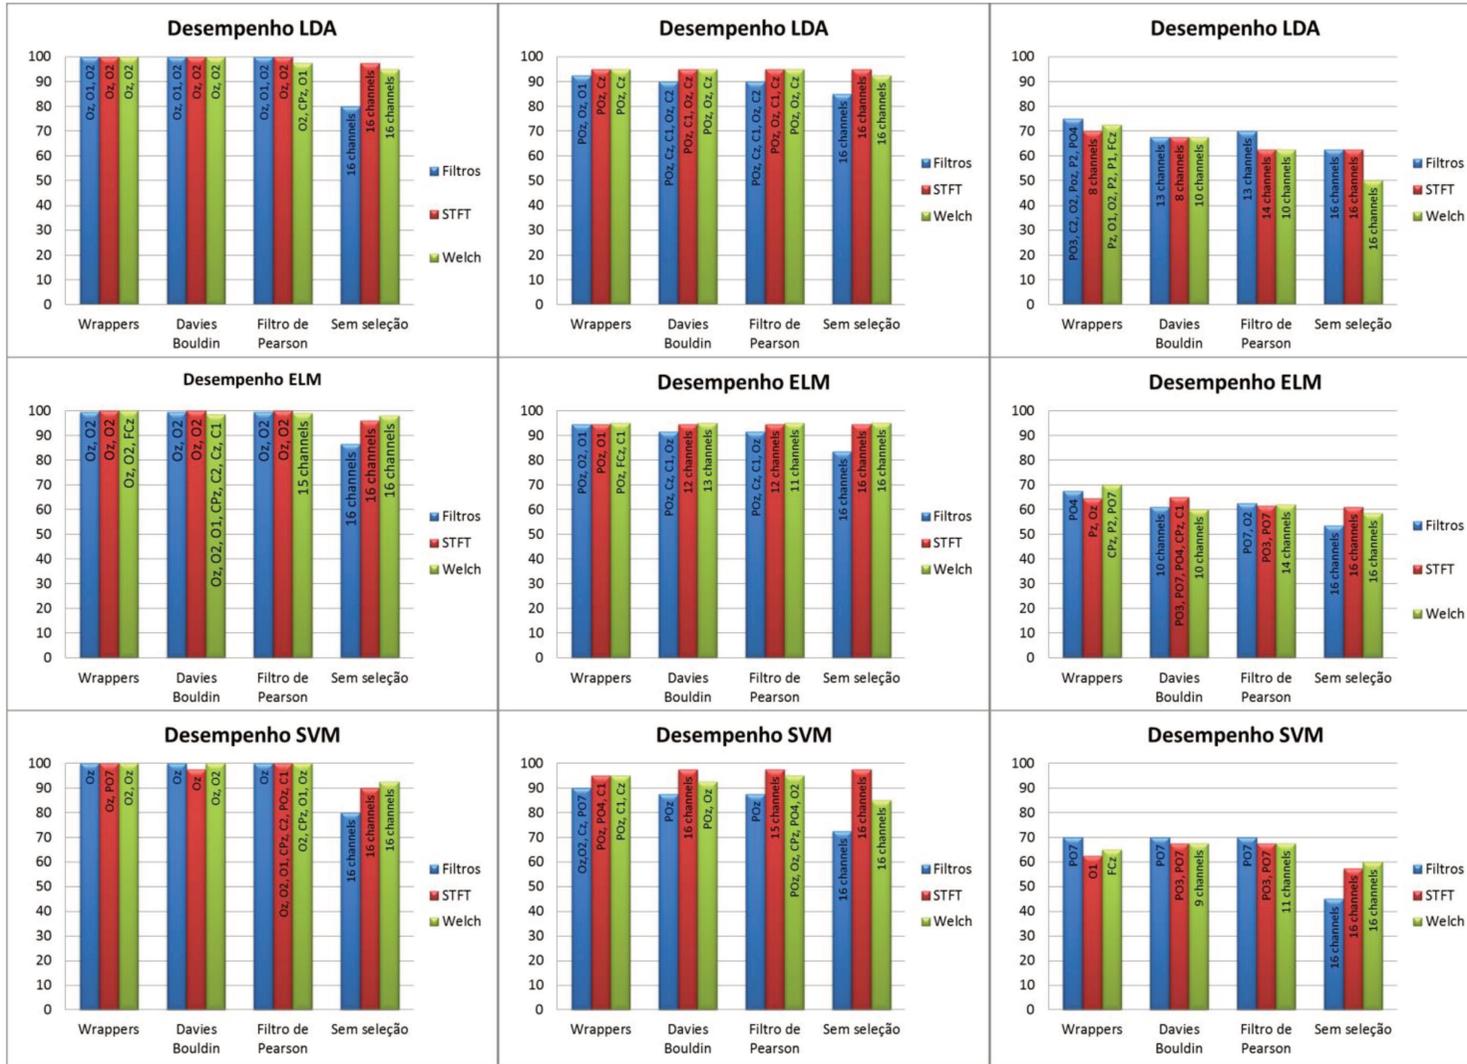
Na etapa de classificação, foram investigadas estruturas de classificação lineares, como o discriminante linear baseado em mínimos quadrados; e não lineares, como ELM e SVM, que apresentam uma maior flexibilidade na definição das fronteiras de separação entre as classes (ver Seção 3.4). O projeto da rede neural ELM utilizou como função de ativação a tangente hiperbólica. Após alguns testes preliminares de validação cruzada, o número de neurônios da camada intermediária foi fixado em 20, sendo seus pesos definidos aleatoriamente seguindo a distribuição Gaussiana. Devido a este comportamento randômico, o desempenho da ELM foi quantificado como a média de 20 realizações para cada indivíduo.

No projeto da SVM, utilizou-se o kernel MLP, pois ele demonstrou maior estabilidade nos testes preliminares realizados. Os parâmetros do kernel foram fixados como  $P_1 = 1$  e  $P_2 = -1$ , resultando na seguinte expressão:

$$k(x, x_i) = \tanh(x_i^T x - 1) \quad (4.1)$$

onde  $x_i$  correspondem aos dados de entrada do conjunto de treinamento. A máquina foi projetada usando as funções *svmtrain* e *svmclassify* do MATLAB<sup>®</sup>.

**Resultados e Discussão:** A Figura 4.12 apresenta o desempenho de três indivíduos em cada um dos 36 cenários e elenca os eletrodos selecionados (o desempenho dos sete voluntários é apresentado no Apêndice A).



(a)

(b)

(c)

Figura 4.12 – Desempenho de voluntários para cada cenário (a) voluntário 2, (b) voluntário 5, (c) voluntário 4.

Em uma primeira consideração, observa-se que, apesar de o ambiente e protocolo da aquisição de dados terem se mantido constantes, houve uma variabilidade de desempenho entre os indivíduos, conforme apresentado na Figura 4.13. A maioria dos indivíduos (5 em 7) alcançou taxa de acerto superior a 90%. A intensidade do potencial evocado está associada a vários fatores, tais como idade, sexo, neurofisiologia e capacidade de concentração (ALLISON et al., 2010), sendo que alguns indivíduos não apresentam resposta VEP adequada para operar uma BCI (ALLISON; NEUPER, 2010). Para voluntários com desempenho menor, observou-se que uma customização do sistema e um adequado mapeamento dos eletrodos são medidas extremamente válidas para melhorar o desempenho do sistema, permitindo um ganho de até 30% (diferença entre a taxa de acerto do melhor caso e do pior caso para o voluntário da Figura 4.12c).

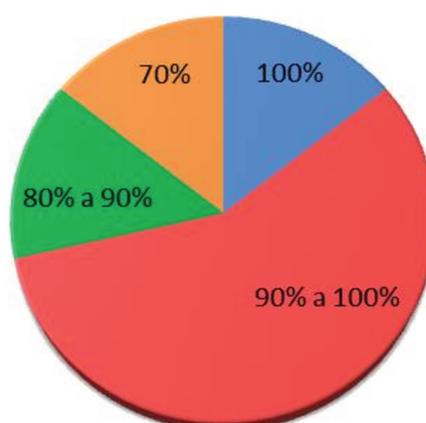


Figura 4.13 – Distribuição da taxa de acerto obtido pelos sete voluntários.

Os desempenhos das três estruturas de classificação, LDA, ELM e SVM, são muito semelhantes ( $p = 0,3992$ , IC = 95%), conforme se observa nas Figuras 4.12 e 4.14. As redes neurais ELM apresentam capacidade de operar com a robustez do classificador linear, provendo um grau de flexibilidade maior na determinação da superfície de separação das classes. O SVM mostrou uma forte dependência da etapa de seleção de atributos, por exemplo, usando todos os eletrodos, o desempenho se reduz em cerca de 8% frente ao obtido com a técnica de seleção *forward wrapper*.

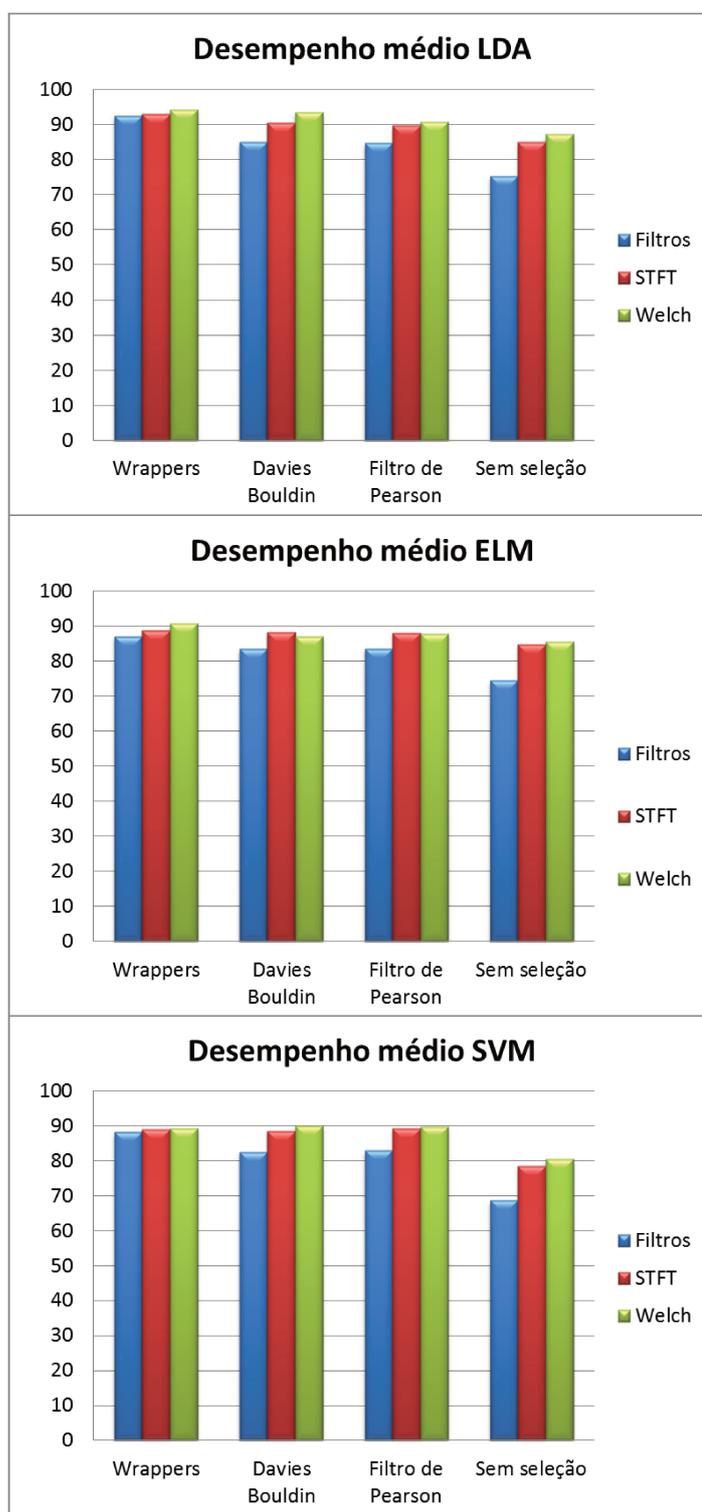


Figura 4.14 – Desempenho médio dos sete indivíduos usando diferentes configurações no módulo de processamento de sinais.

As três técnicas de extração de características avaliadas apresentam comportamento equivalente, embora as extrações por Welch e por STFT pareçam ser mais efetivas do que a extração por banco de filtros ( $p = 0,011$ , IC = 95%). Todavia, para o

voluntário da Figura 4.12(c), cuja resposta VEP é pouco intensa, o melhor desempenho (75%) foi alcançado aplicando banco de filtros aliado ao classificador linear e à técnica de seleção por *wrappers*. Para este mesmo voluntário, a pior configuração, com somente 45% de acerto, foi obtida quando não se operou a seleção de atributos, usando a técnica de banco de filtros e o classificador SVM. Em todos os casos, a seleção das características a serem enviadas ao classificador demonstrou ser relevante para melhorar o desempenho do sistema ( $p = 0,0001$ , IC = 95%), justificando o seu uso no aprimoramento de BCI-SSVEP. As técnicas de filtro avaliadas apresentaram uma taxa de acerto semelhante, considerando o desempenho médio. A técnica de *wrappers* demonstrou um ganho ligeiramente superior, apresentando uma taxa de acerto média cerca de 3% superior às técnicas de filtro usando uma mesma estrutura de classificação.

A Figura 4.12 lista também os eletrodos selecionados em cada cenário para cada voluntário (para a lista completa consultar Figura A.1). Nota-se que a configuração dos melhores canais varia entre os indivíduos e entre as técnicas de processamento adotadas. Para o voluntário apresentado na Figura 4.12(a), que apresenta ótima resposta VEP, geralmente constam somente eletrodos da zona occipital. Em contrapartida, para o indivíduo da Figura 4.12(c), cuja resposta VEP é pouco intensa, os eletrodos mais informativos não são os da zona occipital, mas pertencem a diferentes regiões cerebrais como a parieto-occipital e a zona central. De modo geral, os eletrodos externos à zona occipital tendem a agregar informação ao classificador e auxiliar na diferenciação das classes. Eletrodos da mesma região podem levar a um indesejável viés relacionado à alta correlação de informação entre os sinais. Este fato pode também justificar o melhor desempenho da seleção por *wrappers*, que não considera a quantidade de informação presente nos canais em uma perspectiva de decorrelação, mas leva em conta a estrutura do classificador e o conjunto de características para selecionar os eletrodos que são mais informativos para o sistema. A importância na distribuição dos eletrodos e a relação com a técnica de extração de características não é uma particularidade da abordagem SSVEP, sendo também relatada em (PARK et al., 2013), no contexto de BCIs usando imagética motora.

A aplicação das técnicas de seleção de atributos possibilitou a identificação da contribuição que cada um dos 16 eletrodos fornece. A Figura 4.15 apresenta um ranqueamento dos 16 eletrodos segundo a frequência com a qual eles são selecionados na melhor configuração para cada cenário, considerando os sete indivíduos. Como esperado, os

canais do córtex visual Oz, O1 e O2 são os mais frequentes, aparecendo 14%, 11% e 9%, respectivamente. Na sequência, aparecem os eletrodos PO7 (9%) e Cz (8%), da zona parieto-occipital e do córtex motor, que provavelmente contribuem ao fornecer informações referentes aos movimentos sacádicos dos olhos. Conjuntamente, estes cinco eletrodos aparecem em 51% das configurações, sendo os mais informativos. Os canais Pz, FCz e P2 foram os menos frequentes, o que não significa que eles devem ser desprezados, uma vez que eles fornecem informação útil, principalmente, para indivíduos com baixa resposta VEP, os quais tendem a apresentar uma seleção de eletrodos com posicionamento mais diversificado. Este ranqueamento do grau de informação oriunda de cada eletrodo é valioso para delinear, em um primeiro momento, as melhores posições para a coleta de dados.

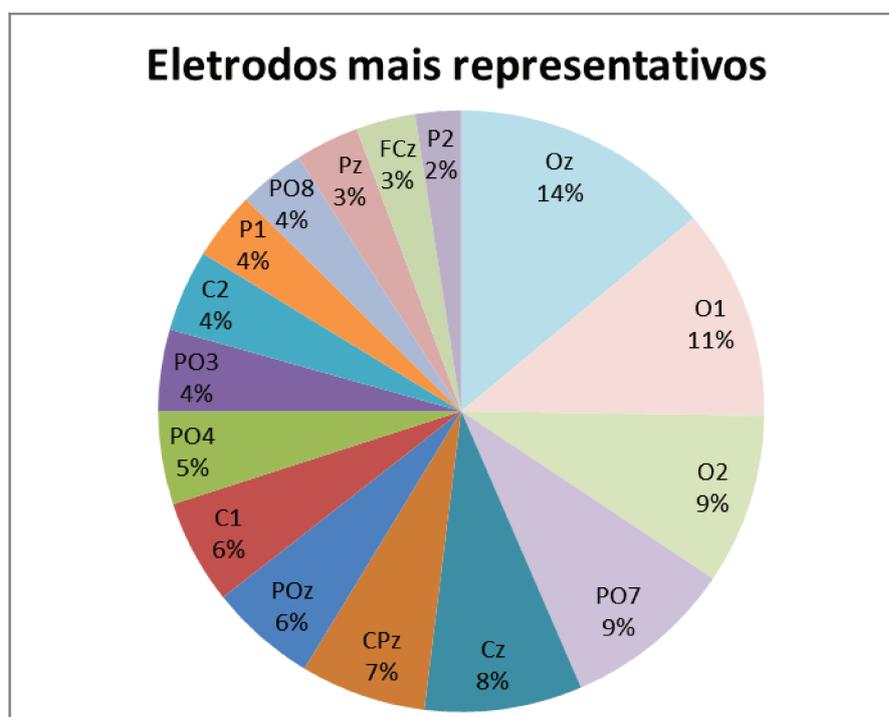


Figura 4.15 – Ordenação dos canais com os melhores atributos para classificação.

**Contribuições e Conclusão:** Os resultados revelaram que, para o problema SSVEP de duas classes, a melhor estrutura de classificação foi o LDA usando o método de Welch para extração de características e o *wrapper* incremental para realizar a seleção de atributos. Esta configuração obteve taxa de acerto em torno de 95%, para os sete indivíduos, atingindo 100% para três deles, o que pode ser considerado, no mínimo, um resultado satisfatório (consultar Apêndice A). As técnicas de extração de características espectrais analisadas – banco de filtros, STFT e Welch – mostraram ser equivalentes. Em particular, o método de Welch e o STFT apresentaram um desempenho semelhante e ligeiramente superior

(aproximadamente 6%) ao alcançado usando bancos de filtros, mas esta diferença está dentro da margem de erro dos indivíduos.

A etapa de seleção de características provou ser extremamente importante, indicando a presença de informação relevante nas zonas parietais, no córtex motor, além do lobo occipital. Em mais de 50 % dos casos, as melhores características eram aquelas extraídas dos sinais coletados pelos eletrodos posicionados nos pontos Oz, O1, O2, PO7 e Cz.

No que concerne os três classificadores testados, os resultados mostram que todos eles podem conceber BCIs-SSVEP eficientes. No entanto, o classificador SVM mostrou-se sensível à estratégia de seleção de atributos, especialmente quando associado com a técnica de extração de características por banco de filtros. A ELM demonstrou-se promissora no contexto de SSVEP e merece ser considerada como parte do repertório de classificadores para sistemas BCI, uma vez que apresenta bom desempenho e capacidade de generalização, podendo ser uma ferramenta útil em problemas com mais classes.

#### **4.3.2 EXPERIMENTO 2: COMPARAÇÃO DE DESEMPENHO DE UMA BCI-SSVEP USANDO TÉCNICAS DE EXTRAÇÃO DE CARACTERÍSTICAS TEMPORAIS E ESPECTRAIS**

**Metodologia:** Este experimento permitiu aprofundar a análise de desempenho de sistemas BCI confrontando o emprego de características extraídas no domínio da frequência – estimativa da densidade espectral de potência de Welch – e do tempo – extração de coeficientes AR pelo método de Burg. O procedimento experimental utilizou os registros cerebrais do voluntário 3 da base DSPCom, considerando as oito sessões de registros EEG realizadas sob estimulação visual nas frequências 6 Hz, 7,5 Hz, 12 Hz, 15 Hz, 20 Hz e 30 Hz. O voluntário fixou a atenção durante 12 s em cada estímulo visual.

A primeira etapa do módulo de processamento de sinais da BCI consistiu na filtragem espacial CAR. Na sequência, os sinais de 12 s foram segmentados em diversos tamanhos de janela para a extração de características pelo método de Burg e de Welch. Cada conjunto de características originou um sistema diferente, 75% dos dados foram usados na etapa de treinamento dos classificadores lineares e 25% foram usados para validação do sistema. Cada classificador foi projetado de maneira a discriminar as classes 6 e 7,5 Hz; 12 e

15 Hz, e 20 e 30 Hz. O desempenho do sistema foi refletido como a taxa de acerto para os dados de validação usando o critério *2-cross fold validation* (THEODORIDIS; KOUTROUMBAS, 2010).

**Resultados e Discussão:** A Tabela 4.5 permite confrontar o desempenho da BCI quando emprega atributos extraídos pelo método de Welch e pelo método de Burg. Os testes foram realizados considerando diversos tamanhos de janelas, com e sem *overlap*. A ordem dos modelos AR foi encontrada por validação cruzada. Na Tabela 4.5 estão apresentados os valores que forneceram melhor taxa de acerto. Em todos os testes foi empregado um classificador linear baseado no método dos mínimos quadrados.

**TABELA 4.5 – DESEMPENHO DO SISTEMA BCI EMPREGANDO ATRIBUTOS EXTRAÍDOS PELOS MÉTODOS DE WELCH E BURG.**

Análise de Desempenho (%) - Classificador Linear									
Método de Extração	Janela (s)	Overlap	Ordem	6 e 7,5 (Hz)	Ordem	12 e 15 (Hz)	Ordem	20 e 30 (Hz)	Média Geral (%)
Welch	1	50%	-	58,7	-	72,8	-	64,7	65,4
	1	0	-	60,4	-	69,8	-	68,8	66,3
Welch	2	50%	-	64,8	-	79,5	-	70,5	71,6
	2	0	-	70,8	-	81,3	-	77,1	76,4
Burg	2	50%	19	63,6	10	61,4	10	65,9	63,6
	2	0	22	64,6	11	64,6	11	66,7	65,3
Welch	3	50%	-	66,1	-	78,6	-	76,8	73,8
	3	0	-	78,1	-	68,8	-	71,9	72,9
Burg	3	50%	18	76,8	25	68,8	23	69,6	71,7
	3	0	27	75,0	27	61,4	22	68,8	68,4
Welch	4	50%	-	82,5	-	92,5	-	85,0	86,7
	4	0	-	75,0	-	95,8	-	66,7	79,2
Burg	4	50%	19	75,0	11	72,5	15	67,5	71,7
	4	0	23	70,8	6	75,0	15	67,5	71,1
Welch	6	50%	-	75,0	-	95,8	-	87,5	86,1
	6	0	-	43,8	-	81,3	-	31,3	52,1
Burg	6	50%	17	79,2	21	83,3	12	79,2	80,6
	6	0	18	75,0	6	75,0	11	75,0	75,0
Welch	12	0	-	75,0	-	87,5	-	100,0	87,5
Burg	12	0	18	87,5	16	75,0	8	87,5	83,3

**Contribuições e Conclusão:** Neste experimento, foi testado o desempenho de uma BCI-SSVEP utilizando uma mesma base de dados de sinais cerebrais, mantendo-se a

etapa de pré-processamento e classificação constantes e testando duas técnicas de extração de características. A primeira analisou o sinal no domínio temporal e empregou como atributos os coeficientes AR extraídos pelo método de Burg, a segunda técnica explorou o conteúdo espectral do sinal, extraindo como atributos a densidade espectral de potência pelo método de Welch. As frequências evocadas foram tratadas aos pares pelo classificador linear, sendo as classes a serem discriminadas: 6 e 7,5 Hz, 12 e 15 Hz e 20 e 30 Hz. É possível ver, na Tabela 4.5, que ambas as técnicas foram capazes de discriminar as classes de maneira satisfatória. Entretanto, o método de Welch apresentou, em geral, um desempenho superior ao método de Burg. Não obstante, observa-se que o método de Welch tende a apresentar um melhor desempenho para discriminar as frequências do par 12 e 15 Hz, para este indivíduo em particular. O método de Burg apresentou uma taxa de acerto de discriminação mais homogênea entre os três grupos de classificação (6 e 7,5 Hz, 12 e 15 Hz e 20 e 30 Hz). Nota-se também que as melhores taxas de acerto para o método de Burg, foram obtidas usando modelos autorregressivos de ordem entre 6 e 27.

Para que esse sistema BCI possa ser utilizado em tempo de execução, é necessário que o intervalo de dados analisado seja curto, de maneira que o usuário possa interagir adequadamente com a aplicação. Todavia, segmentos curtos de sinais tendem a apresentar uma resposta SSVEP pouco expressiva, dificultando o processo de classificação e, conseqüentemente, afetando a robustez do sistema BCI. Vê-se na Tabela 4.5 que janelas maiores de tempo apresentam desempenhos superiores. Neste sentido, considerando o compromisso entre eficiência e confiabilidade, a opção de janelamento mais apropriada a ser utilizada em uma aplicação BCI assistiva, com morosidade mecânica (*e.g.*, controle de uma cadeira de rodas) seria a janela de 4 s, com *overlap* de 50% – que possibilita a geração de comandos a cada 2 s –, e que apresenta taxa de acerto média superior a 85% para o método de Welch e de cerca de 70% para o método de Burg.

### 4.3.3 EXPERIMENTO 3: COMPARAÇÃO DE DESEMPENHO DE SISTEMAS BCI-SSVEP BASEADOS EM ESTÍMULOS VISUAIS CINTILANTES EM DIFERENTES FREQUÊNCIAS – AVALIAÇÃO DE VOLUNTÁRIOS SAUDÁVEIS E PACIENTES QUE SOFRERAM AVC

**Metodologia:** O objetivo deste experimento foi analisar o impacto que os estímulos visuais têm sobre o desempenho e aferir a viabilidade de desenvolver aplicações assistivas de BCI-SSVEP direcionadas a pacientes que sofreram AVC.

A análise utilizou o sinal EEG coletado de dez indivíduos sendo oito voluntários (seis homens e duas mulheres) e dois pacientes que haviam sofrido AVC. A aquisição seguiu o protocolo descrito na Seção 4.3. Para cada indivíduo foram propostos diversos cenários de estimulação usando as frequências 6, 7,5, 12, 15, 20 e 30 Hz. Primeiramente, utilizou-se uma tela de estimulação personalizada contendo as frequências de excitação de melhor resposta para cada indivíduo, considerando dois, quatro e seis estímulos visuais. Em seguida, idealizou-se uma tela de estímulos padrão contendo as frequências de estimulação que na média haviam sido as melhores do grupo de pessoas pesquisado.

Na etapa de pré-processamento do sinal, utilizou-se o método de CAR para a filtragem e remoção dos artefatos. Na sequência, o sinal foi segmentado em janelas de 3 s com sobreposição de 2 s, de modo a permitir a geração de um sinal de comando a cada 1 s, vislumbrando uma operação *online*. De cada janela, estimou-se a densidade espectral de potência usando o método de Welch. As características foram definidas como sendo a soma normalizada da energia espectral contida no intervalo  $\pm 0,02$  Hz em torno de cada frequência evocada. A fim de otimizar o desempenho do sistema, foi empregada a técnica de *forward wrappers* para selecionar os eletrodos com os melhores atributos. Utilizou-se um classificador linear baseado no método dos mínimos quadrados para diferenciar as classes.

**Resultados e Discussão:** O desempenho de cada configuração do sistema foi avaliado para todos os indivíduos. Cada frequência evocada gerou 80 janelas de dados com 3 s cada uma. Os atributos extraídos de cada uma delas foram usados para treinamento (60 janelas de cada frequência) e validação (20 janelas de cada frequência) dos classificadores. As Tabelas 4.6 a 4.8 mostram a taxa de acerto para cada indivíduo quando se usam interfaces de estimulação visual customizadas com 2, 4 ou 6 estímulos, respectivamente.



A comparação das três tabelas mostra que, em geral, o desempenho do sistema diminui com o aumento do número de estímulos visuais, sendo que a cada inclusão de duas novas frequências leva à redução de cerca de 20% na taxa de acerto média. A adição de estímulos implica em uma tarefa de classificação mais complexa e em um desempenho inferior. Todavia, o sistema projetado não atua aleatoriamente, apresentando uma inteligência advinda da etapa de treinamento. Para dois estímulos, têm-se taxa de acerto média inter-indivíduos de 97%, para quatro 77% e, para seis, 57%, enquanto os percentuais de acerto que se obteriam com um classificador aleatório seriam de 50%, 25% e 16%, respectivamente. Uma exceção surpreendente é notada no desempenho apresentado pelo paciente 2, que mantém sua taxa de acerto alta e praticamente inalterada. Apesar da idade e da doença, ele apresenta uma resposta VEP intensa que permite a distinção entre as classes.

Das Tabelas 4.6-4.8 também se observa que o cenário de estimulação personalizado não possui sempre as mesmas frequências de excitação. Por exemplo, para o voluntário 4, o estímulo de 12 Hz é indistinguível na configuração de seis estímulos, mas é distinguível do estímulo de 30 Hz com taxa de acerto de 95%, no cenário com dois estímulos. Em geral, o conjunto das melhores frequências varia entre os indivíduos e entre as configurações experimentais. Na média, os estímulos que permitiram uma melhor distinção entre as classes, considerando os indivíduos analisados, foram aqueles nas frequências: 6, 7,5, 15 e 20 Hz, para uma configuração com 4 estímulos, e 6 e 7,5 Hz para um cenário com dois estímulos. Quando a interface de estímulos visuais é padronizada empregando os estímulos mais frequentes, o desempenho médio do sistema cai de 77% para 71,4% para o problema de quatro classes e de 97% para 90,8% no caso de duas classes, como mostram as Tabelas 4.9 e 4.10.

É importante ressaltar que o objetivo deste experimento não foi comparar o desempenho dos indivíduos entre si, nem o de voluntários saudáveis com pacientes, mas sim verificar se as técnicas que estavam sendo empregadas com êxito nos sinais de voluntários saudáveis seriam úteis em sinais cerebrais de pacientes, neste contexto o valor médio indicado nas Tabelas de 4.6-4-10 serve para comparar o desempenho geral obtido pelos mesmos indivíduos em diferentes condições.

TABELA 4.9 – DESEMPENHO COM 2 ESTÍMULOS VISUAIS E INTERFACE DE ESTÍMULOS PADRÃO.

	Taxa de Acerto (%) - 2 Frequências		Média
	6 Hz	7,5 Hz	
<b>Paciente 1</b>	65	85	75,0
<b>Paciente 2</b>	100	100	100
<b>Voluntário 1</b>	90	75	82,5
<b>Voluntário 2</b>	100	100	100
<b>Voluntário 3</b>	100	100	100
<b>Voluntário 4</b>	95	95	95,0
<b>Voluntário 5</b>	95	100	97,5
<b>Voluntário 6</b>	95	100	97,5
<b>Voluntário 7</b>	80	55	67,5
<b>Voluntário 8</b>	85	100	92,5
			<b>90,8</b>

TABELA 4.10 – DESEMPENHO COM 4 ESTÍMULOS VISUAIS E INTERFACE DE ESTÍMULOS PADRÃO.

	Taxa de Acerto (%) - 4 Frequências				Média
	6 Hz	7,5 Hz	15 Hz	20 Hz	
<b>Paciente 1</b>	25	55	35	70	46,3
<b>Paciente 2</b>	100	100	95	100	98,8
<b>Voluntário 1</b>	80	35	65	70	62,5
<b>Voluntário 2</b>	95	70	75	85	81,3
<b>Voluntário 3</b>	90	55	80	60	71,3
<b>Voluntário 4</b>	55	90	20	70	58,8
<b>Voluntário 5</b>	90	85	90	75	85,0
<b>Voluntário 6</b>	70	50	90	55	66,3
<b>Voluntário 7</b>	80	40	70	35	56,3
<b>Voluntário 8</b>	85	90	85	90	87,5
					<b>71,4</b>

**Contribuições e Conclusão:** Embora o número de pacientes avaliados tenha sido reduzido, esta primeira análise sugere que as técnicas utilizadas no processamento dos sinais cerebrais dos voluntários saudáveis para a concepção de sistemas BCIs-SSVEP podem ser empregadas com êxito nos sinais cerebrais de indivíduos que sofreram AVC. Particularmente, o paciente 2, portador de limitações motoras, apresenta um excelente desempenho, o que encoraja o prosseguimento de projetos com escopo assistivo.

Como cada indivíduo responde melhor a um conjunto de frequências diferente, recomenda-se, a fim de otimizar o desempenho da BCI, o levantamento dos estímulos mais diferenciáveis para determinado usuário. Nos testes, a interface de estímulos customizada apresentou um desempenho cerca de 6% superior ao da interface de estímulos padrão, para

ambos os casos de 2 e 4 estímulos.

A taxa de acerto do sistema com mais de 4 estímulos precisa ser aprimorada para aplicações reais. Um modo seria inserir códigos corretores de erro entre a saída do classificador e o gerador de comandos para a aplicação ou aumentar as janelas temporais de análise dos dados; ambas as soluções levariam a uma redução da taxa de transmissão. Outra abordagem poderia ser investir em uma etapa de pré-processamento mais aprimorada, de modo a elevar a relação sinal-ruído e obter maiores taxas de acerto.

#### **4.3.4 EXPERIMENTO 4: COMPARAÇÃO DE DIFERENTES METODOLOGIAS DE FILTRAGEM ESPACIAL PARA REMOÇÃO DE ARTEFATOS DE SINAIS SSVEP**

**Metodologia:** A etapa de pré-processamento exerce um papel crucial sobre o desempenho final de sistemas BCIs. Em sistemas que devem operar de maneira *online*, é necessário que o pré-processamento atue em janelas estreitas de sinal, e seja capaz de melhorar a relação sinal ruído de forma eficiente, retirando os diversos artefatos presentes no EEG, tais como movimentação muscular, ruídos de fontes externas e interferências eletromagnéticas. Neste experimento, os testes foram realizados utilizando registros EEG do voluntário 1 da base DSPCom, empregando 120 segmentos na etapa de treinamento e 40 na etapa de validação. A taxa de acerto, considerando o conjunto de dados de validação, do classificador linear, ajustado por meio do método dos mínimos quadrados, foi definida como o critério de desempenho do sistema. A estimulação visual foi feita utilizando um padrão xadrez cintilante nas frequências de 12 e 15 Hz. O indivíduo foi exposto a cada estímulo durante 12 s em oito repetições.

O objetivo deste experimento foi comparar o desempenho do sistema BCI aplicando diferentes técnicas de filtragem espacial a uma mesma base de dados SSVEP. Foram testadas as técnicas CAR, MEC e MCC (ver Seção 3.1). Os filtros MEC e MCC permitem modelar o sinal considerando as harmônicas. Assim, nas configurações usando MCC e MEC, o sinal foi abordado de três diferentes maneiras. Na primeira, o sinal foi modelado considerando somente a frequência fundamental, de 12 Hz ou 15 Hz. A segunda abordagem considerou o primeiro harmônico no modelo do sinal, ou seja, as frequências em 12 Hz e 24 Hz para o sinal evocado em 12 Hz e de 15 Hz e 30 Hz para o sinal evocado em 15 Hz. A terceira abordagem considerou o primeiro e segundo harmônicos do sinal, modelando o

sinal evocado em 12 Hz com as frequências em 12, 24 e 36 Hz e o sinal evocado em 15 Hz com as frequências 15, 30 e 45 Hz. A determinação do número de canais no MEC foi fixado em oito, garantindo que ao menos 90% da energia do ruído fosse eliminada. Já para o MCC, o número de canais foi fixado em doze, garantindo que a energia SSVEP fosse ao menos 20% maior que a energia do sinal restante. No total foram analisados quatorze diferentes cenários: (1) CAR, (2) MEC com o primeiro harmônico, (3) MCC com o primeiro harmônico, (4) CAR seguido de MEC com o primeiro harmônico, (5) CAR seguido de MCC com o primeiro harmônico, (6) MEC com dois harmônicos, (7) MCC com dois harmônicos, (8) CAR seguido de MEC com dois harmônicos, (9) CAR seguido de MCC com dois harmônicos, (10) MEC com três harmônicos, (11) MCC com três harmônicos, (12) CAR seguido de MEC com três harmônicos, (13) CAR seguido de MCC com três harmônicos e (14) sem filtragem.

Após a etapa de pré-processamento, foram extraídos os atributos pela técnica de Welch. O método de Welch estimou a densidade espectral de potência por meio da FFT considerando a faixa de 1 Hz em torno das frequências evocadas, 12 e 15 Hz. Utilizou-se um janelamento de 3 s com sobreposição de 2 s, de modo a permitir o emprego das técnicas em operações *online*. Analisou-se também a efetividade da seleção de atributos agregada ao sistema, comparando a técnica de *wrapper* com o caso em que não há seleção.

**Resultados e Discussão:** A Tabela 4.11 apresenta o desempenho da BCI-SSVEP para cada um dos cenários de pré-processamento implementados, considerando o sistema com e sem seleção de atributos pela técnica de *wrapper* incremental. Observa-se que o melhor desempenho (95%) foi obtido utilizando a técnica de filtragem CAR, para ambos os casos, com e sem seleção de atributos. É notável que a aplicação da técnica de seleção de canais resultou sempre num ganho de desempenho do sistema, chegando a uma melhora de 22,5% no caso sem filtragem.

TABELA 4.11 – DESEMPENHO DO SISTEMA APLICANDO DIFERENTES TÉCNICAS DE FILTRAGEM ESPACIAL.

Técnica	Desempenho do Classificador	
	Sem Seleção de Atributos (%)	Com Seleção de Atributos (%)
SEM FILTRAGEM	57,5	80,0
CAR	90,0	95,0
MCC_1 Harmônico	77,5	92,5
MEC_1 Harmônico	70,0	80,0
CAR+MCC_1 Harmônico	77,5	85,0
CAR+MEC_1 Harmônico	82,5	85,0
MCC_2 Harmônicos	65,0	77,5
MEC_2 Harmônicos	82,5	85,0
CAR+MCC_2 Harmônicos	90,0	92,5
CAR+MEC_2 Harmônicos	80,0	85,0
MCC_3 Harmônicos	65,0	85,0
MEC_3 Harmônicos	82,5	85,0
CAR+MCC_3 Harmônicos	82,5	90,0
CAR+MEC_3 Harmônicos	82,5	85,0

**Contribuições e Conclusão:** Os resultados corroboram a importância da filtragem dos sinais cerebrais e seleção de características para um melhor desempenho dos sistemas BCI sendo que, na ausência desses, o sistema trabalha quase como que um sistema aleatório, apresentando taxa de acerto de 57,5%. A seleção de atributos se mostrou extremamente válida, apresentando ganho em todos os cenários. Neste experimento, a técnica de filtragem espacial mais eficiente foi a CAR seguida de seleção de atributos por *wrappers*, taxa de acerto de 95%. Observou-se pouca diferença no desempenho do sistema com a inclusão de harmônicos nos modelos de filtragem via MEC e MCC. Além disso, a inclusão de harmônicas no modelo reduz o número de estímulos disponíveis para serem projetados em um monitor com taxa de *refresh* de 60 Hz, dificultando, por exemplo, trabalhar concomitantemente com evocações nas frequências de 7,5 Hz, 15 Hz e 30 Hz.

#### 4.4 CONSIDERAÇÕES FINAIS

Neste Capítulo, foram relatados os diversos experimentos realizados visando a determinação do conjunto de técnicas que permitem a execução de aplicações em tempo de execução de uma BCI baseada em SSVEP.

A análise comparativa de diferentes técnicas de processamento de sinal aplicadas nas etapas de extração de características, seleção de atributos e classificação fornecem um arcabouço precioso para o desenvolvimento de sistemas BCI, indicando quais técnicas devem ser empregadas para se obter um desempenho adequado em aplicações que funcionem em tempo de execução.

Dentre as técnicas de filtragem espacial – CAR, MEC e MCC – aplicadas na etapa de pré-processamento, conforme descrito em especial na Seção 4.3.4, observa-se que o filtro CAR foi o mais robusto, juntamente com a técnica de CAR combinada com MCC usando um modelo de dois harmônicos.

Com relação à extração de características, os modelos de extração de características no domínio do tempo e da frequência apresentaram resultados satisfatórios, sendo que o modelo de extração espectral pelo método de Welch mostrou-se um pouco superior ao método de Burg (ver Tabela 4.5). Entretanto, a extração dos coeficientes autorregressivos, pelo método de Burg, mostrou-se promissora para ser empregada em problemas nos quais não se conhece, a priori, a frequência na qual o estímulo se manifesta como no paradigma de imagética. Dentre o repertório de técnicas de extração de atributos no domínio espectral, observou-se que STFT e o Método de Welch apresentaram desempenhos semelhantes e ligeiramente superiores ao do banco de filtro. É interessante notar que a técnica STFT extrai o valor de maneira pontual na frequência de interesse sendo a mais rápida entre as testadas. O método de Welch calcula a PSD em uma janela estreita, de 0,2 a 1 Hz, centrada na frequência de interesse, permitindo se obter informações de evocações não bem representadas na exata frequência evocada. Por sua vez, o filtro calcula a energia do sinal em uma janela ainda mais extensa, de 1 a 2 Hz, em torno da frequência de interesse e, provavelmente, ao abranger mais frequências na estimativa da PSD, engloba uma maior interferência do ruído, prejudicando o conteúdo informativo das características e consequentemente, o desempenho do sistema de um modo geral. Além disso, o fato de a faixa de análise ser mais ampla acaba degradando o desempenho do banco de filtros quando se precisa operar com frequências vizinhas, como 6 e 7,5 Hz. No que concerne às técnicas de seleção de atributos, foram testadas as duas vertentes conceituais: filtros – coeficiente de correlação de Pearson e índice de Davies-Bouldin – e *wrapper*, seguindo a heurística gulosa de *forward wrapper*. As três abordagens trouxeram ganho de desempenho ao sistema BCI, em comparação com o caso sem seleção de atributos. A técnica de *wrapper* é

computacionalmente mais custosa, entretanto fornece o melhor desempenho, uma vez que combina os atributos ao esquema de classificação utilizado. As técnicas de filtros apresentaram desempenho equivalente e são rápidas de serem operadas, permitindo testes que visem, por exemplo, a definição das melhores posições a serem colocados os eletrodos.

Todas as estruturas de classificação testadas, tanto lineares como não lineares, foram capazes de discriminar as classes, até mesmo no caso de seis estímulos diferentes, conforme descrito na Seção 4.3.3. Além das estratégias tradicionais de classificação (discriminante linear e SVM), foi avaliada a técnica não linear ELM, ainda não empregada na abordagem de BCI-SSVEP, a qual se mostrou adequada, apresentando bom desempenho e capacidade de generalização.

Em síntese, o melhor arranjo de técnicas, dentre as testadas, foi a BCI implementada com:

- Pré-processamento: CAR;
- Extração de Características: Cálculo da densidade espectral de potência pelo método de Welch;
- Seleção de Características: *wrapper* incremental;
- Classificador: Função discriminante linear baseada no método dos mínimos quadrados.

Conforme relatado na literatura médica, constatou-se que os sinais oriundos da região occipital fornecem bons atributos sobre o estímulo visual no qual o indivíduo está concentrado. Entretanto, os sinais registrados na região parieto-occipital, parietal e central também contribuem com informações relevantes para o preditor, melhorando a sua taxa de acerto. Em particular, para indivíduos com baixa resposta VEP, as características advindas dos eletrodos posicionados fora do lobo occipital tendem a melhorar o desempenho da BCI-SSVEP.

Apesar de preliminares, os resultados observados nos sinais cerebrais de pacientes que sofreram AVC foram animadores, corroborando a factibilidade da implementação de sistemas BCI-SSVEP. Os testes realizados levam a um sentimento de que o desempenho dos pacientes tende a ser semelhante ao dos voluntários saudáveis, não obstante a diferença de idade (idade média de 69 anos para paciente *versus* de 26 anos para voluntários) e a lesão cerebral.

Os testes também revelaram que cada indivíduo responde melhor a um conjunto de estímulos e que o emprego de uma interface customizada agrega cerca de 6% à taxa de acerto do sistema que emprega uma interface padrão.

Os resultados permitem compreender como cada etapa do processamento de sinais afeta o desempenho da BCI e harmonizar as melhores técnicas, arranjo de eletrodos e interface de estímulos visuais. Além disso, os testes foram realizados usando janelas temporais que simulassem um processamento em tempo de execução. O desempenho apresentado pelo sistema permite vislumbrar a factibilidade da construção de sistemas BCI-SSVEP robustos e eficientes.

## 5. PROPOSTA DE FILTRAGEM ESPAÇO-TEMPORAL

A resposta sem distorção de mínima variância (MVDR) é uma abordagem de estimação espectral não paramétrica, frequentemente empregada em problemas de processamento em arrays de antenas. O MVDR modela a formação de feixes adaptativamente, procurando cancelar os interferentes e direcionar os feixes alvo a serem mantidos (BENESTY; CHEN; HUANG, 2005). Trata-se de uma técnica de alta resolução, na qual o espectro do sinal pode ser entendido como a saída de um banco de filtros, sendo cada filtro centrado em uma das frequências de análise. A principal diferença com relação à abordagem por periodogramas é que os filtros de banda passante dependem tanto dos dados quanto das frequências de interesse (HAYKIN, 2008).

Utilizando a capacidade do MVDR de aliar a informação de frequências evocadas de maneira dependente dos dados de entrada e do posicionamento dos eletrodos, propõe-se aqui uma técnica de filtragem objetivando o cancelamento dos interferentes do sinal. O filtro espaço-temporal proposto será denominado no texto de Filtro MVDR.

Inicialmente, considere o exemplo mostrado na Figura 5.1, no qual se tem sinais provenientes de dois eletrodos  $x_1(n)$  e  $x_2(n)$ . Deseja-se combinar estes sinais em um único sinal de saída  $y(n)$ , de modo que o conteúdo espectral presente na frequência de interesse  $\omega_0$  seja preservado e o conteúdo espectral nas demais frequências atenuado.

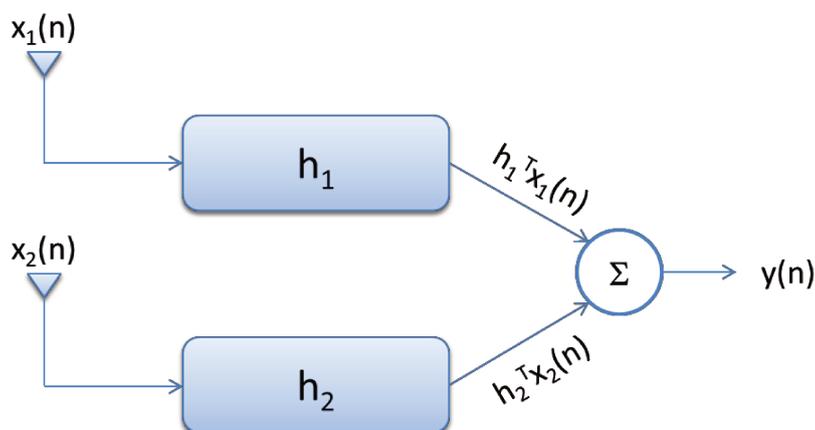


Figura 5.1 – Diagrama do filtro MVDR combinando duas entradas e selecionando uma única frequência de interesse.

É razoável supor, como apresentado no Capítulo 2, que a resposta SSVEP possa ser modelada por uma senoide oscilante na frequência evocada visualmente, de modo que os sinais cerebrais podem ser modelados como duas ondas senoidais oscilantes na frequência  $\omega_0$  e com fases arbitrárias  $\theta$  e  $\varphi$ :

$$x_1(n) = A \cos(\omega_0 n + \theta) \quad (5.1)$$

$$x_2(n) = B \cos(\omega_0 n + \varphi) \quad (5.2)$$

assim, o vetor de entrada é dado por:

$$\mathbf{x}^T(n) = [x_1(n) \ x_1(n-1) \ x_1(n-2) \ \dots \ x_2(n) \ x_2(n-1) \ x_2(n-2) \ \dots] \quad (5.3)$$

onde  $T$  denota a transposição do vetor.

O filtro  $\mathbf{h}$  pode ser visto como uma composição dos filtros de cada entrada  $\mathbf{h}_1$  e  $\mathbf{h}_2$ :

$$\mathbf{h}^T = [\mathbf{h}_1 \ \mathbf{h}_2] \quad (5.4)$$

ou de forma mais explícita, especificando os coeficientes:

$$\mathbf{h}^T = [h_{10} \ h_{11} \ h_{12} \ \dots \ h_{20} \ h_{21} \ h_{22} \ \dots] \quad (5.5)$$

assim, o sinal de saída  $y(n)$  é dado por:

$$y(n) = y_1(n) + y_2(n) = \mathbf{h}^T \mathbf{x}(n) \quad (5.6)$$

O sinal de saída do primeiro filtro é:

$$\begin{aligned} y_1(n) &= \mathbf{h}_1^T \mathbf{x}_1(n) = [h_{10} \ h_{11} \ h_{12} \ \dots] x_1(n) \\ y_1(n) &= h_{10} A \cos(\omega_0 n + \theta) + h_{11} A \cos(\omega_0(n-1) + \theta) \\ &\quad + h_{12} A \cos(\omega_0(n-2) + \theta) + \dots \end{aligned} \quad (5.7)$$

Utilizando as propriedades trigonométricas:

$$\begin{aligned}
y_1(n) &= h_{10} A \cos(\omega_0 n + \theta) \\
&\quad + h_{11} [A \cos(\omega_0 n + \theta) \cos(-\omega_0) \\
&\quad - A \sin(\omega_0 n + \theta) \sin(-\omega_0)] \\
&\quad + h_{12} [A \cos(\omega_0 n + \theta) \cos(-2\omega_0) \\
&\quad - A \sin(\omega_0 n + \theta) \sin(-2\omega_0)] + \dots
\end{aligned} \tag{5.8}$$

É importante ressaltar, que as frequências múltiplas dentro dos cossenos e senos não definem harmônicas do sinal SSVEP modelado, mas surgem das amostras atrasadas do modelo. Rearranjando os termos, têm-se:

$$\begin{aligned}
y_1(n) &= A \cos(\omega_0 n + \theta) (h_{10} + h_{11} \cos(-\omega_0) + h_{12} \cos(-2\omega_0) + \dots) \\
&\quad - A \sin(\omega_0 n + \theta) (h_{11} \sin(-\omega_0) + h_{12} \sin(-2\omega_0) + \dots)
\end{aligned} \tag{5.9}$$

Realizando um procedimento análogo, para o sinal de entrada  $x_2(n)$ , têm-se:

$$\begin{aligned}
y_2(n) &= A \cos(\omega_0 n + \varphi) (h_{20} + h_{21} \cos(-\omega_0) + h_{22} \cos(-2\omega_0) + \dots) \\
&\quad - A \sin(\omega_0 n + \varphi) (h_{21} \sin(-\omega_0) + h_{22} \sin(-2\omega_0) + \dots)
\end{aligned} \tag{5.10}$$

O objetivo do filtro é manter a potência espectral referente à resposta SSVEP e minimizar a potência nas demais bandas de frequência. A potência do sinal filtrado  $y(n)$  pode ser calculada como:

$$\begin{aligned}
J_{pot} &= E[y^2(n)] \\
&= E[(\mathbf{h}^T \mathbf{x}(n))(\mathbf{x}^T(n) \mathbf{h})] \\
&= \mathbf{h}^T E[\mathbf{x}(n) \mathbf{x}^T(n)] \mathbf{h} \\
J_{pot} &= \mathbf{h}^T \mathbf{R} \mathbf{h}
\end{aligned} \tag{5.11}$$

aonde  $E(\cdot)$  é o operador esperança e  $\mathbf{R}$  é a matriz de covariância dos sinais de entrada. Desta forma, é necessário observar as seguintes condições:

Para a entrada  $\mathbf{x}_1(n)$ :

$$\begin{cases} h_{10} + h_{11} \cos(\omega_0) + h_{12} \cos(2\omega_0) + \dots = 1 \\ h_{11} \sin(-\omega_0) + h_{12} \sin(-2\omega_0) + \dots = 0 \end{cases} \tag{5.12}$$

e para a entrada  $\mathbf{x}_2(n)$ :

$$\begin{cases} h_{20} + h_{21} \cos(\omega_0) + h_{22} \cos(2\omega_0) + \dots = 1 \\ h_{21} \text{sen}(-\omega_0) + h_{22} \text{sen}(-2\omega_0) + \dots = 0 \end{cases} \quad (5.13)$$

Para simplificar a notação, definem-se os vetores de coeficientes de cossenos e senos:

$$\mathbf{C}_1 = \begin{bmatrix} 1 \\ \cos(\omega_0) \\ \cos(2\omega_0) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \quad \mathbf{S}_1 = \begin{bmatrix} 0 \\ \text{sen}(\omega_0) \\ \text{sen}(2\omega_0) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \quad (5.14)$$

$$\mathbf{C}_2 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \cos(\omega_0) \\ \cos(2\omega_0) \\ \vdots \end{bmatrix} \quad \mathbf{S}_2 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ \text{sen}(\omega_0) \\ \text{sen}(2\omega_0) \\ \vdots \end{bmatrix} \quad (5.15)$$

É possível escrever as expressões (5.12) e (5.13) de maneira sucinta em notação matricial:

$$\begin{aligned} \mathbf{h}^T \mathbf{C}_1 &= 1 & \mathbf{h}^T \mathbf{S}_1 &= 0 \\ \mathbf{h}^T \mathbf{C}_2 &= 1 & \mathbf{h}^T \mathbf{S}_2 &= 0 \end{aligned} \quad (5.16)$$

Destas condições emerge naturalmente um problema de otimização com as quatro restrições expressas em (5.16), visto que se tem dois sinais de entrada e uma frequência de SSVEP. A solução deste problema pode ser encontrada calculando-se o lagrangiano:

$$\nabla L(\lambda) = 2\mathbf{R}\mathbf{h} - \lambda_1 \mathbf{C}_1 - \lambda_2 \mathbf{S}_1 - \lambda_3 \mathbf{C}_2 - \lambda_4 \mathbf{S}_2 = 0 \quad (5.17)$$

onde  $\lambda$  são os coeficientes de Lagrange. Isolando o vetor dos coeficientes do filtro, tem-se:

$$\mathbf{h} = \frac{\lambda_1}{2} \mathbf{R}^{-1} \mathbf{C}_1 + \frac{\lambda_2}{2} \mathbf{R}^{-1} \mathbf{S}_1 + \frac{\lambda_3}{2} \mathbf{R}^{-1} \mathbf{C}_2 + \frac{\lambda_4}{2} \mathbf{R}^{-1} \mathbf{S}_2 \quad (5.18)$$

Para se determinar os multiplicadores de Lagrange, pode-se substituir (5.18) nas

restrições (5.16), obtendo-se:

$$\begin{aligned}
 h^T C_1 &= \frac{\lambda_1}{2} C_1^T R^{-1} C_1 + \frac{\lambda_2}{2} S_1^T R^{-1} C_1 + \frac{\lambda_3}{2} C_2^T R^{-1} C_1 + \frac{\lambda_4}{2} S_2^T R^{-1} C_1 = 1 \\
 h^T S_1 &= \frac{\lambda_1}{2} C_1^T R^{-1} S_1 + \frac{\lambda_2}{2} S_1^T R^{-1} S_1 + \frac{\lambda_3}{2} C_2^T R^{-1} S_1 + \frac{\lambda_4}{2} S_2^T R^{-1} S_1 = 0 \\
 h^T C_2 &= \frac{\lambda_1}{2} C_1^T R^{-1} C_2 + \frac{\lambda_2}{2} S_1^T R^{-1} C_2 + \frac{\lambda_3}{2} C_2^T R^{-1} C_2 + \frac{\lambda_4}{2} S_2^T R^{-1} C_2 = 1 \\
 h^T S_2 &= \frac{\lambda_1}{2} C_1^T R^{-1} S_2 + \frac{\lambda_2}{2} S_1^T R^{-1} S_2 + \frac{\lambda_3}{2} C_2^T R^{-1} S_2 + \frac{\lambda_4}{2} S_2^T R^{-1} S_2 = 0
 \end{aligned} \tag{5.19}$$

Escrevendo de maneira simplificada em notação matricial:

$$\begin{bmatrix} \frac{C_1^T R^{-1} C_1}{2} & \frac{S_1^T R^{-1} C_1}{2} & \frac{C_2^T R^{-1} C_1}{2} & \frac{S_2^T R^{-1} C_1}{2} \\ \frac{C_1^T R^{-1} S_1}{2} & \frac{S_1^T R^{-1} S_1}{2} & \frac{C_2^T R^{-1} S_1}{2} & \frac{S_2^T R^{-1} S_1}{2} \\ \frac{C_1^T R^{-1} C_2}{2} & \frac{S_1^T R^{-1} C_2}{2} & \frac{C_2^T R^{-1} C_2}{2} & \frac{S_2^T R^{-1} C_2}{2} \\ \frac{C_1^T R^{-1} S_2}{2} & \frac{S_1^T R^{-1} S_2}{2} & \frac{C_2^T R^{-1} S_2}{2} & \frac{S_2^T R^{-1} S_2}{2} \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \lambda_4 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \end{bmatrix} \tag{5.20}$$

sendo:

$$\Lambda = \begin{bmatrix} \frac{C_1^T R^{-1} C_1}{2} & \frac{S_1^T R^{-1} C_1}{2} & \frac{C_2^T R^{-1} C_1}{2} & \frac{S_2^T R^{-1} C_1}{2} \\ \frac{C_1^T R^{-1} S_1}{2} & \frac{S_1^T R^{-1} S_1}{2} & \frac{C_2^T R^{-1} S_1}{2} & \frac{S_2^T R^{-1} S_1}{2} \\ \frac{C_1^T R^{-1} C_2}{2} & \frac{S_1^T R^{-1} C_2}{2} & \frac{C_2^T R^{-1} C_2}{2} & \frac{S_2^T R^{-1} C_2}{2} \\ \frac{C_1^T R^{-1} S_2}{2} & \frac{S_1^T R^{-1} S_2}{2} & \frac{C_2^T R^{-1} S_2}{2} & \frac{S_2^T R^{-1} S_2}{2} \end{bmatrix} \tag{5.21}$$

com:

$$\Lambda \lambda = \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \end{bmatrix} \tag{5.22}$$

De modo que o vetor de coeficientes de Lagrange pode ser determinado operando

o cálculo da inversa da matriz de restrições:

$$\boldsymbol{\lambda} = \boldsymbol{\Lambda}^{-1} \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \end{bmatrix} \quad (5.23)$$

E sucessivamente, podem-se encontrar os coeficientes do filtro  $\mathbf{h}_1$  e  $\mathbf{h}_2$  por (5.18). A matriz  $\boldsymbol{\Lambda}$  evidencia que, se existe uma única frequência de interesse, o projeto de todos os filtros se dá de maneira equivalente, mas não idêntica, uma vez que os coeficientes  $\mathbf{C}_1$ ,  $\mathbf{C}_2$ ,  $\mathbf{S}_1$  e  $\mathbf{S}_2$  são análogos, mas a matriz de correlação  $\mathbf{R}$  depende do sinal de entrada.

## 5.1 PROCEDIMENTOS EXPERIMENTAIS

Para avaliar a atuação e a capacidade de eliminação de interferentes do Filtro MVDR foi realizada uma série de testes e simulações visando, especialmente, sua aplicação em sistemas BCI. Os primeiros experimentos empregaram sinais artificiais e, na sequência, foram utilizados registros EEG-SSVEP.

A primeira avaliação combinou dois sinais de entrada senoidais defasados, ambos oscilantes na frequência fundamental de 15 Hz, sendo:

$$x_1(n) = \text{sen}(2\pi 15n) \quad x_2(n) = 0,8\text{sen}\left(2\pi 15n + \frac{\pi}{6}\right).$$

A Figura 5.2 mostra os sinais temporais  $x_1(n)$ ,  $x_2(n)$  e  $y_1(n)$ . É possível ver que a saída do filtro (curva verde) é uma senoide de frequência 15 Hz, com fase intermediária a dos sinais de entrada e amplitude igual à soma da amplitude de  $x_1(n)$  e  $x_2(n)$ . Analisando o espectro de frequência desses sinais, nota-se que a energia espectral do sinal filtrado  $y_1(n)$  é igual à soma da energia das duas senoides que o compõe. Como os sinais de entrada eram senoides puras, o filtro MVDR foi projetado com ordem 1.

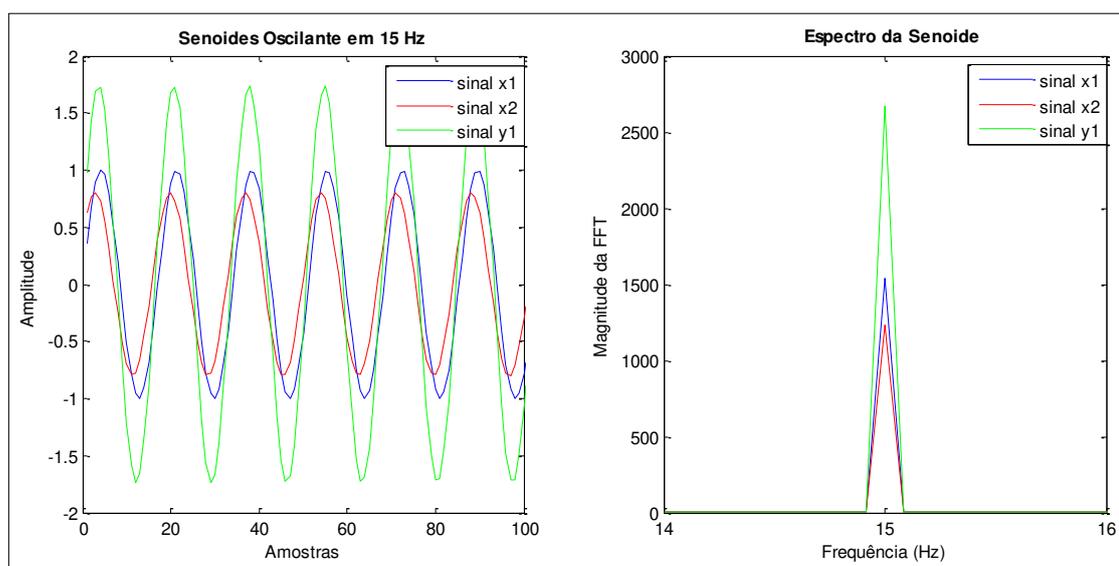


Figura 5.2 – Resultado da filtragem em 15 Hz de duas senoides oscilantes a 15 Hz.

O segundo experimento visou simular um sinal mais complexo e semelhante ao sinal cerebral contendo informação de potencial evocado. Para isto, foram acrescentados ruído impulsivo, visando modelar artefatos como os *blinks*, e gaussiano, gerados de maneira aleatória, às senoides de frequência 15 Hz. Também foi adicionada uma interferência senoidal oscilante em 20 Hz. Cada sinal gerado continha 3072 amostras, equivalente a 12 s quando se usa taxa de amostragem de 256 Hz. O Quadro 5.1 apresenta o código em MATLAB<sup>®</sup> usado para especificar os sinais de entrada.

**Quadro 5.1 – Código de geração dos sinais senoidais com ruído aditivo do tipo impulsivo e gaussiano.**

```

% geração de um sinal de 12 s amostrado a 256 Hz
Fs = 256;
Namostras = Fs*12;

% frequência da senoide representando a resposta SSVEP
w1 = 2*pi*15/Fs;

% frequência da senoide de interferência
w2 = 2*pi*20/Fs;

% gerando ruído impulsivo aleatório
ruído_impulsivo = (randn(1,Namostras)).^5;
ruído_impulsivo = ruído_impulsivo /sqrt(mean(ruído_impulsivo.^2));
for qq = 1:length(ruído_impulsivo)
    if abs(ruído_impulsivo (qq))<3
        ruído_impulsivo (qq) = 0;
    end
end

% gerando ruído Gaussiano aleatório
ruído_Gauss1 = randn(1,Namostras);
ruído_Gauss2 = randn(1,Namostras);

% sinais de entrada em 15 Hz
x1 = sin(w1*(1:Namostras))+0.2* ruído_Gauss1+ruído_impulsivo+
0.6*sin(w2*(1:Namostras));
x2 = 0.8*sin(w1*(1:Namostras)+pi/6)+0.5* ruído_Gauss2+0.4*
ruído_impulsivo + 0.3*sin(w2*(1:Namostras));

```

Nesta simulação o filtro foi projetado com ordem 5. É possível observar na Figura 5.3 que o sinal filtrado  $y_1(n)$  apresenta-se mais semelhante a uma senoide pura oscilante em torno de 15 Hz que os sinais ruidosos de entrada  $x_1(n)$  e  $x_2(n)$ . Esta constatação é corroborada tanto na análise do sinal temporal, como pelo espectro de frequência, aonde se nota que o sinal filtrado  $y_1(n)$  mantém, na frequência de 15 Hz, uma componente de valor intermediário aos apresentados pelos canais de entrada  $x_1(n)$  e  $x_2(n)$ , apresentando valores próximos de zero nas demais frequências, inclusive na frequência interferente de 20 Hz, demonstrando o potencial de sintonia do filtro. Este resultado demonstra que o filtro MVDR é

promissor para o cancelamento eficiente de interferentes.

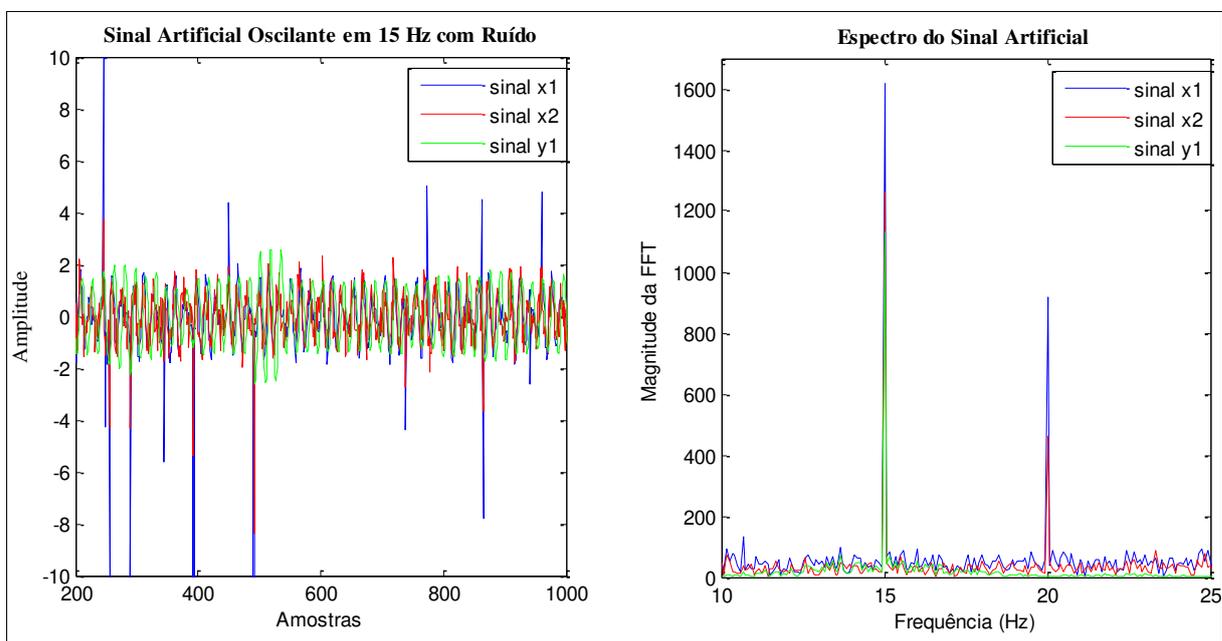


Figura 5.3 – Resultado da filtragem em 15 Hz de dois sinais senoidais ruidosos.

## 5.2 FREQUÊNCIAS DE SINTONIA

Em problemas reais de BCI-SSVEP, o número de frequências a serem distinguidas pelo classificador é geralmente superior a dois. Desta forma, é necessário que o filtro MVDR seja capaz de conservar a energia em todas as possíveis frequências evocadas e cancelar as demais componentes de frequência. A Figura 5.4 mostra o diagrama esquemático do caso em que se deseja avaliar um total de  $N$  frequências. Cada frequência a mais a ser analisada implica no acréscimo de filtros.

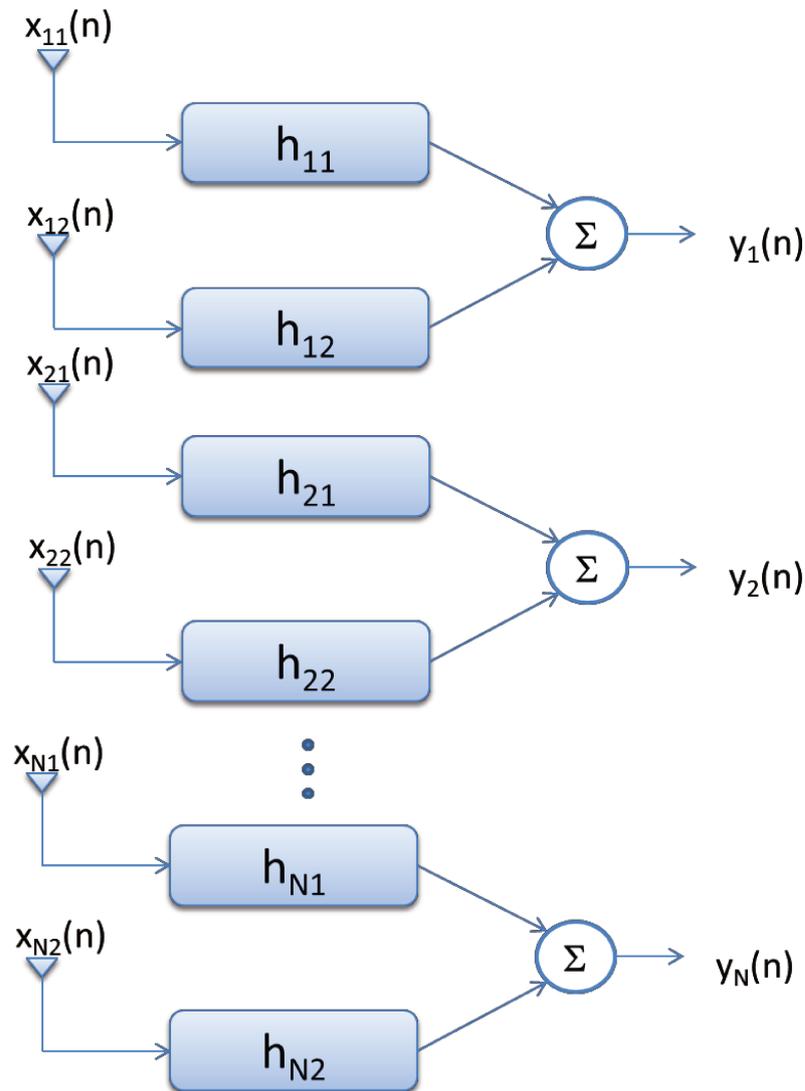


Figura 5.4 – Diagrama do filtro MVDR combinando duas entradas e selecionando  $N$  frequências.

Inicialmente, considere o caso de duas possíveis frequências  $\omega_1$  e  $\omega_2$ . Os sinais de entrada podem ser modelados como sendo a soma de cossenoides oscilantes em cada uma das possíveis frequências evocadas:

$$x_1(n) = A_1 \cos(\omega_1 n + \theta_1) + A_2 \cos(\omega_2 n + \theta_2) \quad (5.24)$$

$$x_2(n) = B_1 \cos(\omega_1 n + \varphi_1) + B_2 \cos(\omega_2 n + \varphi_2) \quad (5.25)$$

Para que a filtragem mantenha as propriedades dos sinais nas frequências de interesse e leve a zero as demais frequências, é necessário incluir algumas restrições no projeto do filtro. No caso, cada nova frequência introduz duas novas restrições para cada um dos sinais de entrada a serem combinados. Considerando primeiramente  $x_1(n)$  e as

frequências  $\omega_1$  e  $\omega_2$ , as restrições são:

$$\begin{cases} h_{10} + h_{11} \cos(\omega_1) + h_{12} \cos(2\omega_1) + \dots = 1 \\ h_{10} + h_{11} \cos(\omega_2) + h_{12} \cos(2\omega_2) + \dots = 1 \\ h_{11} \text{sen}(-\omega_1) + h_{12} \text{sen}(-2\omega_1) + \dots = 0 \\ h_{11} \text{sen}(-\omega_2) + h_{12} \text{sen}(-2\omega_2) + \dots = 0 \end{cases} \quad (5.26)$$

expressões semelhantes podem ser escritas para a entrada  $x_2(n)$ .

No caso, de duas frequências com duas entradas, tem-se um total de oito restrições:

$$\begin{aligned} \mathbf{h}^T \mathbf{C}_1 &= 1 & \mathbf{h}^T \mathbf{S}_1 &= 0 \\ \mathbf{h}^T \mathbf{C}_2 &= 1 & \mathbf{h}^T \mathbf{S}_2 &= 0 \\ \mathbf{h}^T \mathbf{C}_3 &= 1 & \mathbf{h}^T \mathbf{S}_3 &= 0 \\ \mathbf{h}^T \mathbf{C}_4 &= 1 & \mathbf{h}^T \mathbf{S}_4 &= 0 \end{aligned} \quad (5.27)$$

sendo:

$$\begin{aligned} \mathbf{C}_1 &= \begin{bmatrix} 1 \\ \cos(\omega_1) \\ \cos(2\omega_1) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} & \mathbf{S}_1 &= \begin{bmatrix} 0 \\ \text{sen}(\omega_1) \\ \text{sen}(2\omega_1) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \\ \mathbf{C}_2 &= \begin{bmatrix} 1 \\ \cos(\omega_2) \\ \cos(2\omega_2) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} & \mathbf{S}_2 &= \begin{bmatrix} 0 \\ \text{sen}(\omega_2) \\ \text{sen}(2\omega_2) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \end{aligned} \quad (5.28)$$

$$\mathbf{C}_3 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \cos(\omega_1) \\ \cos(2\omega_1) \\ \vdots \end{bmatrix} \quad \mathbf{S}_3 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ \text{sen}(\omega_1) \\ \text{sen}(2\omega_1) \\ \vdots \end{bmatrix}$$

$$\mathbf{C}_4 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \cos(\omega_2) \\ \cos(2\omega_2) \\ \vdots \end{bmatrix} \quad \mathbf{S}_4 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ \text{sen}(\omega_2) \\ \text{sen}(2\omega_2) \\ \vdots \end{bmatrix}$$

As restrições (5.27) definem um problema de otimização, cuja solução pode ser encontrada solucionando o lagrangiano:

$$\nabla L(\lambda) = 2\mathbf{R}\mathbf{h} - \lambda_1\mathbf{C}_1 - \lambda_2\mathbf{S}_1 - \lambda_3\mathbf{C}_2 - \lambda_4\mathbf{S}_2 - \lambda_5\mathbf{C}_3 - \lambda_6\mathbf{S}_3 - \lambda_7\mathbf{C}_4 - \lambda_8\mathbf{S}_4 = 0 \quad (5.29)$$

A determinação dos coeficientes de Lagrange passa pela solução do seguinte sistema matricial:

$$\begin{bmatrix} \frac{\mathbf{C}_1^T \mathbf{R}^{-1} \mathbf{C}_1}{2} & \frac{\mathbf{S}_1^T \mathbf{R}^{-1} \mathbf{C}_1}{2} & & \frac{\mathbf{C}_4^T \mathbf{R}^{-1} \mathbf{C}_1}{2} & \frac{\mathbf{S}_4^T \mathbf{R}^{-1} \mathbf{C}_1}{2} \\ \frac{\mathbf{C}_1^T \mathbf{R}^{-1} \mathbf{S}_1}{2} & \frac{\mathbf{S}_1^T \mathbf{R}^{-1} \mathbf{S}_1}{2} & \dots & \frac{\mathbf{C}_4^T \mathbf{R}^{-1} \mathbf{S}_1}{2} & \frac{\mathbf{S}_4^T \mathbf{R}^{-1} \mathbf{S}_1}{2} \\ & \vdots & \ddots & \vdots & \vdots \\ \frac{\mathbf{C}_1^T \mathbf{R}^{-1} \mathbf{C}_4}{2} & \frac{\mathbf{S}_1^T \mathbf{R}^{-1} \mathbf{C}_4}{2} & & \frac{\mathbf{C}_4^T \mathbf{R}^{-1} \mathbf{C}_4}{2} & \frac{\mathbf{S}_4^T \mathbf{R}^{-1} \mathbf{C}_4}{2} \\ \frac{\mathbf{C}_1^T \mathbf{R}^{-1} \mathbf{S}_4}{2} & \frac{\mathbf{S}_1^T \mathbf{R}^{-1} \mathbf{S}_4}{2} & \dots & \frac{\mathbf{C}_4^T \mathbf{R}^{-1} \mathbf{S}_4}{2} & \frac{\mathbf{S}_4^T \mathbf{R}^{-1} \mathbf{S}_4}{2} \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \lambda_4 \\ \lambda_5 \\ \lambda_6 \\ \lambda_7 \\ \lambda_8 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \end{bmatrix} \quad (5.30)$$

Uma vez determinados os coeficientes  $\lambda_1$  a  $\lambda_8$ , o filtro é dado por:

$$\mathbf{h} = \frac{\lambda_1}{2}\mathbf{R}^{-1}\mathbf{C}_1 + \frac{\lambda_2}{2}\mathbf{R}^{-1}\mathbf{S}_1 + \frac{\lambda_3}{2}\mathbf{R}^{-1}\mathbf{C}_2 + \frac{\lambda_4}{2}\mathbf{R}^{-1}\mathbf{S}_2 + \frac{\lambda_5}{2}\mathbf{R}^{-1}\mathbf{C}_3 + \frac{\lambda_6}{2}\mathbf{R}^{-1}\mathbf{S}_3 + \frac{\lambda_7}{2}\mathbf{R}^{-1}\mathbf{C}_4 + \frac{\lambda_8}{2}\mathbf{R}^{-1}\mathbf{S}_4 \quad (5.31)$$

sendo  $\mathbf{R}$  a matriz de correlação dos valores de entrada.

Um terceiro experimento avaliou a eficiência do filtro em conservar a energia em todas as frequências de interesse e cancelar os interferentes presentes nas demais faixas de frequências de interesse quando se combinam dois sinais de entrada. Neste teste foram gerados quatro sinais senoidais, sendo  $x_{11}(n)$  e  $x_{12}(n)$  oscilantes em 15 Hz e  $x_{21}(n)$  e  $x_{22}(n)$  oscilantes na frequência de 20 Hz. Semelhantemente ao experimento anterior (ver Quadro 5.1), foram acrescentados ruídos impulsivo e gaussiano gerados de maneira aleatória. Também foi introduzida uma componente senoidal de amplitude menor nas frequências a serem enfocadas, de modo que os sinais cuja frequência principal era 15 Hz possuíam também conteúdo espectral em 20 Hz e vice-versa. Todos os sinais foram gerados com 3072 amostras. O filtro foi projetado com ordem 35, para ser capaz de atenuar as faixas de interesse de maneira efetiva. A Figura 5.5 mostra os sinais de entrada e a saída do filtro no domínio do tempo e da frequência. O espectro dos sinais  $y_1(n)$  e  $y_2(n)$  foram plotados com amplitude reduzida pela metade. É possível ver que o filtro MVDR consegue manter perfeitamente ambas as frequências de interesse sem gerar componentes espúrias.

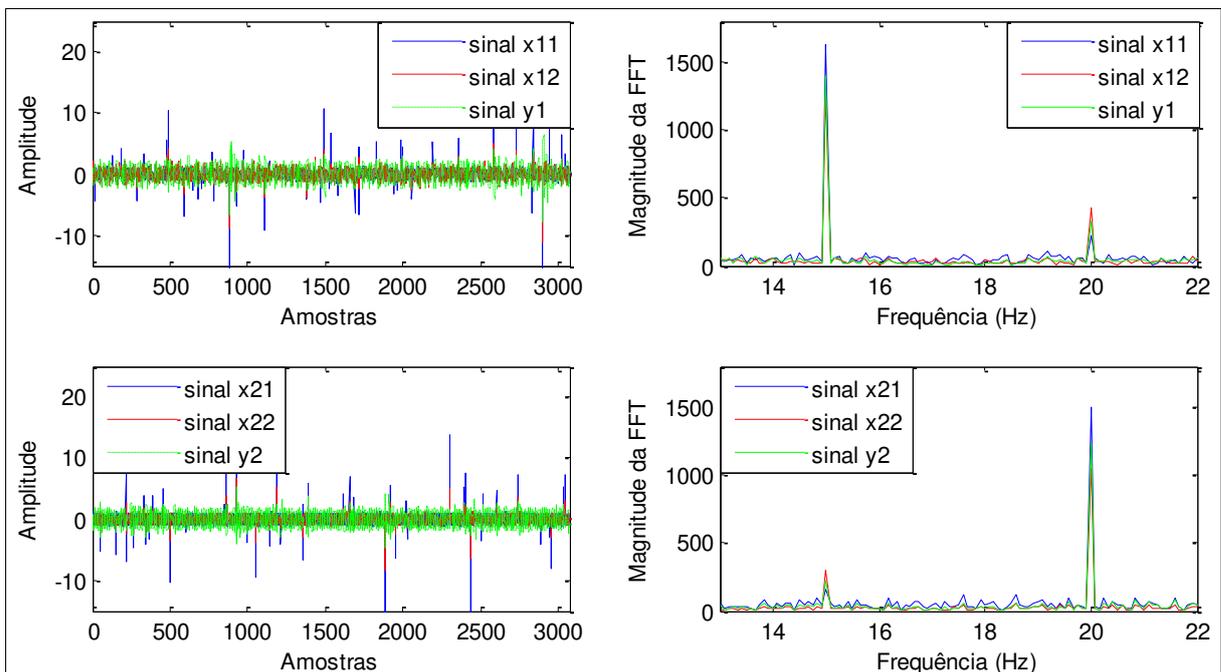


Figura 5.5 – Resultado da filtragem em 15 e 20 Hz de quatro sinais senoidais combinados dois a dois.

Na sequência, realizou-se um quarto experimento, utilizando sinais cerebrais reais, adquiridos via EEG sob o paradigma SSVEP. Os eletrodos selecionados continham uma boa resposta VEP para o indivíduo. Sendo:

$x_{11}(n)$  – sinal coletado na posição O1 sob estimulação visual de 15 Hz.

$x_{12}(n)$  – sinal coletado na posição PO7 sob estimulação visual de 15 Hz.

$x_{21}(n)$  – sinal coletado na posição O1 sob estimulação visual de 20 Hz.

$x_{22}(n)$  – sinal coletado na posição PO7 sob estimulação visual de 20 Hz.

Todos os sinais foram previamente filtrados pela técnica de CAR e multiplicados por um fator de  $10^6$ , para evitar um mal condicionamento da matriz de restrições, devido ao fato da pequena ordem de grandeza dos valores. A Figura 5.6 apresenta os sinais cerebrais no domínio do tempo e da frequência e a saída dos filtros MVDR (curvas verde). O filtro projetado com ordem 100 foi capaz de eliminar ampla gama de ruído. Em particular, observa-se que o ruído presente na região da frequência de 10 Hz foi abruptamente reduzido no processo de filtragem. Este resultado mostra a capacidade do filtro MVDR em conservar a energia nas frequências de interesse de 15 Hz e 20 Hz, reduzindo a intensidade dos interferentes presentes nas demais frequências.

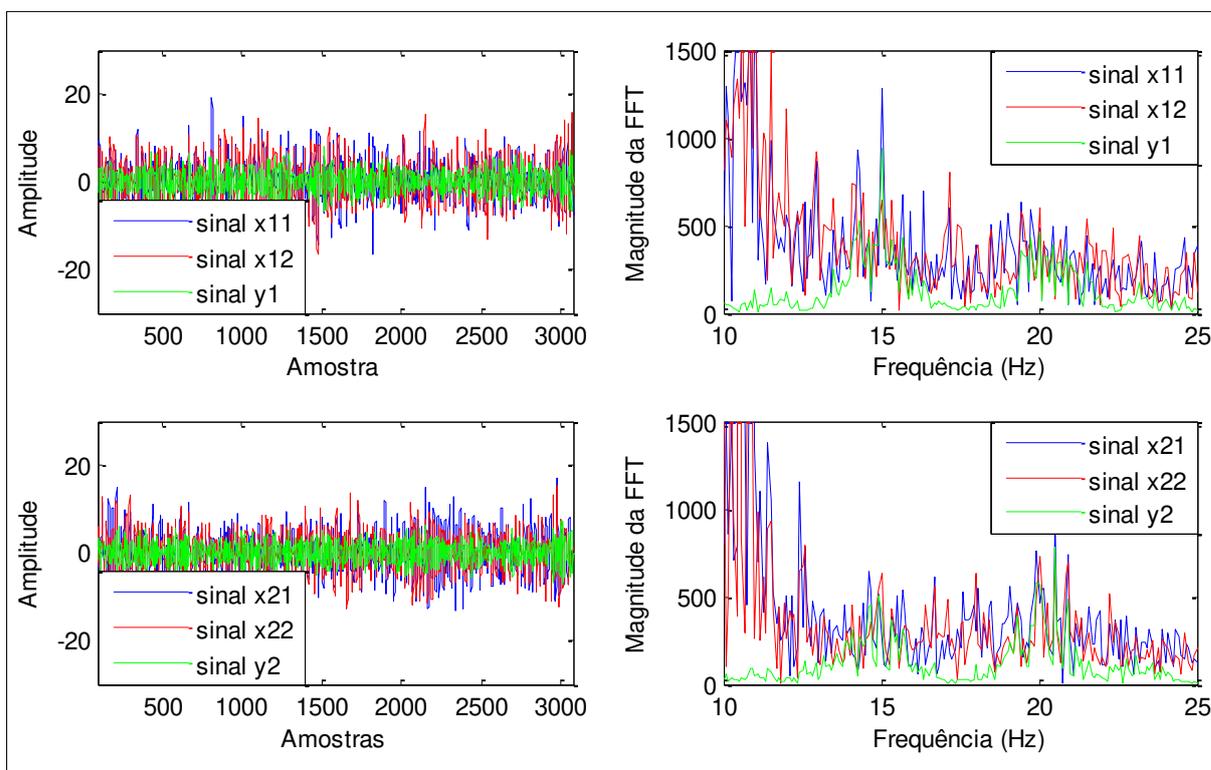


Figura 5.6 – Resultado da filtragem em 15 Hz e 20 Hz de sinais cerebrais com potencial visual evocado.

Realizando uma matemática análoga à apenas apresentada, é possível gerar as restrições do filtro para tantas frequências quantas forem necessárias. Assim, foi considerado um caso de BCI com seis frequências evocadas, utilizando os sinais EEG-SSVEP da base de

dados do DSPCom coletados nas posições O1 e Oz. O indivíduo foi submetido a estímulos visuais cintilantes nas seguintes frequências: 6, 7,5, 12, 15, 20 e 30 Hz. A Figura 5.7 ilustra o resultado do processo de filtragem deste quinto experimento.

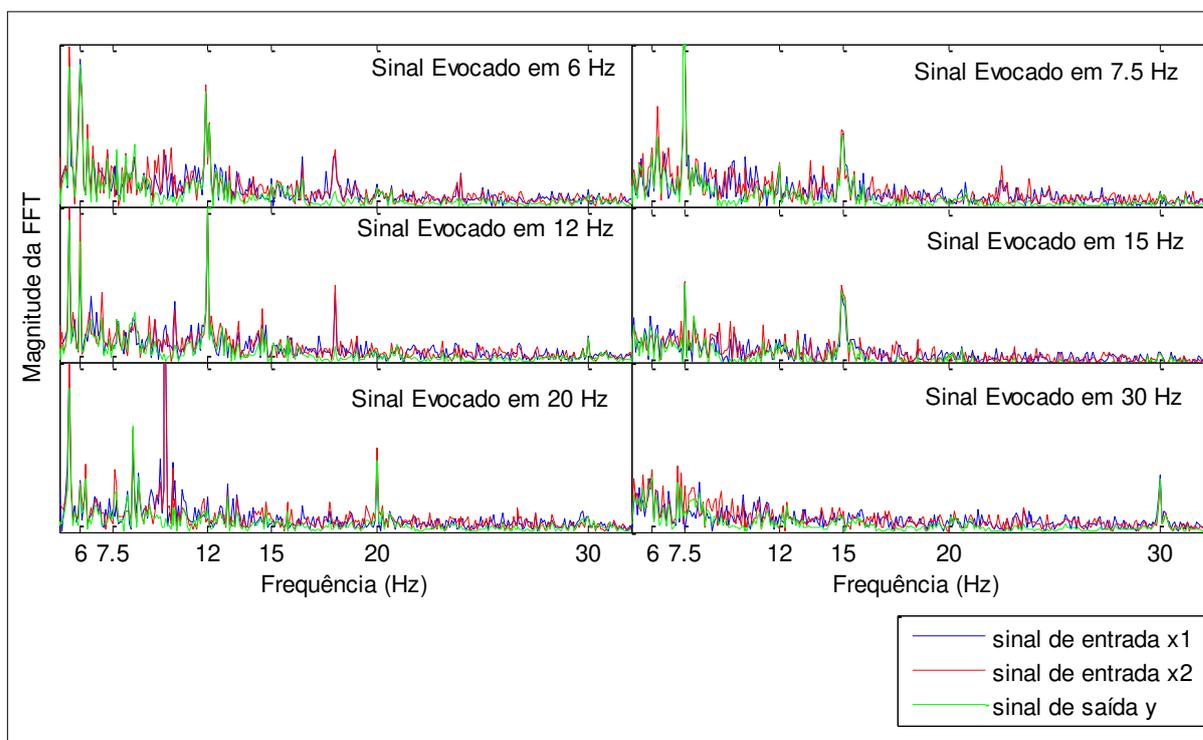


Figura 5.7 –Resultado da filtragem em seis diferentes frequências de sinais cerebrais com potencial visual evocado.

Neste caso, trabalhou-se com 24 restrições e o filtro foi projetado com ordem 100. A Figura 5.7 evidencia que o filtro MVDR mantém-se robusto, preservando o conteúdo espectral nas frequências de interesse e reduzindo o conteúdo nas demais frequências, como desejado. Além disso, o filtro mostrou-se capaz de operar adequadamente mesmo no caso de frequências bem próximas, como 6 e 7,5 Hz.

### 5.3 NÚMERO DE ENTRADAS

Apesar de o desenvolvimento matemático e os experimentos relatados até o momento terem considerado o problema somente para a combinação de dois sinais de entrada por filtragem, é possível estender a técnica permitindo a combinação de tantos sinais de entrada quanto forem convenientes. Justamente, um caso de interesse na análise de sinais SSVEP pode ser combinar mais entradas, fazendo um arranjo espacial mais complexo do

posicionamento dos eletrodos. O aumento do número de entradas exige que filtros sintonizados nas frequências de interesse sejam disponibilizados paralelamente. A Figura 5.8 ilustra o caso de  $N$  entradas combinadas em uma saída pelo processo de filtragem.

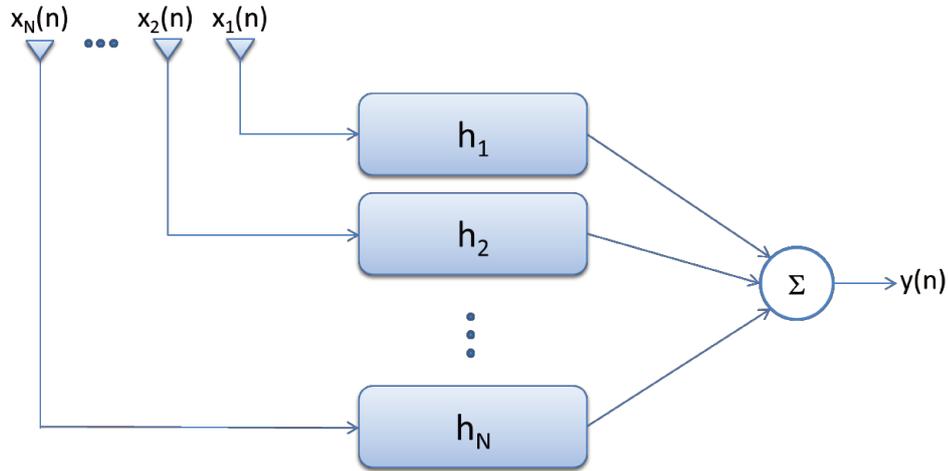


Figura 5.8 – Diagrama do filtro MVDR combinando  $N$  entradas e selecionando uma única frequência.

Cada nova entrada incorpora novas restrições no projeto do filtro. Para ilustrar o procedimento, considere o caso da combinação de três sinais de entrada  $x_1$ ,  $x_2$  e  $x_3$  coletados na posição O1, O2 e Oz de um indivíduo submetido ao estímulo de 15 Hz.

$$x_1(n) = A \cos(\omega_0 n + \theta) \tag{5.32}$$

$$x_2(n) = B \cos(\omega_0 n + \varphi) \tag{5.33}$$

$$x_3(n) = C \cos(\omega_0 n + \alpha) \tag{5.34}$$

com  $\omega_0 = 2\pi 15$  e fases  $\theta$ ,  $\varphi$  e  $\alpha$  arbitrárias.

As expressões de (5.1) a (5.11) permanecem as mesmas, entretanto, as restrições devem incluir a terceira entrada, sendo:

$$\begin{aligned} \mathbf{h}^T \mathbf{C}_1 &= 1 & \mathbf{h}^T \mathbf{S}_1 &= 0 \\ \mathbf{h}^T \mathbf{C}_2 &= 1 & \mathbf{h}^T \mathbf{S}_2 &= 0 \\ \mathbf{h}^T \mathbf{C}_3 &= 1 & \mathbf{h}^T \mathbf{S}_3 &= 0 \end{aligned} \tag{5.35}$$

com:

$$\begin{aligned}
 \mathbf{C}_1 &= \begin{bmatrix} 1 \\ \cos(\omega_0) \\ \cos(2\omega_0) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} & \mathbf{S}_1 &= \begin{bmatrix} 0 \\ \text{sen}(\omega_0) \\ \text{sen}(2\omega_0) \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \\
 \mathbf{C}_2 &= \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \cos(\omega_0) \\ \cos(2\omega_0) \\ \vdots \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} & \mathbf{S}_2 &= \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ \text{sen}(\omega_0) \\ \text{sen}(2\omega_0) \\ \vdots \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \end{bmatrix} \\
 \mathbf{C}_3 &= \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \\ 1 \\ \cos(\omega_0) \\ \cos(2\omega_0) \\ \vdots \end{bmatrix} & \mathbf{S}_3 &= \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ \vdots \\ 0 \\ 0 \\ 0 \\ \vdots \\ 0 \\ \text{sen}(\omega_0) \\ \text{sen}(2\omega_0) \\ \vdots \end{bmatrix}
 \end{aligned} \tag{5.36}$$

O lagrangiano que soluciona este problema de seis restrições é:

$$\nabla \mathbf{L}(\boldsymbol{\lambda}) = 2\mathbf{R}\mathbf{h} - \lambda_1 \mathbf{C}_1 - \lambda_2 \mathbf{S}_1 - \lambda_3 \mathbf{C}_2 - \lambda_4 \mathbf{S}_2 - \lambda_5 \mathbf{C}_3 - \lambda_6 \mathbf{S}_3 = 0 \tag{5.37}$$

sendo  $\mathbf{R}$  a matriz de correlação gerada pelos dados de cada uma das entradas.

Os multiplicadores de Lagrange podem ser determinados por:

$$\lambda = \Lambda^{-1} \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \end{bmatrix} \quad (5.38)$$

sendo:

$$\Lambda = \begin{bmatrix} \frac{C_1^T R^{-1} C_1}{2} & \frac{S_1^T R^{-1} C_1}{2} & \frac{C_2^T R^{-1} C_1}{2} & \frac{S_2^T R^{-1} C_1}{2} & \frac{C_3^T R^{-1} C_1}{2} & \frac{S_3^T R^{-1} C_1}{2} \\ \frac{C_1^T R^{-1} S_1}{2} & \frac{S_1^T R^{-1} S_1}{2} & \frac{C_2^T R^{-1} S_1}{2} & \frac{S_2^T R^{-1} S_1}{2} & \frac{C_3^T R^{-1} S_1}{2} & \frac{S_3^T R^{-1} S_1}{2} \\ \frac{C_1^T R^{-1} C_2}{2} & \frac{S_1^T R^{-1} C_2}{2} & \frac{C_2^T R^{-1} C_2}{2} & \frac{S_2^T R^{-1} C_2}{2} & \frac{C_3^T R^{-1} C_2}{2} & \frac{S_3^T R^{-1} C_2}{2} \\ \frac{C_1^T R^{-1} S_2}{2} & \frac{S_1^T R^{-1} S_2}{2} & \frac{C_2^T R^{-1} S_2}{2} & \frac{S_2^T R^{-1} S_2}{2} & \frac{C_3^T R^{-1} S_2}{2} & \frac{S_3^T R^{-1} S_2}{2} \\ \frac{C_1^T R^{-1} C_3}{2} & \frac{S_1^T R^{-1} C_3}{2} & \frac{C_2^T R^{-1} C_3}{2} & \frac{S_2^T R^{-1} C_3}{2} & \frac{C_3^T R^{-1} C_3}{2} & \frac{S_3^T R^{-1} C_3}{2} \\ \frac{C_1^T R^{-1} S_3}{2} & \frac{S_1^T R^{-1} S_3}{2} & \frac{C_2^T R^{-1} S_3}{2} & \frac{S_2^T R^{-1} S_3}{2} & \frac{C_3^T R^{-1} S_3}{2} & \frac{S_3^T R^{-1} S_3}{2} \end{bmatrix} \quad (5.39)$$

Os coeficientes dos três filtros podem ser determinados por:

$$\mathbf{h} = \frac{\lambda_1}{2} \mathbf{R}^{-1} \mathbf{C}_1 + \frac{\lambda_2}{2} \mathbf{R}^{-1} \mathbf{S}_1 + \frac{\lambda_3}{2} \mathbf{R}^{-1} \mathbf{C}_2 + \frac{\lambda_4}{2} \mathbf{R}^{-1} \mathbf{S}_2 + \frac{\lambda_5}{2} \mathbf{R}^{-1} \mathbf{C}_3 + \frac{\lambda_6}{2} \mathbf{R}^{-1} \mathbf{S}_3 \quad (5.40)$$

generalizando para o caso de  $N$  entradas:

$$\mathbf{h} = \sum_{i=1}^N \frac{\lambda_i}{2} \mathbf{R}^{-1} \mathbf{C}_i + \frac{\tilde{\lambda}_i}{2} \mathbf{R}^{-1} \mathbf{S}_i \quad (5.41)$$

Cada entrada é submetida a um filtro diferente, que depende dos dados de entrada, evidenciados por meio da matriz de correlação  $\mathbf{R}$ .

A Figura 5.9 apresenta o resultado da filtragem realizada com os sinais SSVEP na frequência de 15 Hz. O sinal temporal apresenta os três sinais de entrada e a saída do filtro (curva verde), a qual apresenta uma característica senoidal mais marcada, quando comparada com os sinais de entrada. No espectro de frequência, se constata que o filtro MVDR de ordem 100 foi capaz de combinar as três entradas observando as restrições impostas, de modo a manter o conteúdo espectral em 15 Hz e atenuar as demais componentes de frequência.

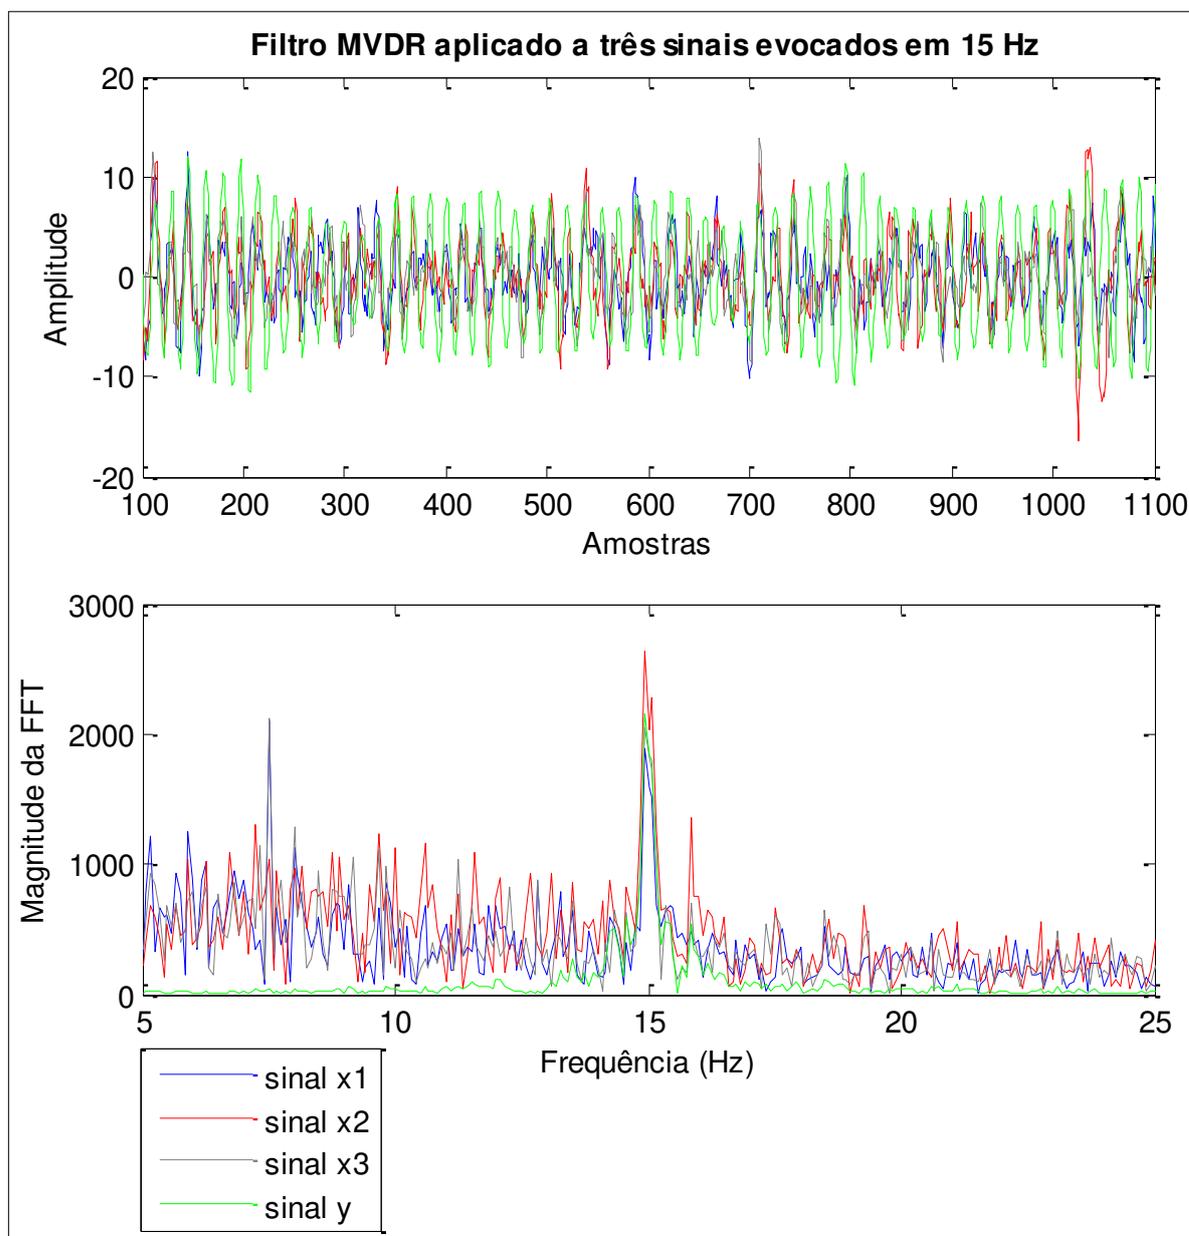


Figura 5.9 – Resultado da filtragem em 15 Hz de três sinais cerebrais com potencial visual evocado.

## 5.4 COMPRIMENTO DO SINAL

Até o momento as simulações utilizaram sinais cerebrais de 12 s, entretanto, para viabilizar sistemas BCIs é necessário que o processamento de sinais ocorra em tempo de execução. Isto demanda que o filtro opere em janelas menores, nas quais a relação sinal ruído é ainda menor.

Considerando novamente os dados utilizados na realização do quarto experimento

(ver Figura 5.5), o sinal EEG foi segmentado em janelas de 3 s e 2 s, para permitir a avaliação do efeito do janelamento no desempenho da filtragem MVDR. As Figuras 5.10 e 5.11 apresentam os resultados.

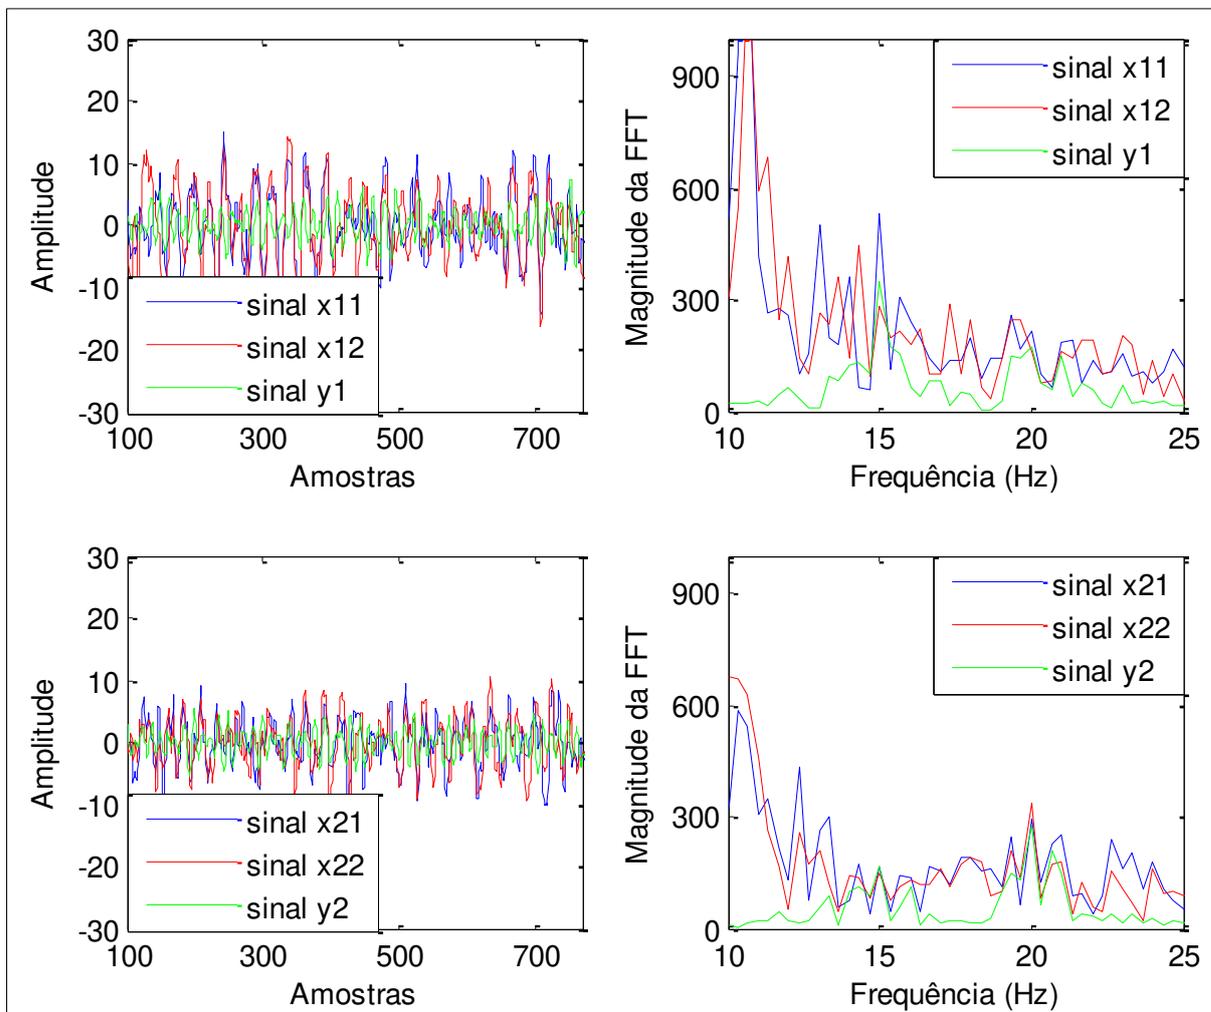


Figura 5.10 – Resultado da filtragem em 15 Hz e 20 Hz de 3 s de sinais cerebrais com potencial visual evocado.

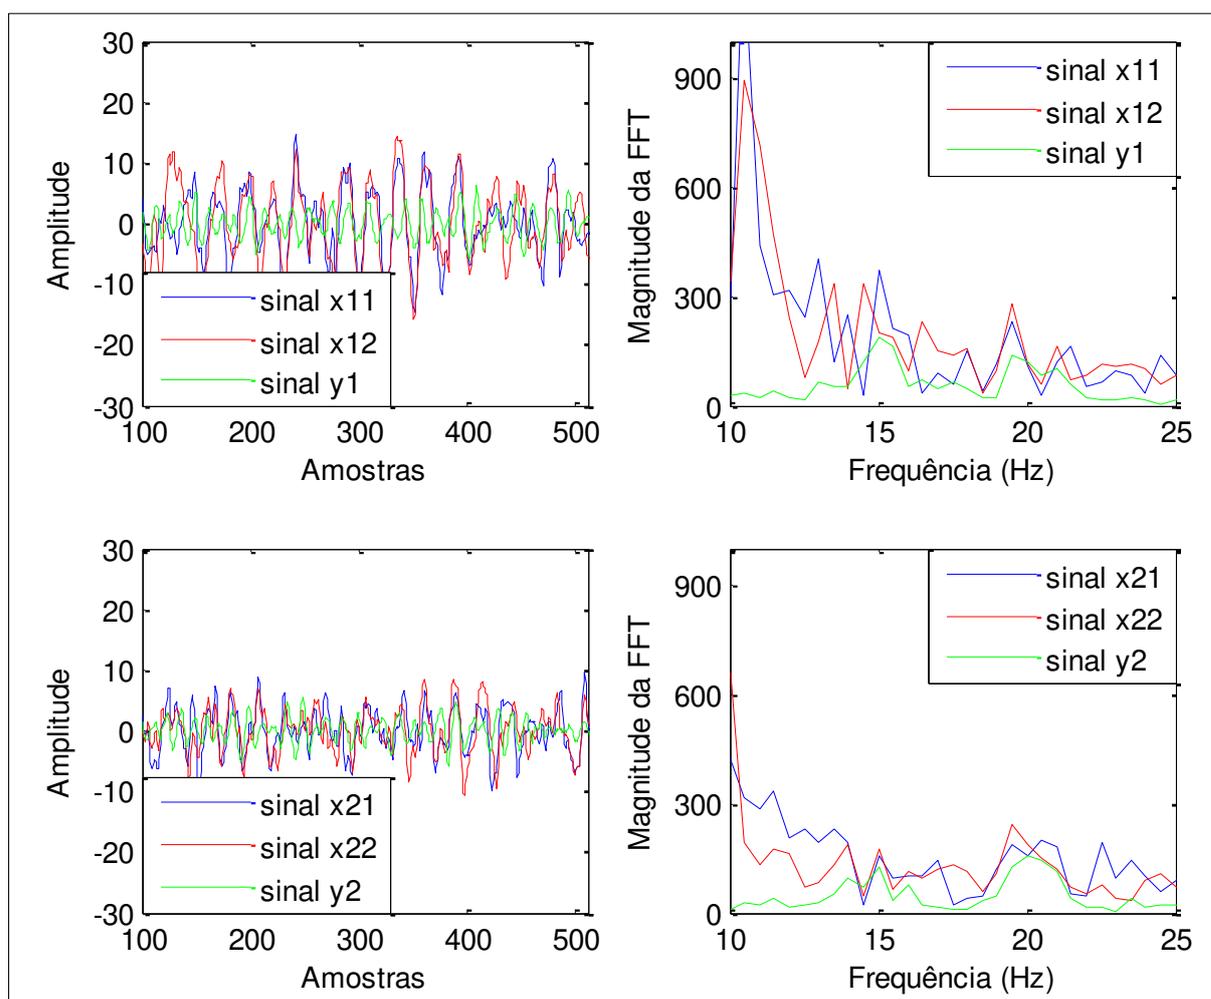


Figura 5.11 – Resultado da filtragem em 15 Hz e 20 Hz de 2 s de sinais cerebrais com potencial visual evocado.

Observa-se que o pico de potencial evocado é menos expressivo quanto menor é a janela. Entretanto, o filtro MVDR demonstra ser capaz de manter a energia nas frequências de interesse e atenuar as demais faixas de frequência.

## 5.5 ORDEM DO FILTRO MVDR

Um parâmetro crucial no projeto de um filtro é a determinação da sua ordem, uma vez que ela afeta diretamente o sinal filtrado. Uma ordem pequena torna o filtro incapaz de observar as restrições impostas; já uma ordem muito grande, além de exigir maior capacidade computacional, pode resultar em matrizes de restrições mal condicionadas, inviabilizando a obtenção de uma solução.

A avaliação da ordem do filtro pode, em primeira instância, considerar o resultado

da filtragem. A Figura 5.12 ilustra oito processos de filtragem utilizando diferentes ordens. Nesta simulação foram combinados dois sinais de entrada  $x_1$  e  $x_2$  adquiridos pelo EEG na posição O1 e Oz, respectivamente. Ambos os sinais tem 12 s e foram amostrados à taxa de 256 Hz enquanto o indivíduo estava submetido a um estímulo visual cintilante em 15 Hz. O sinal de saída (curva verde) mostra o resultado da filtragem aplicando o filtro MVDR de ordem 10, 50, 100, 200, 300, 500, 800 e 1000.

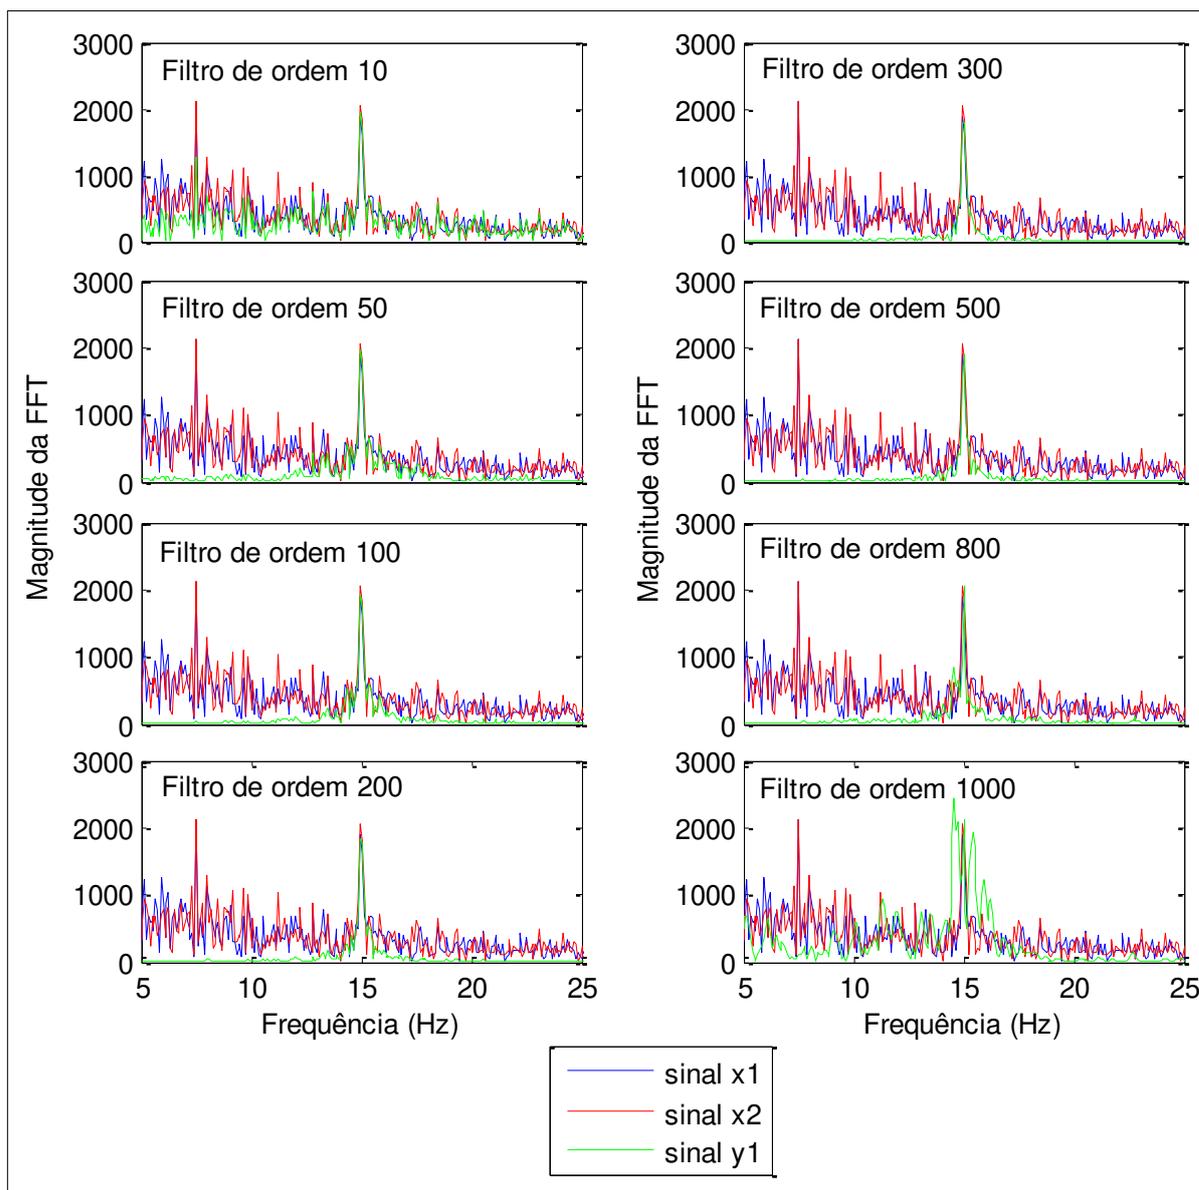


Figura 5.12 – Resultado da filtragem em 15 Hz de dois sinais cerebrais usando diversas ordens de filtro.

A análise da Figura 5.12 permite inferir que o filtro de ordem 10 é capaz de manter o valor de energia na frequência de interesse de 15 Hz, todavia a restrição de atenuação nas demais frequências não foi observada. Observa-se que com o aumento do

número de coeficientes do filtro, a filtragem vai se tornando mais eficaz, atenuando as frequências não desejadas. Os filtros de ordem entre 200, 300 e 500 apresentam um comportamento semelhante, com faixa de transição estreita ( $\sim 1$  Hz) em torno de 15 Hz. Entretanto, ao aumentar ainda mais a ordem do filtro, observa-se que há um ganho de energia para as frequências limítrofes a 15 Hz, este comportamento é visto no filtro de ordem 800 e está bem evidenciado para o filtro de ordem 1000. Neste último, nota-se ainda que a atenuação do espectro nas demais frequências não ocorre a contento. É interessante notar que o filtro opera corretamente para uma ampla gama de ordens (entre 100 e 800), flexibilizando a atribuição dos parâmetros durante o projeto do filtro.

## **5.6 FILTRO MVDR APLICADO A UMA BCI-SSVEP**

Nesta seção, são relatadas algumas simulações de sistemas BCI-SSVEP que incluíram a filtragem MVDR na etapa de pré-processamento. Os experimentos empregaram sinais EEG de dois voluntários da base de dados DESTINE (ver Seção 4.3). Ambos os voluntários escolhidos (voluntário 1 e voluntário 3) apresentavam resposta SSVEP representativa da maioria dos indivíduos saudáveis avaliados, estando associados ao grupo com desempenho entre 90% e 100% no experimento descrito na Seção 4.3.1 (ver Figura 4.12). Para guiar a estruturação do filtro MVDR foram utilizados os sinais EEG oriundos dos eletrodos selecionados com mais frequência para cada indivíduo (ver Figura A.1). Optou-se por realizar dez combinações de dois sinais com repetição dos eletrodos mais informativos, conforme apresenta a Tabela 5.1.

Este arranjo de canais foi escolhido para gerar uma avaliação inicial da atuação do filtro MVDR na BCI, entretanto uma análise mais sistemática sobre a forma de combinação dos sinais EEG poderia proporcionar um melhor desempenho do sistema.

TABELA 5.1 – COMBINAÇÃO DE SINAIS EEG NA FILTRAGEM MVDR.

	Canal	Combinações
<b>Voluntário 1</b>	1	O1-O2
	2	O1-Oz
	3	O1-Pz
	4	O1-CPz
	5	Oz-Pz
	6	Oz-CPz
	7	O1-PO7
	8	Oz-PO7
	9	PO3-C1
	10	PO8-P1
<b>Voluntário 3</b>	1	O1-O2
	2	O1-Oz
	3	O2-Oz
	4	O1-Pz
	5	O2-Pz
	6	Oz-Pz
	7	O1-PO7
	8	O2-PO7
	9	Oz-PO7
	10	Pz-PO7

Primeiramente, foram avaliadas: a ordem do filtro MVDR, a influência da combinação do filtro MVDR com a filtragem CAR e a necessidade de seleção de características. A Tabela 5.2 apresenta a capacidade do sistema em discriminar os sinais de 12 Hz e 15 Hz empregando o filtro MVDR, com diferentes ordens (20, 30 e 50), nos sinais cerebrais do voluntário 3. Os sinais EEG foram previamente segmentados em janelas de 3 s com *overlap* de 2 s. Como o filtro MVDR atenua todo o espectro, exceto as frequências de interesse, a extração de características consistiu no cálculo do módulo da FFT nas frequências evocadas. O sistema de classificação adotado foi o linear baseado no método dos mínimos quadrados.

TABELA 5.2 – DESEMPENHO DA BCI PARA DIFERENTES ORDENS.

		Ordem	Taxa de Acerto (%)		
			12 Hz	15 Hz	Total
Sem seleção	Sem CAR	20	95	90	92,5
		30	100	90	95
		50	90	95	92,5
	Com CAR	30	85	85	85
		50	90	75	82,5
Wrapper	Sem CAR	20	95	95	95
		30	95	95	95
		50	95	95	95
	Com CAR	30	100	100	100
		50	95	100	97,5

Nota-se que, todas as ordens do filtro MVDR avaliadas retornam desempenho semelhante. Ordens maiores não foram testadas devido ao mau condicionamento da matriz de restrições. O emprego do CAR em precedência da filtragem MVDR teve um comportamento dual: para os casos em que não houve seleção de atributos, verificou-se um decréscimo de 10% na taxa de acerto, enquanto que para os casos em que os atributos foram selecionados pelo algoritmo *forward wrapper*, o desempenho do sistema aumentou em 2%. Os resultados desta primeira avaliação definiram a seguinte estrutura de pré-processamento que será adotada nos testes sucessivos: filtragem CAR seguida de filtragem MVDR com ordem 30.

Na sequência, foram feitas simulações com o objetivo de confrontar os principais resultados relatados no Capítulo 4 com o desempenho deste novo arranjo de filtragem. Relembrando, a combinação de técnicas que resultou em melhores taxas de acerto da BCI verificada no Capítulo 4 foi: pré-processamento: CAR; extração de características: método de Welch; seleção de atributos: *forward wrapper*; e classificação: classificador linear baseado no método dos mínimos quadrados.

A Tabela 5.3 apresenta a capacidade dos dois sistemas em discriminar os estímulos visuais em 12 Hz e 15 Hz. Os testes foram realizados para janelas de 3 s com *overlap* de 2 s, 1 s sem *overlap* e 0,5 s sem *overlap*. Foram considerados os sinais dos voluntários 1 e 3.

TABELA 5.3 – DESEMPENHO DA BCI EMPREGANDO O FILTRO MVDR.

Indivíduo	Técnica	Janela (s)	Overlap (s)	Taxa de Acerto (%)		
				12 Hz	15 Hz	Total
Voluntário 1	CAR	3	2	100	100	100
		1	0	83	88	85
		0,5	0	75	71	73
	CAR+Filtro MVDR	3	2	100	100	100
		1	0	92	88	90
		0,5	0	73	77	75
Voluntário 3	CAR	3	2	100	100	100
		1	0	88	67	69
		0,5	0	69	65	67
	CAR+Filtro MVDR	3	2	100	100	100
		1	0	96	83	90
		0,5	0	75	63	69

É possível observar que a estrutura que emprega a filtragem MVDR apresenta um melhor desempenho em todas as configurações analisadas, sendo o ganho mais expressivo, de 21%, verificado para o voluntário 3 quando se aplicou o janelamento de 1 s, alcançando taxa de acerto de 90%.

Para avaliar a atuação do filtro MVDR no problema de discriminação de mais frequências, foi retomado o experimento descrito na Seção 4.3.3, considerando os sinais dos voluntários 1 e 3. A Tabela 5.4 apresenta o desempenho de cada um dos sistemas em discriminar quatro frequências, enquanto a Tabela 5.5 apresenta os resultados para seis frequências.

TABELA 5.4 – DESEMPENHO DA BCI COM QUATRO ESTÍMULOS.

		Taxa de Acerto (%) - 4 Frequências				
		6 Hz	7,5 Hz	15 Hz	20 Hz	Total
Voluntário 1	CAR	80	35	65	70	62,5
	CAR+Filtro MVDR	85	55	85	75	75,0
Voluntário 3	CAR	90	55	80	60	71,3
	CAR+Filtro MVDR	90	50	70	75	71,3

TABELA 5.5 – DESEMPENHO DA BCI COM SEIS ESTÍMULOS.

		Taxa de Acerto (%) - 6 Frequências						Total
		6 Hz	7,5 Hz	12 Hz	15 Hz	20 Hz	30 Hz	
Voluntário 1	CAR	35	40	50	70	50	10	42,5
	CAR+Filtro MVDR	60	55	65	70	30	40	53,3
Voluntário 3	CAR	65	60	45	65	55	50	56,7
	CAR+Filtro MVDR	90	50	15	85	65	80	64,2

Observa-se que, em geral, o filtro MVDR proporcionou um ganho de desempenho de cerca de 10 % para todas as configurações, excetuando-se o caso de quatro frequências no sinal do voluntário 3, em que o desempenho foi mantido igual. Verifica-se que o filtro MVDR é capaz de contribuir na distinção de classes de frequências próximas como 6 e 7,5 Hz, ao mesmo tempo que não prejudica a discriminação de harmônicas, uma vez elas não entram na modelagem.

## 5.7 CONSIDERAÇÕES FINAIS

O filtro espaço-temporal proposto é em si uma contribuição relevante à área de processamento de sinais, uma vez que permite combinar a localização espacial dos sinais de entrada, ao mesmo tempo em que sintoniza as frequências de interesse em análise. Neste trabalho, o filtro MVDR foi avaliado no âmbito de sinais cerebrais com conteúdo de potencial visual evocado. Os experimentos descritos ao longo deste Capítulo demonstram o potencial da técnica, que pode contribuir tanto na etapa de pré-processamento como na de extração de características, uma vez que isola os picos de energia nas frequências de interesse de análise.

Na escolha das frequências a serem utilizadas, deve-se atentar para que a banda do filtro não se sobreponha. Nos experimentos relatados, testaram-se frequências próximas como 6 Hz e 7,5 Hz, as quais foram corretamente distinguidas no processo de filtragem. A ordem do filtro é outro ponto importante, para que as restrições sejam obedecidas. O filtro mostrou-se robusto permitindo a atribuição de uma ampla gama de ordens.

Os resultados preliminares sobre a atuação da filtragem MVDR em sistemas BCI-SSVEP revelam a capacidade da filtragem MVDR em aumentar o ganho de processamento do sistema. Foi possível verificar que o filtro MVDR é capaz de proporcionar taxas de acerto superiores às obtidas com a estrutura apontada como a melhor no Capítulo 4 (filtragem CAR,

extração usando o método de Welch, seleção por *wrappers* e classificação linear). Os resultados foram, em geral, superiores mesmo para janelas mais estreitas de 3 s, 1 s e 0,5 s, e nos problemas de discriminação de quatro e seis estímulos visuais. A flexibilidade do filtro MVDR, permitindo arranjar os sinais de entrada de forma conveniente bem como sintonizar a filtragem para atuar sobre todas as frequências de interesse abre um amplo leque de pesquisa em várias áreas. Uma avaliação mais sistemática sobre a configuração dos sinais de entrada pode resultar em melhor desempenho da filtragem. Em particular, para BCI-SSVEP, trabalhos futuros poderiam investigar diversos aspectos, como:

- Qual a melhor combinação de sinais cerebrais e posicionamento de eletrodos no escalpo?
- Quantos sinais de entrada devem ser combinados?
- Deve ou não haver redundância no casamento de sinais de eletrodos mais informativos com sinais provenientes de eletrodos de regiões pouco relacionadas à resposta SSVEP?

Um próximo passo na definição do filtro MVDR poderia considerar manter o conteúdo espectral em faixas de frequências ao invés de frequências isoladas. Esta alteração possibilitaria a utilização da ferramenta na abordagem de outro leque de problemas, como o processamento de sinais cerebrais avaliados no paradigma de imagética.

---

## 6. CONCLUSÕES

A pesquisa desenvolvida avaliou cuidadosamente as quatro etapas envolvidas no módulo de processamento de sinais de sistemas BCI-SSVEP, a saber: pré-processamento, extração e seleção de características e classificadores. As análises levaram a uma compreensão da forma estrutural e do funcionamento operacional de sistemas BCIs. A fim de contribuir na melhoria do desempenho do sistema e na sua eficiência, foram empregadas abordagens clássicas e ferramentas inovadoras de processamento de sinais e *machine learning*. Cada experimento evidenciou uma série de aspectos relevantes para a concepção das BCIs. Na sequência, são sintetizados os resultados e observações considerados mais relevantes.

### Pré-Processamento

Esta etapa, responsável por aumentar a relação sinal-ruído do sinal cerebral adquirido, mostrou-se crucial para garantir um desempenho satisfatório dos sistemas BCIs. De maneira geral, todos os filtros espaciais testados – CAR, MCC, MEC, MCC-CAR e MEC-CAR –, usando modelos que consideraram uma, duas ou três harmônicas, contribuíram com um aumento da taxa de acerto do sistema, com relação à ausência de execução do pré-processamento. As técnicas que forneceram o melhor desempenho, no conjunto de dados avaliados, foi o CAR e o CAR combinado com MCC usando um modelo de duas harmônicas. Entretanto, esta última ao incorporar harmônicas no modelo, acaba por limitar o uso das frequências de estimulação disponíveis para serem projetadas, visto que, para garantir precisão, os estímulos devem ser submúltiplos da taxa de *refresh* do monitor. Desta maneira, a melhor opção de filtragem espacial é o CAR, uma técnica matematicamente simples e computacionalmente rápida, que viabiliza uma fácil incorporação em sistemas que devem operar de maneira embarcada e em tempo de execução.

### **Extração de Características**

A resposta VEP costuma ser bem visível no espectro do sinal cerebral, principalmente quando se avaliam janelas temporais de mais de 10 segundos. O desafio consiste em identificar o padrão evocado em janelas estreitas, aonde a relação sinal ruído é baixa a tal ponto que a resposta VEP se torna indistinguível dos sinais interferentes. Este desafio deve ser enfrentado, uma vez que o tamanho da janela de análise impacta diretamente na taxa de transmissão de informação do sistema. Entre os diversos tamanhos de janela testados e considerando diferentes intervalos de *overlap*, a faixa entre 3 e 4 s mostrou-se a mais adequada para extração de atributos direcionadas a BCIs que controlem aplicações que possuem inércia, tal como o controle de uma cadeira de rodas. Para estes sistemas, a sobreposição das janelas de análise, em cerca de 50%, permite que um sinal de comando seja gerado a cada 1 ou 2 s, tempo suficiente para o controle do sistema, além de ser pouco fatigante para o usuário em se concentrar por cerca de 3 a 4 s em um estímulo visual. Para este tamanho de janelas de análise, as características extraídas no domínio espectral pelo método de Welch, banco de filtros e STF se mostraram mais robustas que as obtidas pelos coeficientes AR extraídas pelo método de Burg.

Outro ponto observado, concernente à extração de atributos, é a variabilidade da intensidade da resposta VEP entre os indivíduos. Dentre as frequências de estímulos visuais testadas (6, 7,5, 12, 15, 20 e 30 Hz), as que melhor evocam o potencial cerebral variaram entre os indivíduos e, além disso, variaram em um mesmo indivíduo de um dia a outro, revelando uma possível dependência de fatores cognitivos, psicológicos e emocionais. Entretanto, é possível verificar, durante a etapa de condicionamento do usuário, quais eletrodos fornecem os melhores sinais e quais frequências evocam de maneira mais intensa o potencial cerebral; esta análise prévia tende a melhorar o desempenho final do sistema em até 6%. O potencial evocado costuma ser mais intenso nos sinais adquiridos pelos eletrodos posicionados na zona occipital. Todavia, para os indivíduos com resposta VEP pouco expressiva, os sinais advindos de eletrodos de outros lobos, como o frontal, parietal e central, fornecem informações úteis, capazes de aprimorar o desempenho das BCIs. Não obstante a diferença da resposta VEP entre os indivíduos, as análises preliminares realizadas com os sinais cerebrais de pacientes que sofreram AVC foram animadoras, uma vez que as respostas VEP deles permitiram alcançar taxas de acerto no sistema semelhante às dos voluntários saudáveis, estando dentro do intervalo de variação observado.

### **Seleção de Características**

A etapa de seleção de atributos, tanto por filtros como por *wrappers*, mostrou-se extremamente importante, gerando ganho no desempenho do sistema BCI, em praticamente todos os cenários testados. A técnica de *wrappers* consegue capturar as melhores características que trabalham com determinado classificador e, em geral, fornece uma seleção mais acurada que as técnicas de seleção por filtros. Entretanto, as técnicas de filtros permitem uma rápida avaliação do sistema, e podem ser muito úteis durante o condicionamento do usuário, para a determinação das melhores posições a serem fixados os eletrodos.

### **Classificação**

Os atributos extraídos dos sinais cerebrais, no âmbito de sistemas SSVEP, mostraram-se linearmente separáveis, permitindo que o sistema atingisse taxa de acerto média superior a 95% para o caso de dois estímulos visuais, cerca de 77% para quatro frequências evocadas e de aproximadamente 57% usando seis diferentes estímulos, considerando janelas de análise de 3 s. Todas as estruturas de classificação testadas no trabalho – função do discriminante linear, ELM e SVM – se mostraram eficientes na tarefa de discriminação das classes. Em particular, a rede ELM, que ainda não havia sido testada neste contexto de análise, se mostrou uma alternativa válida a ser considerada no repertório de classificadores de sistemas BCI, uma vez que é de simples implementação, apresenta boa capacidade de generalização e é computacionalmente rápida, quando comparada às outras técnicas de classificação não lineares.

### **Filtro MVDR**

Neste trabalho também foi proposto o filtro MVDR, uma técnica de filtragem espaço-temporal que contribui tanto na etapa de pré-processamento, para eliminação de ruído e artefatos, quanto na etapa de extração de características, uma vez que é capaz de evidenciar os picos de frequência dos estímulos visuais. O filtro MVDR apresenta um enorme potencial de aplicação na análise e processamento de sinais. No escopo de sistemas BCI-SSVEP ele se torna uma ferramenta interessante, pois sua flexibilidade permite arranjar os eletrodos que capturam os dados e sintonizar o sinal nas frequências dos estímulos visuais. Os experimentos realizados permitiram observar que a filtragem MVDR realmente é capaz de proporcionar ganho de desempenho em sistemas BCI-SSVEP, aprimorando a qualidade dos sistemas em

discriminar entre mais estímulos visuais, além de aumentar a taxa de acerto do sistema para janelas de análise estreitas.

Estes resultados permitem constatar que é possível estabelecer um sistema de transmissão de informações direta entre o cérebro humano e uma máquina usando esta inovadora forma de comunicação. Todavia, são necessárias mais pesquisas e avanços tecnológicos para permitir que as BCIs se tornem uma opção de comunicação popular. Os desafios da multidisciplinariedade envolvidos no desenvolvimento de BCIs fazem com que o desenvolvimento desta tecnologia se dê de maneira plural, possibilitando não só a inovação tecnológica em si, mas trazendo avanços nas diversas áreas do saber a ela conectadas.

No âmbito de processamento de sinais, é necessário intensificar a capacidade de identificação da resposta VEP, mesmo em ambientes ruidosos e susceptíveis a diversos interferentes. E se possível, explorar, juntamente com a neurociência, padrões fisiológicos mais expressivos que permitam fidedignidade na extração de parâmetros em janelas estreita. Além disso, é imprescindível, para a popularização das BCIs, entender melhor a pluralidade do comportamento neurofisiológico e, se possível, determinar pontos de homogeneidade na população, permitindo a padronização dos sistemas.

Outro ponto a ser ressaltado é que o paradigma ERP é promissor para desenvolver aplicações BCIs em que se pressupõe que o usuário esteja disposto a ficar diante de uma tela com estímulos, como em jogos imersivos. De maneira geral, especialmente para aplicações assistivas, o paradigma de imagética é uma escolha mais natural, que permite inclusive um melhor entrosamento entre o indivíduo e a prótese, por exemplo. Neste aspecto, faz-se essencial que a psico-neurologia estabeleça diretrizes que facilitem o treinamento dos indivíduos que devem controlar seus pensamentos, a fim de gerenciar uma dada aplicação. Seria importante compreender como os fatores emocionais e psicológicos interferem nos padrões fisiológicos, isto pode levar a um melhor entendimento do subconsciente humano.

Também são necessários avanços na área de engenharia, computação e física, que possibilitem que as BCIs possam ser utilizadas em ambientes genéricos, sujeitos às mais diferentes interferências, que possam ser direcionadas a pessoas sem conhecimento técnico especializado, que permitam a mobilidade, que garantam segurança e conforto ao usuário e que sejam intuitivas e amigáveis para poderem ser manipuladas por leigos. Inclusive, é importante que a coleta dos sinais cerebrais evolua no sentido de permitir um posicionamento

dos eletrodos de forma não invasiva, mais intuitiva e autônoma, e que os sistemas sejam financeiramente acessíveis.

Até mesmo as ciências humanas são questionadas no desenvolvimento de BCIs, sendo necessário delimitar o alcance da tecnologia na privacidade humana e definir uma política de relacionamento ética, moral, jurídica e filosófica.

Muitos destes pontos estão sendo investigados por diferentes grupos de pesquisas no Brasil e no mundo. Apesar dos inúmeros obstáculos a serem confrontados, é possível antever o enorme potencial das BCIs em desencadear uma revolução na forma de interação que o ser humano tem com as máquinas. Possivelmente, no futuro os sistemas BCIs se tornarão opções frequentes de comunicação.

---

## Referências

- ABBAS, S. N.; ABO-ZAHHAD, M.; AHMED, S. M. State-of-the-Art Methods and Future Perspectives for Personal Recognition Based on Electroencephalogram Signals. **IET Biometrics**, v. 4, n. 3, p. 179–190, 2015.
- AIDLEY, D. J.; STANFIELD, P. R. **Ion Channels: Molecules in Action**. Cambridge University Press, 1996.
- AKAIKE, H. A New Look at the Statistical Model Identification. **Automatic Control, IEEE Transactions on**, v. 19, n. 6, p. 716–723, 1974.
- ALLISON, B. Z. et al. Towards an Independent Brain-Computer Interface Using Steady State Visual Evoked Potentials. **Clinical Neurophysiology**, v. 119, n. 2, p. 399–408, 2008.
- ALLISON, B. et al. BCI Demographics: How many (and What Kinds of) People Can Use an SSVEP BCI? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 18, n. 2, p. 107–116, 2010.
- ALLISON, B. Z.; NEUPER, C. Could Anyone Use a BCI? In: **Brain-Computer Interface**. Springer London, 2010. p. 35–54.
- ALLISON, B. Trends in BCI Research: Progress Today, Backlash Tomorrow?. **XRDS: Crossroads, The ACM Magazine for Students**, v. 18, n. 1, p. 18–22, 2011.
- AMABILE, R. A. DE N. Remoção de Artefatos e Análise de Parâmetros Espectrais em Sinais de EEG: Efeitos do Fármaco Flunitrazepam. **Engenharia Eléctrica**, v. Pos-Gradua, 2008.
- AMIRI, S. et al. A Review of P300, SSVEP, and Hybrid P300/SSVEP Brain-Computer Interface Systems. **Brain-Computer Interface Systems - Recent Progress and Future Prospects**, v. 2013, p. 1–8, 2013.
- ANDERSEN, R. A.; MUSALLAM, S.; PESARAN, B. Selecting the Signals for a Brain-Machine Interface. **Current Opinion in Neurobiology**, v. 14, n. 6, p. 720–726, 2004.
- ATKINS, P.; PAULA, J. **Atkins' Physical Chemistry**. Oxford, 2002.
- BAKARDJIAN, H. Optimization of SSVEP Responses for Robust BCI. **Dissertation**, 2010.
- BAKARDJIAN, H.; TANAKA, T.; CICHOCKI, A. Optimization of SSVEP Brain Responses with Application to Eight-Command Brain-Computer Interface. **Neuroscience Letters**, v. 469, n. 1, p. 34–38, 2010.
- BASHORE, T. R.; MOLEN, M. W. VAN DER. Discovery of the P300: A tribute. **Biological Psychology**, v. 32, n. 2, p. 155–171, 1991.
- BECK, R.; DEMPSTER, A. G.; KALE, I. Finite-Precision Goertzel Filters Used for Signal Tone Detection. **IEEE Transactions on Circuits and Systems II: Analog and Digital**

**Signal Processing**, v. 48, n. 6, p. 691–700, 2001.

BELL, B. M.; PERCIVAL, D. B. A Two Step Burg Algorithm. **IEEE Transactions on Signal Processing**, v. 39, n. 1, p. 185–189, 1991.

BENESTY, J.; CHEN, J.; HUANG, Y. A Generalized MVDR Spectrum. **IEEE Signal Processing Letters**, v. 12, n. 12, p. 827–830, 2005.

BERGER, H. Uber das Elektrenkephalogramm des Menschen. **European Archives of Psychiatry and Clinical Neuroscience**, v. 87, n. 1, p. 527– 570., 1929.

BERGER, T. W., et al. **Brain-Computer Interfaces: An international assessment of research and development trends**. Springer Science & Business Media, 2008.

BERTRAND, O.; PERRIN, F.; PERNIER, J. A Theoretical Justification of the Average Reference in Topographic Evoked Potential Studies. **Electroencephalography and Clinical Neurophysiology/Evoked Potentials Section**, v. 62, n. 6, p. 462–464, 1985.

BIN, G., et al. VEP-Based Brain-Computer Interfaces: Time, Frequency, and Code Modulations. **Computational Intelligence Magazine, IEEE**, v. 4, n. 4, p. 22–26, 2009.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford University Press, 1995.

BISHOP, C. M. **Pattern Recognition an Machine Learning**. New York: Springer, 2006.

BLUM, A. L.; LANGLEY, P. Selection of Relevant Features and Examples in Machine Learning. **Artificial Intelligence**, v. 97, n. 1, p. 245–271, 1997.

BONNET, L.; LOTTE, F.; LÉCUYER, A. Two Brains, One Game: Design and Evaluation of a Multiuser BCI Video Game Based on Motor Imagery. **Transactions on Computational Intelligence and AI in Games - IEEE**, v. 5, n. 2, p. 185–198, 2013.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. In: **Proceedings of the fifth annual workshop on Computational learning theory**. ACM, 1992. p. 144-152.

BRADSHAW, L. A.; WIJESINGHE, R. S.; WIKSWO JR, J. P. **Spatial Filter Approach for Comparison of the Forward and Inverse Problems of Electroencephalography and Magnetoencephalography**Annals of Biomedical Engineering. **Anais...**2001

BRAZIER, M. A. B. **A History of the Electrical Activity of the Brain: The First Half-Century**.

BRUNNER, C., et al. A Comparison of Univariate, Vector, Bilinear Autoregressive, and Band Power Features for Brain-Computer Interfaces. **Medical and Biological Engineering and Computing**, v. 49, n. 11, p. 1337–1346, 2011.

BURGES, C. J. C. A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, v. 2, n. 2, p. 121–167, 1998.

BUTTERWORTH, S. On the Theory of Filter Amplifiers. **Wireless Engineer**, v. 7, n. 6, p.

536–541, 1930.

CARVALHO, S. N. et al. Comparative Analysis of Strategies for Feature Extraction and Classification in SSVEP BCIs. **Biomedical Signal Processing and Control**, v. 21, p. 34–42, 2015.

CATON, R. The Electric Currents of the Brain. **The Journal of Nervous and Mental Disease**, v. 2, n. 4, p. 610, 1875.

CERUTTI, S.; LIBERATI, D.; MASCELLANI, P. Parameter Extraction in EEG Processing During Riskful Neurosurgical Operations. **Signal processing**, v. 9, n. 1, p. 25–35, 1985.

CHAPMAN, R. M.; BRAGDON, H. R. Evoked Responses to Numerical and Non-Numerical Visual Stimuli While Problem Solving. **Nature**, v. 495, n. 203, p. 1155–1157, 1964.

CHATRIAN, G. E.; LETTICH, E.; NELSON, P. L. Ten Percent Electrode System for Topographic Studies of Spontaneous and Evoked EEG Activities. **American Journal of EEG Technology**, v. 25, n. 2, p. 83–92, 1985.

CHENG, M., et al. Design and Implementation of a Brain-Computer Interface with High Transfer Rates. **IEEE Transactions on Biomedical Engineering**, v. 49, n. 10, p. 1181–1186, 2002.

CICHOCKI, A., et al. Noninvasive BCIs: Multiway Signal-Processing Array Decompositions. **IEEE Computer Society**, n. 10, p. 34–42, 2008.

CINCOTTI, F., et al. Non-Invasive Brain-Computer Interface System: Towards its Application as Assistive Technology. **Brain Research Bulletin**, v. 75, n. 6, p. 796–803, 2008.

CORTES, C.; VAPNIK, V. Support-Vector Networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995.

COSTA, T. B. S.; CARVALHO, S. N.; URIBE, L. F. S; FERRARI, R.; SOUZA, R. S.; SORIANO, D. C.; CASTELLANO, G.; ATTUX, R. R. F.; ROMANO, J. M. T.; CARDOZO, E. . Online Brain-Computer Interface Based on Steady-State Visually Evoked Potentials. In: **2nd Brainn Congress**, Campinas. Journal of Epilepsy and Clinical, 2015, v. 21, p. 75, 2015.

COYLE, S. M. et al. Brain-Computer Interface Using a Simplified Functional Near-Infrared Spectroscopy System. **Journal of neural engineering**, v. 4, n. 3, p. 219–26, 2007.

CRISTIANINI, N.; SHAWE-TAYLOR, J. **An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods**. Cambridge University Press, 2000.

CURRAN, E. et al. Cognitive Tasks for Driving a Brain Computer Interfacing System: A Pilot Study. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 12, n. 1, p. 48–54, 2004.

CURRAN, E. A.; STOKES, M. J. Learning to Control Brain Activity: A Review of the Production and Control of EEG Components for Driving Brain-Computer Interface (BCI) Systems. **Brain and Cognition**, v. 51, n. 3, p. 326–336, 2003.

- DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. **IEEE transactions on pattern analysis and machine intelligence**, v. 1, n. 2, p. 224–227, 1979.
- DE HOON, M. J. L. et al. Why Yule-Walker Should Not Be Used for Autoregressive Modelling. **Annals of nuclear energy**, v. 23, n. 15, p. 1219–1228, 1996.
- DIEN, J. Issues in the Application of the Average Reference: Review, Critiques, and Recommendations. **Behavior Research Methods, Instruments and Computers**, v. 30, n. 1, p. 34–43, 1998.
- DORNHEGE, G. **Toward Brain-Computer Interfacing**. MIT Press, 2007.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. John Wiley & Sons, Ltd., 2012.
- EASON, R. G.; HARTEY, M. R.; WHITE, C. T. Effects of Attention and Arousal on Visually Evoked Cortical Potentials and Reaction Time in Man. **Physiology e Behavior**, v. 4, n. 3, p. 283–289, 1969.
- ENGELIEN, A., et al. A Combined Functional in Vivo Measure for Primary and Secondary Auditory Cortices. **Hearing research**, v. 148, n. 1, p. 153-160, 2000.
- FARWELL, L. A.; DONCHIN, E. Talking Off the Top of Your Head: Toward a Mental Prosthesis Utilizing Event-Related Brain Potentials. **Electroencephalography and Clinical Neurophysiology**, v. 70, n. 6, p. 510–523, 1988.
- FARWELL, L. A.; DONCHIN, E. The Truth Will Out: Interrogative Polygraphy (“Lie Detection”) With Event-Related Brain Potentials. **Psychophysiology**, v. 28, n. 5, p. 531–547, 1991.
- FISHER, R. A. The Use of Multiple Measurements in Taxonomic Problems. **Annals of Eugenics**, v. 7, n. 2, p. 179–188, 1936.
- FLOURENS, P. **Expériences Sur le Système Nerveux: Faisant Suite Aux Recherches Expérimentales sur les Propriétés et les Fonctions du Système Nerveux dans les Animaux Vertébrés**. Crevot, 1825.
- FORMAN, G.. An Extensive Empirical Study of Feature Selection Metrics for Text Classification. **The Journal of machine learning research**, v. 3, p. 1289-1305, 2003.
- FRACKOWIAK, Richard SJ et al. Human brain function. **San Diego, CA**, 2004.
- FRIMAN, O.; VOLOSYAK, I.; GRÄSER, A. Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 4, p. 742–50, 2007.
- GTEC. G.tec Medical Engineering. Disponível em: <<http://www.gtec.at/>>. Acesso em: 1 dez. 2015.
- GALAMBOS, R.; MAKEIG, S.; TALMACHOFF, P. J. A 40-Hz Auditory Potential Recorded from the Human Scalp. **Proceedings of the national academy of sciences**, v. 78, n.

4, p. 2643-2647, 1981.

GARCIA-MOLINA, G.; ZHU, D. **Optimal Spatial Filtering for the Steady State Visual Evoked Potential: BCI Application**. Proceedings of International IEEE EMBS Conference on Neural Engineering, 2011.

GATH, I., et al. On the Tracking of Rapid Dynamic Changes in Seizure EEG. **Biomedical Engineering, IEEE Transactions on**, v. 39, n. 9, p. 952-958, 1992.

GODÓI, A. C. B. **Detecção de Potenciais Evocados P300 para Ativação de uma Interface Cérebro-Máquina**. Universidade de São Paulo, 2010.

GOEL, V., et al. Dominant Frequency Analysis of EEG Reveals Brain's Response During Injury and Recovery. **Biomedical Engineering, IEEE Transactions on**, v. 43, n. 11, p. 1083-1092, 1996.

GOERTZEL, G. An Algorithm for the Evaluation of Finite Trigonometric Series. **The American Mathematical Monthly**, v. 65, n. 1, p. 34–35, 1958.

GOLLEE, H. et al. **An SSVEP-Based Brain-Computer Interface for the Control of Functional Electrical Stimulation**. IEEE Transactions on Biomedical Engineering, 2010.

GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. **Brain-Computer Interfaces: A Gentle Introduction**. Springer-Verlag Berlin Heidelberg, 2010.

GUGER, C.; ALLISON, B. Z.; MÜLLER-PUTZ, G. R. **Brain-Computer Interface Research: A State-of-the-Art Summary 4**. Springer International Publishing, 2015.

GUYON, I.; ELISSEEFF, A. An Introduction to Variable and Feature Selection. **Journal of Machine Learning Research**, v. 3, p. 1157–1182, 2003.

HARDOON, D. R.; SZEDMAK, S.; SHAW-TAYLOR, J. Canonical Correlation Analysis: An Overview with Application to Learning Methods. **Neural Computation**, v. 16, n. 12, p. 2639–2664, 2004.

HAYKIN, S. S. **Adaptive Filter Theory**. Pearson Education, 2008.

HERCULANO-HOUZEL, S. The Human Brain in Numbers: A Linearly Scaled-Up Primate Brain. **Frontiers in human neuroscience**, v. 3, n. November, p. 31, 2009.

HERMANN, C. S. Human EEG Responses to 1-100 Hz Flicker: Resonance Phenomena in Visual Cortex and their Potential Correlation to Cognitive Phenomena. **Experimental Brain Research**, v. 137, n. 3-4, p. 346–353, 2001.

HIGASHI, H. et al. **EEG Auditory Steady State Responses Classification for the Novel BCI** Proceedings of International Conference of Engineering in Medicine and Biology Society- IEEE/EMBC, 2011.

HILLE, B. **Ion Channels of Excitable Membranes**. Sunderland: Sinauer, 2001.

HIRSCH, L. J.; BRENNER, R. P. EEG Basics. In: **Atlas of EEG in Critical Care**. John

Wiley & Sons, Ltd., 2010a. p. 1–37.

HIRSCH, L. J.; BRENNER, R. P. EEG in Encephalopathy. In: **Atlas of EGG in Critical Care**. John Wiley & Sons, Ltd., 2010b. p. 39–88.

HOCHBERG, L. R. et al. Neuronal Ensemble Control of Prosthetic Devices by a Human with Tetraplegia. **Nature**, v. 442, n. 7099, p. 164–171, 2006.

HODGKIN, A. L.; HUXLEY, Andrew F. A Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve. **The Journal of physiology**, v. 117, n. 4, p. 500, 1952.

HUANG, G. et al. Trends in Extreme Learning Machines: A Review. **Neural Networks**, v. 61, n. 1, p. 32–48, 2015.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. **Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks** IEEE International Joint Conference on Neural Networks. **Anais...**2004

HUANG, G.-B. et al. Extreme Learning Machine for Regression and Multiclass Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 42, n. 2, p. 513–29, 2012.

HUETTEL, S. A.; MCCARTHY, G. What is Odd in the Oddball Task?: Prefrontal Cortex Is Activated by Dynamic Changes in Response Strategy. **Neuropsychologia**, v. 42, n. 3, p. 379–386, 2004.

IBGE. **Censo Demográfico 2010 - Características Gerais da População, Religião e Pessoas com Deficiência**. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística. Ministério do Planejamento, Orçamento e Gestão, 2010.

JACOBSEN, E.; LYONS, R. The Sliding DFT. **IEEE Signal Processing Magazine**, v. 20, n. 2, p. 74–80, 2003.

JANSEN, B. H.; BOURNE, J. R.; WARD, J. W. Autoregressive Estimation of Short Segment Spectra for Computerized EEG Analysis. **IEEE Transactions on Biomedical Engineering**, v. BME-28, n. 9, p. 630–638, 1981.

JASPER, H. H. The Ten Twenty Electrode System of the International Federation. **Electroencephalography and Clinical Neurophysiology**, v. 10, n. 1, p. 371–375, 1958.

JURCAK, V.; TSUZUKI, D.; DAN, I. 10/20, 10/10, and 10/5 Systems Revisited: Their Validity as Relative Head-Surface-Based Positioning Systems. **Neuroimage**, v. 34, n. 4, p. 1600-1611, 2007.

KAY, S. **Intuitive Probability and Random Processes using MATLAB**. Springer Science & Business Media, 2006.

KENNEDY, P. R., et al. Direct Control of A Computer from the Human Central Nervous System. **Transactions on Rehabilitation Engineering IEEE**, v. 8, n. 2, p. 198–202, 2000.

- KIM, D., et al. Classification of Selective Attention to Auditory Stimuli: Toward Vision-Free Brain-Computer Interfacing. **Journal of neuroscience methods**, v. 197, n. 1, p. 180-185, 2011.
- KOHAVI, R.; JOHN, G. H. Wrappers for Feature Subset Selection. **Artificial Intelligence**, v. 97, n. 1, p. 273-324, 1997.
- KRISTENSEN, C. H.; ALMEIDA, R. M. M. DE; GOMES, W. B. Desenvolvimento Histórico e Fundamentos Metodológicos da Neuropsicologia Cognitiva. **Psicologia: Reflexão e Crítica**, v. 14, n. 2, p. 259-274, 2001.
- KRUEGER-BECK, E., et al. Potencial de Ação: do Estímulo à Adaptação Neural. **Fisioter Mov**, v. 24, n. 3, p. 535-47, 2011.
- KULAIIF, A. C. P.; ZUBEN, F. J. VON. **Improved Regularization in Extreme Learning Machines** Anais do Congresso Brasileiro de Inteligência Computacional (CBIC), 2013.
- LAFLEUR, K. et al. Quadcopter Control in Three-Dimensional Space Using A Noninvasive Motor Imagery-Based Brain-Computer Interface. **Journal of Neural Engineering**, v. 10, n. 4, p. 46003, 2013.
- LENHARDT, A.; KAPER, M.; RITTER, H. J. An Adaptive P300-Based Online Brain-Computer Interface. **Transactions on Neural Systems and Rehabilitation Engineering**, v. 16, n. 2, p. 121-130, 2008.
- LEUTHARDT, E. C. et al. A Brain-Computer Interface Using Electrographic Signals in Humans. **Journal of Neural Engineering**, v. 1, n. 2, p. 63, 2004.
- LI, Y. et al. A Hybrid BCI System Combining P300 and SSVEP and Its Application to Wheelchair Control. **IEEE Transactions on Biomedical Engineering**, v. 60, n. 11, p. 3156-3166, 2013.
- LIN, Z., et al. Frequency Recognition Based on Canonical Correlation Analysis for SSVEP-Based BCIs. **Biomedical Engineering, IEEE Transactions on**, v. 53, n. 12, p. 2610-2614, 2006.
- MACHADO, A. **Neuroanatomia Funcional**. Atheneu, 2005.
- MARTINEZ, P.; BAKARDJIAN, H.; CICHOCKI, A. Fully Online Multicommand Brain-Computer Interface with Visual Neurofeedback Using SSVEP Paradigm. **Computational Intelligence and Neuroscience**, 2007.
- MASON, S. G. et al. **A Comprehensive Survey of Brain Interface Technology Design** Annals of Biomedical Engineering, 2007.
- MAYNARD, E. M.; NORDHAUSEN, C. T.; NORMANN, R. A. The Utah Intracortical Electrode Array: A Recording Structure for Potential Brain-Computer Interfaces. **Electroencephalography and Clinical Neurophysiology**, v. 102, n. 3, p. 228-239, 1997.
- MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

- MCFARLAND, D. J. et al. Spatial Filter Selection for EEG-Based Communication. **Electroencephalography and Clinical Neurophysiology**, v. 103, n. 3, p. 386–394, 1997.
- MCFARLAND, D. J.; WOLPAW, J. R. Brain-Computer Interface Operation of Robotic and Prosthetic Devices. **Computer**, n. 10, p. 52–56, 2008.
- MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. **Communications of the ACM**, v. 54, n. 5, p. 60-66, 2011.
- MEISTER, I. G., et al. Playing Piano in the Mind - An fMRI Study on Music Imagery and Performance in Pianists. **Cognitive Brain Research**, v. 19, n. 3, p. 219–228, 2004.
- MELLINGER, J., et al. An MEG-Based Brain-Computer Interface (BCI). **NeuroImage**, v. 36, n. 3, p. 581–593, 2007.
- MILLÁN, J. D. R., et al. Combining Brain-Computer Interfaces and Assistive Technologies: State-of-the-Art and Challenges. **Frontiers in Neuroscience**, v. 4, p. 1–15, 2010.
- MINER, L. A.; MCFARLAND, D. J.; WOLPAW, J. R. Answering Questions with an Electroencephalogram-Based Brain-Computer Interface. **Archives of Physical, Medicine and Rehabilitation**, v. 79, n. 9, p. 1029–1033, 1998.
- MORA, N., et al. **Simple and Efficient Methods for Steady State Visual Evoked Potential Detection in BCI Embedded System**. IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP), 2014.
- MORA, N.; MUNARI, I. D.; CIAMPOLINI, P. **Subject-Independent, SSVEP-Based BCI: Trading Off Among Accuracy, Responsiveness and Complexity**. Proceedings of Annual International IEEE EMBS. Montpellier, France. 2015.
- MULERT, C.; LEMIEUX, L. **EEG-fMRI: Physiological Basis, Technique, and Applications**. Springer Science & Business Media, 2009.
- MULLER, J. **Elements of Physiology**. Lea and Blanchard, 1843.
- MULLER, S. M. T., et al. **Spectral Techniques for Incremental SSVEP Analysis Applied to a BCI Implementation**. V Latin American Congress on Biomedical Engineering (CLAIB). Havana, Cuba: Springer Berlin Heidelberg, 2013.
- MULLER-PUTZ, G. R., et al. Steady-state somatosensory evoked potentials: suitable brain signals for brain-computer interfaces? **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 14, n. 1, p. 30–37, 2006.
- MUTHUSWAMY, J.; THAKOR, N. V. Spectral Analysis Methods for Neurological Signals. **Journal of Neuroscience Methods**, v. 83, n. 1, p. 1–14, 1998.
- NAGAOKA, T. et al. Development of a New Rehabilitation System Based on a Brain-Computer Interface Using Near-Infrared Spectroscopy. In: **Oxygen Transport to Tissue XXXI**. p. 497–503.
- NAN, W. et al. **A Comparison of Minimum Energy Combination and Canonical**

- Correlation Analysis for SSVEP Detection.** Proceedings of International IEEE EMBS Conference on Neural Engineering. Cancun, Mexico. 2011.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain Computer Interfaces, a Review. **Sensors**, v. 12, n. 2, p. 1211–1279, 2012.
- NICOLELIS, M. A. L. Actions from Thoughts. **Nature**, v. 409, n. 6818, p. 403–407, 2001.
- NIJBOER, F. et al. An Auditory Brain-Computer Interface (BCI). **Journal of Neuroscience Methods**, v. 167, n. 1, p. 43–50, 2008.
- NUTTALL, A. H.; CARTER, G. C. A Generalized Framework for Power Spectral Estimation. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 28, n. 3, p. 334–335, 1980.
- OOSTENVELD, R.; PRAAMSTRA, P. The Five Percent Electrode System for High-Resolution EEG and ERP Measurements. **Clinical Neurophysiology**, v. 112, n. 4, p. 713-719, 2001.
- OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-Time Signal Processing**. Prentice Hall, 1999.
- PALANIAPPAN, R. **Identifying Individuality Using Mental Task Based Brain Computer Interface.** Conference on Intelligent Sensing and Information Processing - ICISIP-IEEE. **Anais...2005**
- PARK, S. A. et al. Evaluation of Feature Extraction Methods for EEG-Based Brain-Computer Interfaces in Terms of Robustness to Slight Changes in Electrode Locations. **Medical and Biological Engineering and Computing**, v. 51, n. 5, p. 571–579, 2013.
- PARKER, S. **Como a Mente Funciona**. Companhia das Letras, 2004.
- PFURTSCHELLER, G.; FLOTZINGER, D.; NEUPER, C. Differentiation Between Finger, Toe and Tongue Movement in Man Based on 40 Hz EEG. **Electroencephalography and clinical neurophysiology**, v. 90, n. 6, p. 456-460, 1994
- PFURTSCHELLER, G.; NEUPER, C. **Motor Imagery and Direct Brain-Computer Communication.** Proceedings of the IEEE, 2001.
- PHAM, D. T.; LE BRETON, A. Levinson-Durbin-Type Algorithms for Continuous-Time Autoregressive Models and Applications. **Mathematics of Control, Signals and Systems**, v. 4, n. 1, p. 69–79, 1991.
- PHINYOMARK, A.; LIMSAKUL, C.; PHUKPATTARANONT, P. A Novel Feature Extraction for Robust EMG Pattern Recognition. **ArXiv Preprint**, v. 912, n. 3973, 2009.
- PINEDA, J. A.; ALLISON, B. Z.; VANKOV, A. The Effects of Self-Movement, Observation, and Imagination on  $\mu$  Rhythms and Readiness Potentials (RP's): Toward a Brain-Computer Interface (BCI). **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 219–222, 2000.

- POLAK, M.; KOSTOV, A. **Feature Extraction in Development of Brain-Computer Interface: A Case Study**. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 1998.
- PORYZALA, P.; MATERKA, A. Cluster Analysis of CCA Coefficients for Robust Detection of the Asynchronous SSVEPs in Brain-Computer Interfaces. **Biomedical Signal Processing and Control**, v. 10, p. 201–208, 2014.
- POWER, S. D.; FALK, T. H.; CHAU, T. Classification of Prefrontal Activity Due to Mental Arithmetic and Music Imagery Using Hidden Markov Models and Frequency Domain Near-Infrared Spectroscopy. **Journal of Neural Engineering**, v. 7, n. 2, p. 26002, 2010.
- QIN, L.; DING, L.; HE, B. Motor Imagery Classification by Means of Source Analysis for Brain-Computer Interface Applications. **Journal of Neural Engineering**, v. 1, n. 3, p. 135, 2004.
- RANTA, R.; SALIDO-RUIZ, R.; LOUIS-DORR, V. **Reference Estimation in EEG Recordings**. Annual International Conference of Engineering in Medicine and Biology - IEEE/EMBC, 2010.
- REBSAMEN, B. et al. A brain controlled wheelchair to navigate in familiar environments. **Neural Systems and Rehabilitation Engineering, IEEE Transactions on**, v. 18, n. 6, p. 590-598, 2010.
- REGAN, D. Steady-State Evoked Potentials. **Journal of the Optical Society of America**, v. 67, n. 11, p. 1475–1489, 1977a.
- REGAN, D. Evoked Potentials in Basic and Clinical Research. In: **EEG Informatics. A Didactic Review of Methods and Applications of EEG Data Processing**. [Elsevier Amsterdam, 1977b. p. 319–347.
- ROSENBLATT, F. Principles of Neurodynamics: Perceptrons and the Theory of. **Brain Mechanisms**, p. 555-559, 1962.
- ROSS, B.; PICTON, T. W.; PANTEV, C. Temporal Integration in the Human Auditory Cortex as Represented by the Development of the Steady-State Magnetic Field. **Hearing research**, v. 165, n. 1, p. 68-84, 2002.
- ROSS, Bernhard et al. Frequency Specificity of 40-Hz Auditory Steady-State Responses. **Hearing research**, v. 186, n. 1, p. 57-68, 2003.
- SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. John Wiley & Sons, Ltd., 2007.
- SCHREUDER, M.; BLANKERTZ, B.; TANGERMANN, M. A New Auditory Multi-Class Brain-Computer Interface Paradigm: Spatial Hearing As An Informative Cue. **Plos One**, v. 5, n. 4, p. e9813, 2010.
- SEMMLOW, J. L. **Biosignal and Biomedical Image Processing: MATLAB-Based Applications**. New York: Marcel Dekker, Inc., 2004.

- SENHADJI, L.; BELLANGER, J. J.; CARRAULT, G. EEG Spike Detectors Based on Different Decompositions: A Comparative Study. In: **Time frequency and wavelets in biomedical signal processing**. p. 407–421, 1997.
- SILVA, F. L. DA. EEG: Origin and Measurement. In: **EEG-fMRI**. Amsterdam: Springer Berlin Heidelberg, 2010. p. 19–38.
- SITARAM, R. et al. Temporal Classification of Multichannel Near-Infrared Spectroscopy Signals of Motor Imagery for Developing a Brain-Computer Interface. **NeuroImage**, v. 34, n. 4, p. 1416–1427, 2007.
- SLENES, G. F. et al. **The Use of fMRI for the Evaluation of the Effect of Training in Motor Imagery BCI Users**. Proceedings of International IEEE EMBS Conference on Neural Engineering, 2013.
- SORIANO, D. et al. **Music Versus Motor Imagery for BCI Systems a Study Using fMRI and EEG: Preliminary Results**. Biosignals and Biorobotics Conference, 2013.
- SOUTELLO, L. F. M. G. et al. **Análise Preliminar de Diferentes Padrões de Estimulação em Interfaces Cérebro-Computador Baseadas em SSVEP**. Anais do EADCA-Unicamp., 2015.
- SUTTON, S. et al. Evoked-Potential Correlates of Stimulus Uncertainty. **Science**, v. 150, n. 3700, p. 1187–1188, 1965.
- SUTTON, S. et al. Information Delivery and the Sensory Evoked Potential. **Science**, v. 155, n. 3768, p. 1436–1439, 1967.
- TAVARES, T. V. et al. **Análise de Técnicas de Filtragem Espacial em Sistemas BCI-SSVEP**. Anais do Simpósio de Processamento de Sinais da Unicamp, 2015.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. California: Academic Press, 2010.
- URIBE, L. F. et al. A Recurrence-Based Approach for Feature Extraction in Brain-Computer Interface Systems. In: **Translational Recurrences**. Springer International Publishing, 2014. p. 95–107.
- VAPNIK, V. N. **Estimation of Dependences Based on Empirical Data**. New York: Springer-Verlag, 1982.
- VIDAL, J. J. Toward Direct Brain-Computer Communication. **Annual review of Biophysics and Bioengineering**, v. 2, n. 1, p. 157-180, 1973.
- VIDAL, J. J. Real-Time Detection of Brain Events in EEG. **Proceedings of the IEEE**, v. 65, n. 5, p. 633–641, 1977.
- WAELE, S. DE; BROERSEN, P. M. T. The Burg Algorithm for Segments. **IEEE Transactions on Signal Processing**, v. 48, n. 10, p. 2876–2880, 2000.
- WALTER, G. Slow Potential Waves in the Human Brain Associated with Expectancy,

- Attention and Decision. **European Archives of Psychiatry and Clinical Neuroscience**, v. 206, n. 3, p. 309–322, 1964.
- WANG, H. et al. An Asynchronous Wheelchair Control by Hybrid EEG–EOG Brain-Computer Interface. **Cognitive Neurodynamics**, v. 8, n. 5, p. 399–409, 2014.
- WANG, N. et al. Discrimination Between Idle and Work States in BCI Based on SSVEP. **Proceedings of IEEE International Conference on Advanced Computer Control**, v. 4, n. 1, p. 355–358, 2010.
- WANG, W., et al. An Electrographic Brain Interface in an Individual with Tetraplegia. **PloS one**, v. 8, n. 2, p. e55344, 2013.
- WANG, Y.; CAO, F.; YUAN, Y. A Study on Effectiveness of Extreme Learning Machine. **Neurocomputing**, v. 74, n. 16, p. 2483–2490, 2011.
- WANG, Y.; WANG, Y. T.; JUNG, T. P. Visual Stimulus Design for High-Rate SSVEP BCI. **Electronics Letters**, v. 46, n. 15, p. 1, 2010.
- WELCH, P. D. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. **IEEE Transactions on audio and electroacoustics**, v. 15, n. 2, p. 70–73, 1967.
- WOLPAW, J. R. et al. An EEG-Based Brain-Computer Interface for Cursor Control. **Electroencephalography and Clinical Neurophysiology**, v. 78, n. 3, p. 252–259, 1991.
- WOLPAW, J. R. et al. Brain-Computer Interface Technology: A Review of the First International Meeting. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 164–173, 2000.
- WOLPAW, J. R. et al. Brain-Computer Interfaces for Communication and Control. **Clinical Neurophysiology**, v. 113, n. 6, p. 767–91, 2002.
- WOLPAW, J. R.; MCFARLAND, Dennis J. Control of a Two-Dimensional Movement Signal by a Noninvasive Brain-Computer Interface in Humans. **Proceedings of the National Academy of Sciences of the United States of America**, v. 101, n. 51, p. 17849–17854, 2004.
- ZHU, D. et al. A Survey of Stimulation Methods Used in SSVEP-Based BCIs. **Computational Intelligence and Neuroscience**, 2010.

## Apêndice A

A Figura A.1 apresenta o desempenho individual dos sete voluntários em cada um dos 36 cenários do experimento descrito na Subseção 4.3.1 e elenca os eletrodos seleccionados em cada configuração.

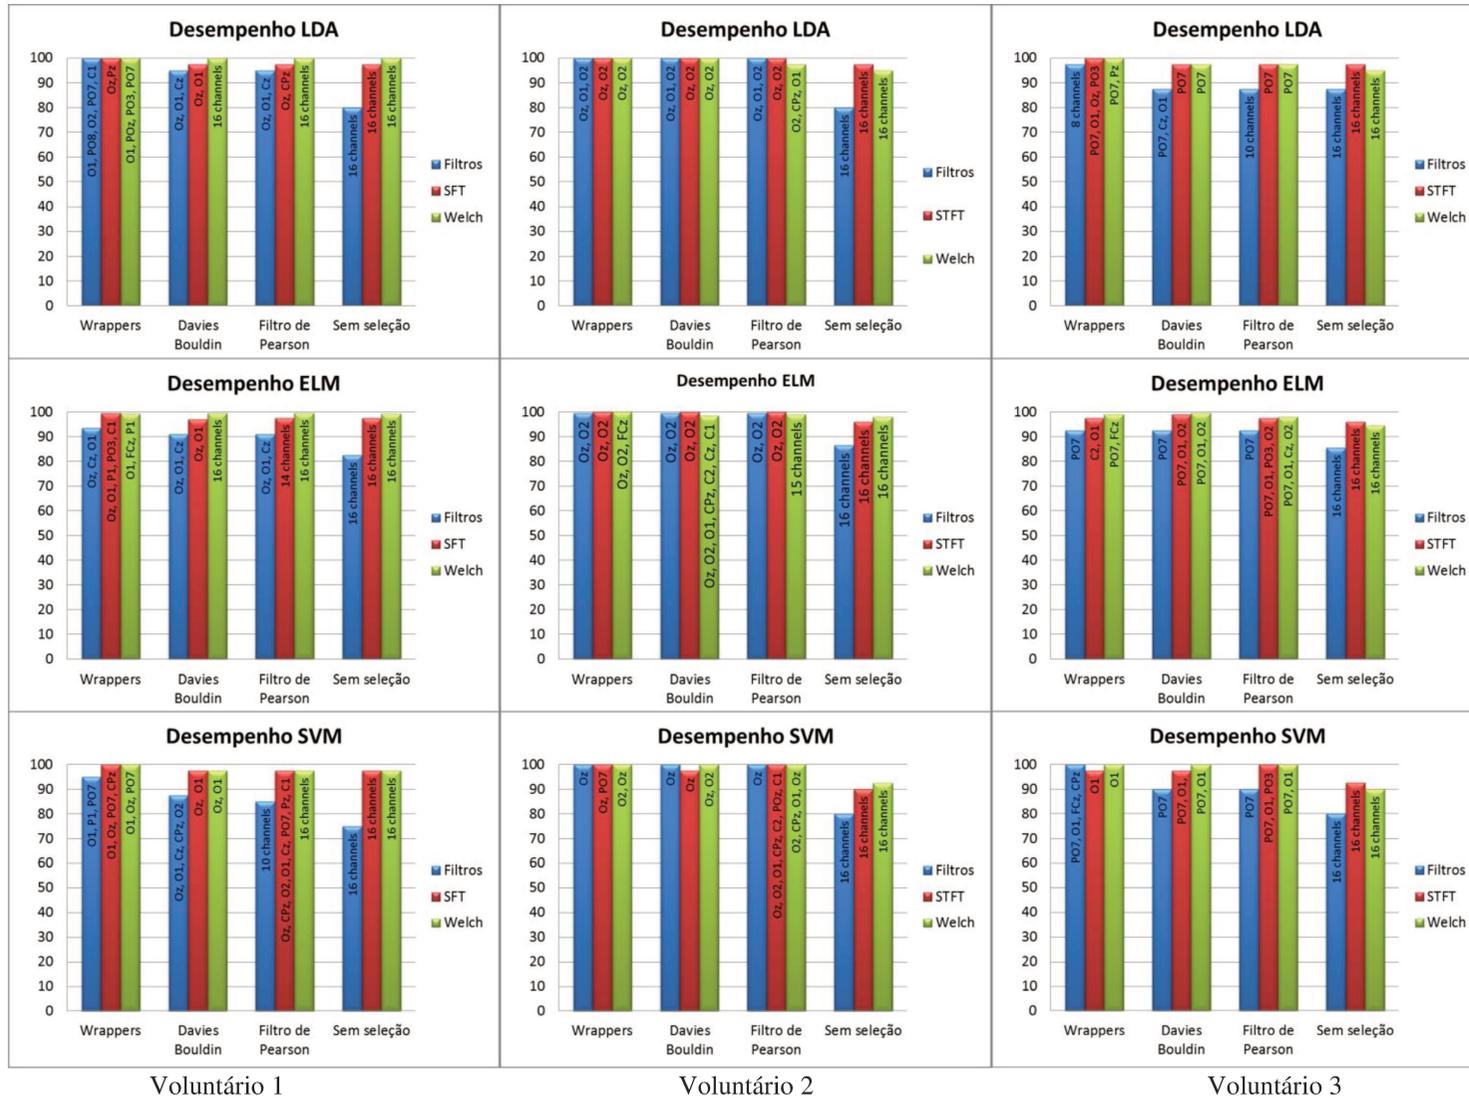
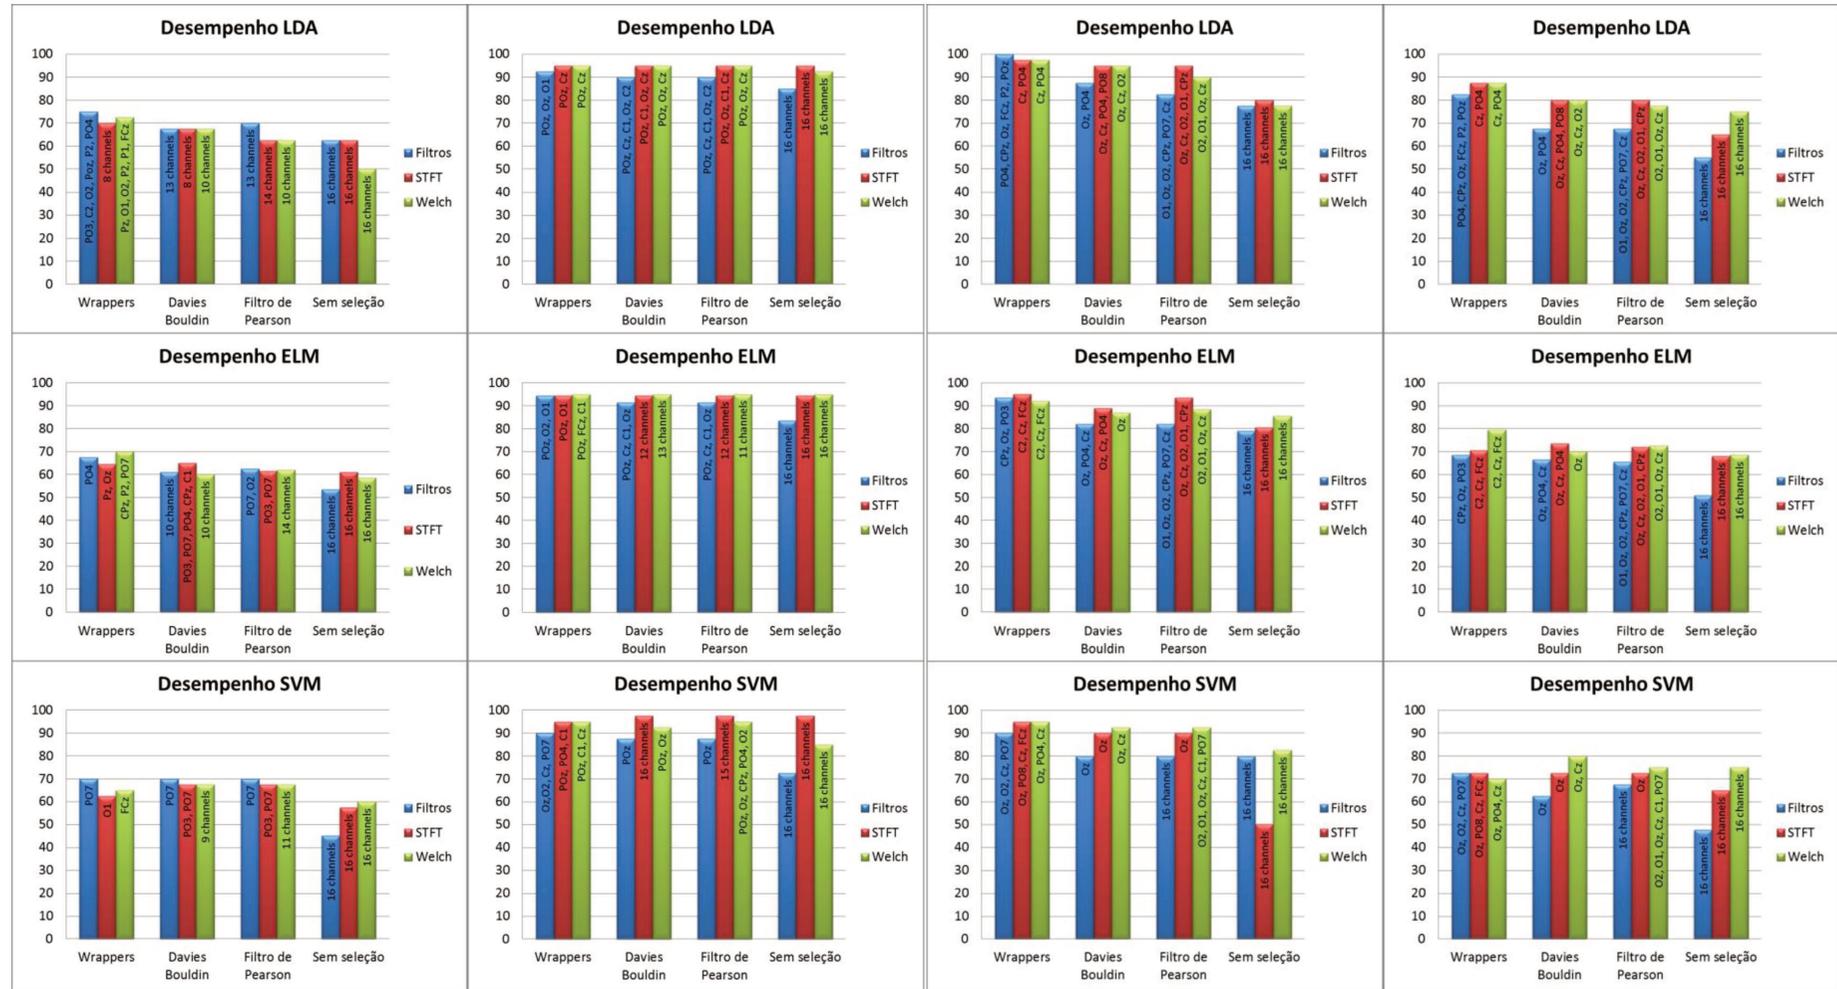


Figura A.1 – Desempenho dos sete voluntários para cada cenário.



Voluntário 4

Voluntário 5

Voluntário 6

Voluntário 7

Figura A.1 – Desempenho dos sete voluntários para cada cenário (continuação).

## Anexo A - Parecer do Comitê de Ética



FACULDADE DE CIÊNCIAS MÉDICAS  
COMITÊ DE ÉTICA EM PESQUISA

[www.fcm.unicamp.br/pesquisa/etica/index.html](http://www.fcm.unicamp.br/pesquisa/etica/index.html)

CEP, 13/10/10  
(Grupo III)

**PARECER CEP:** N° 791/2010 (Este n° deve ser citado nas correspondências referente a este projeto).  
**CAAE:** 0617.0.146.000-10

### I - IDENTIFICAÇÃO:

**PROJETO:** “DESENVOLVIMENTO DE TECNOLOGIA DE INFORMAÇÃO PARA NEUROLOGIA - DESTINE”.

**PESQUISADOR RESPONSÁVEL:** Li Li Min

**INSTITUIÇÃO:** Hospital das Clínicas/UNICAMP

**APRESENTAÇÃO AO CEP:** 11/08/2010

**APRESENTAR RELATÓRIO EM:** 13/10/11 (O formulário encontra-se no *site* acima).

### II - OBJETIVOS

Referente à parte do departamento de neurologia: mapear as regiões de maior 'atividade elétrica cerebral' de pacientes que sofreram um AVC para otimizar (para cada paciente, individualmente) a captação dos sinais cerebrais proporcionados por estímulos voluntários. O objetivo é que esses sinais sejam posteriormente captados e utilizados a proporcionar um melhor controle de cadeiras de rodas motorizadas através da 'evocação' dos estímulos voluntários previamente mapeados. Além do 'mapeamento cerebral', são previstos exames físicos e aplicação de questionários (instrumentos de avaliação) para melhor caracterizar o comprometimento neurológico e fatores referentes à qualidade de vida dos pacientes.

### III - SUMÁRIO

O projeto é interdisciplinar (envolvendo a Faculdade de Engenharia Elétrica, a Faculdade de Ciências Médicas e o Instituto de Física da UNICAMP, bem como o Centro de Tecnologia da Informação Renato Archer) e prevê um esforço muito grande na parte da engenharia envolvida na captação dos sinais cerebrais dos pacientes que sofreram AVC, no processamento desses sinais, e de sua 'interface' com cadeiras de rodas motorizadas. É lembrado que pacientes que sofreram AVC frequentemente se encontram incapacitados tanto do exercício de atividades motoras (através das quais uma cadeira motorizada poderia ser comandada por um joystick) como da suas capacidades vocais (através da qual uma cadeira motorizada poderia ser comandada pela voz). Referente ao mapeamento das 'melhores regiões/melhores estímulos' de atividade cerebral deve ser feito caso-a-caso, e levará em conta, além de aquisições de eletroencefalograma (EEG), informações oriundas de técnicas de neuroimagem como a ressonância magnética funcional (fMRI) e a tomografia proporcionada pela técnica de espectometria no infravermelho próximo (NIRS)

### IV - COMENTÁRIOS DOS RELATORES

Após respostas às pendências, o projeto encontra-se adequadamente redigido e de acordo com a Resolução CNS/MS 196/96 e suas complementares, bem como o Termo de Consentimento Livre e Esclarecido.

**FACULDADE DE CIÊNCIAS MÉDICAS  
COMITÊ DE ÉTICA EM PESQUISA**

[www.fcm.unicamp.br/pesquisa/etica/index.html](http://www.fcm.unicamp.br/pesquisa/etica/index.html)

**V - PARECER DO CEP**

O Comitê de Ética em Pesquisa da Faculdade de Ciências Médicas da UNICAMP, após acatar os pareceres dos membros-relatores previamente designados para o presente caso e atendendo todos os dispositivos das Resoluções 196/96 e complementares, resolve aprovar sem restrições o Protocolo de Pesquisa, bem como ter aprovado o Termo do Consentimento Livre e Esclarecido, assim como todos os anexos incluídos na Pesquisa supracitada.

O conteúdo e as conclusões aqui apresentados são de responsabilidade exclusiva do CEP/FCM/UNICAMP e não representam a opinião da Universidade Estadual de Campinas nem a comprometem.

**VI - INFORMAÇÕES COMPLEMENTARES**

O sujeito da pesquisa tem a liberdade de recusar-se a participar ou de retirar seu consentimento em qualquer fase da pesquisa, sem penalização alguma e sem prejuízo ao seu cuidado (Res. CNS 196/96 – Item IV.1.f) e deve receber uma cópia do Termo de Consentimento Livre e Esclarecido, na íntegra, por ele assinado (Item IV.2.d).

Pesquisador deve desenvolver a pesquisa conforme delineada no protocolo aprovado e descontinuar o estudo somente após análise das razões da descontinuidade pelo CEP que o aprovou (Res. CNS Item III.1.z), exceto quando perceber risco ou dano não previsto ao sujeito participante ou quando constatar a superioridade do regime oferecido a um dos grupos de pesquisa (Item V.3.).

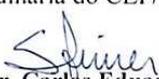
O CEP deve ser informado de todos os efeitos adversos ou fatos relevantes que alterem o curso normal do estudo (Res. CNS Item V.4.). É papel do pesquisador assegurar medidas imediatas adequadas frente a evento adverso grave ocorrido (mesmo que tenha sido em outro centro) e enviar notificação ao CEP e à Agência Nacional de Vigilância Sanitária – ANVISA – junto com seu posicionamento.

Eventuais modificações ou emendas ao protocolo devem ser apresentadas ao CEP de forma clara e sucinta, identificando a parte do protocolo a ser modificada e suas justificativas. Em caso de projeto do Grupo I ou II apresentados anteriormente à ANVISA, o pesquisador ou patrocinador deve enviá-las também à mesma junto com o parecer aprovatório do CEP, para serem juntadas ao protocolo inicial (Res. 251/97, Item III.2.e)

Relatórios parciais e final devem ser apresentados ao CEP, de acordo com os prazos estabelecidos na Resolução CNS-MS 196/96.

**VII- DATA DA REUNIÃO**

Homologado na VIII Reunião Ordinária do CEP/FCM, em 24 de agosto de 2010.

  
**Prof. Dr. Carlos Eduardo Steiner**  
PRESIDENTE do COMITÊ DE ÉTICA EM PESQUISA  
FCM / UNICAMP



CEP, 24/06/14.  
(PARECER CEP: Nº 791/2010)

Universidade Estadual de Campinas  
Pró-Reitoria de Pesquisa  
Comitê de Ética em Pesquisa



## PARECER

### I – IDENTIFICAÇÃO:

PROJETO: “DESENVOLVIMENTO DE TECNOLOGIA DE INFORMAÇÃO PARA NEUROLOGIA - DESTINE”.

PESQUISADOR RESPONSÁVEL: Li Li Min

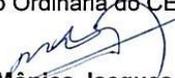
### II – PARECER DO CEP.

O Comitê de Ética em Pesquisa da Universidade Estadual de Campinas tomou ciência e aprovou a solicitação de adendo para inclusão da Prof.<sup>a</sup> Gabriela Castellano ao estudo, a inclusão dos indivíduos sadios no estudo, bem como a versão do Termo de Consentimento Livre e Esclarecido para voluntários saudáveis, do protocolo de pesquisa supracitado.

O conteúdo e as conclusões aqui apresentados são de responsabilidade exclusiva do CEP/UNICAMP e não representam a opinião da Universidade Estadual de Campinas nem a comprometem.

### III – DATA DA REUNIÃO.

Homologado na V Reunião Ordinária do CEP/UNICAMP, em 24 de junho de 2014.

  
**Dra. Mônica Jacques de Moraes**  
VICE-COORDENADORA DO COMITÊ DE ÉTICA EM PESQUISA  
UNICAMP

---

## **Anexo B - Termo de Consentimento Livre e Esclarecido - Pacientes**

Desenvolvimento de Tecnologia de Informação para Neurologia

Pesquisador responsável: Prof. Dr. Li Li Min

Eu, \_\_\_\_\_,  
idade \_\_\_\_\_, endereço \_\_\_\_\_,  
profissão \_\_\_\_\_, declaro ter conhecimento sobre a pesquisa  
“Desenvolvimento de Tecnologia de Informação para Neurologia” que tem como objetivo  
geral avaliar o uso de sistemas de computadores em pacientes com lesão do cérebro para a  
reabilitação. Espera-se com esta pesquisa, desenvolver novos sistemas de computadores e  
equipamentos que auxiliem pessoas com algum tipo de lesão cerebral ou paralisia a  
possibilidade de se mover novamente com esses equipamentos. O procedimento envolve  
utilização de uma entrevista com questionários, exame físico para avaliar a gravidade da lesão  
cerebral existente. O participante é submetido a um exame de ressonância magnética,  
eletroencefalografia, tomografia de luz próximo da faixa de infravermelho para avaliar as  
estruturas cerebrais e seu funcionamento. O participante pode ser convidado mais de uma vez  
para realizar esses exames para aumentar a precisão dos resultados. Além disso, o participante  
pode ser solicitado para testar alguns equipamentos em desenvolvimento, neste caso seriam  
realizados os exames de eletroencefalografia e ou tomografia de luz próximo da faixa de  
infravermelho com o intuito de captar sinais cerebrais para comandar os equipamentos,  
exemplo comandar uma cadeira de rodas à distância, sem estar sentado nela e sem fazer  
esforço físico.

É de meu conhecimento que a minha participação nesta pesquisa não implica em  
nenhum benefício pessoal, não é obrigatória e não trará riscos previsíveis. Os riscos possíveis  
são mínimos, relacionados aos procedimentos clínicos não invasivos, tais como, alergia ao gel  
da eletroencefalografia. Neste caso, o paciente será orientado como proceder adequadamente,  
porém não haverá ressarcimento nem compensações por estes danos.

Caso queira, sei que posso desistir a qualquer momento, sem que isso me cause prejuízo. Serei, portanto, acompanhado e assistido pelo pesquisador responsável e a sua equipe durante esses procedimentos, podendo fazer perguntas sobre qualquer dúvida que apareça durante todo o estudo. Não haverá nenhuma forma de reembolso de dinheiro.

Diante disso, aceito participar voluntariamente desta pesquisa, sabendo que os dados coletados estarão sob o resguardo científico e o sigilo profissional, e contribuirão para o alcance dos objetivos deste trabalho e para posteriores publicações dos dados.

Para quaisquer reclamações referentes à abuso ou procedimentos não éticos por parte do pesquisador, sei que posso ligar para o Comitê de Ética em Pesquisa da UNICAMP (Rua: Tessália Vieira de Camargo, 126 - Caixa Postal 6111 13083-887. Campinas – SP, telefone 3521-8936; fax 3521-7187; e-mail: cep@fcm.unicamp.br) ou para o pesquisador responsável, Li Li Min, no ambulatório de Neurologia (3521-7754). Para isso, receberei uma cópia deste termo por mim assinado.

---

Assinatura do participante

---

Assinatura do responsável

---

Assinatura do pesquisador

Campinas, \_\_\_\_/\_\_\_\_/20\_\_\_\_

---

## **Anexo C - Termo de Consentimento Livre e Esclarecido - Voluntários Saudáveis**

DESTINE: Desenvolvimento de Tecnologia de Informação para Neurologia

Pesquisadores responsáveis: Prof. Dr. Li Li Min e Profa. Dra. Gabriela Castellano

Você está sendo convidado a participar da pesquisa “Desenvolvimento de Tecnologia de Informação para Neurologia”, que tem como objetivo geral avaliar o uso de sistemas de computadores em pacientes com lesão do cérebro para a reabilitação. Espera-se com esta pesquisa desenvolver novos sistemas de computadores e equipamentos que auxiliem pessoas com algum tipo de lesão cerebral ou paralisia para que tenham a possibilidade de se mover ou se comunicar novamente com esses equipamentos. Para isso, serão feitos experimentos também com voluntários saudáveis, como é o seu caso.

Você poderá ser submetido a três tipos de exames: ressonância magnética (RM), eletroencefalografia (EEG) e tomografia de luz próximo da faixa de infravermelho (NIRS), para avaliar as estruturas cerebrais e seu funcionamento. Você poderá ser convidado mais de uma vez para realizar esses exames para aumentar a precisão dos resultados. Além disso, você poderá ser solicitado para testar alguns equipamentos em desenvolvimento, neste caso seriam realizados os exames de EEG e/ou NIRS com o intuito de captar sinais cerebrais para comandar os equipamentos, por exemplo, comandar uma cadeira de rodas à distância, sem estar sentado nela e sem fazer esforço físico. Todos esses exames são não invasivos, e nenhum deles utiliza radiação ionizante.

No exame de RM, você entrará na máquina de RM e lá permanecerá, deitado e imóvel, por volta de 30 a 60 minutos. Durante esse tempo a máquina medirá sinais provenientes do seu cérebro e fará imagens do mesmo. O exame não causa nenhuma dor e também não possui nenhum efeito nocivo para o corpo humano – em particular, nesta pesquisa não será feito nenhum exame de RM usando contraste. No entanto, você poderá sentir desconforto devido ao grande barulho que a máquina faz (para isso serão fornecidos tampões de ouvido), e ao fato de que você deverá permanecer o mais imóvel possível dentro da máquina, para que os sinais possam ser medidos de forma correta. Além disso, devido a

que o campo magnético usado na máquina de RM é alto (como um forte ímã), caso você possua algum metal dentro do seu corpo (como pinos, marca-passos, próteses metálicas, balas de revólver), não poderá, de nenhuma maneira, realizar o exame, e **NÃO DEVE DEIXAR DE AVISAR** o pesquisador responsável (que estiver realizando os exames). Por esse motivo também, antes de entrar na sala da RM, você deverá remover do corpo qualquer objeto metálico, como anéis, brincos, pulseiras e óculos, etc. Também é importante que você remova objetos magnetizados como cartões de crédito, pois eles podem ser apagados ou danificados pelo campo magnético.

No caso dos exames de EEG e NIRS, uma touca com vários sensores será colocada sobre sua cabeça, para a medida dos seus sinais cerebrais. Esses exames também não possuem nenhum efeito nocivo para o corpo humano, mas você poderá sentir dor e desconforto devido ao contato apertado e prolongado dos sensores sobre o couro cabeludo, devido a que a touca deve ser colocada bem apertada para poder medir bem o sinal. Para evitar ou minimizar esse desconforto, é importante que você avise a pessoa que estiver colocando a touca em você, sobre qualquer desconforto que sentir no momento da colocação da mesma. Você também poderá, se quiser, interromper a aquisição em qualquer momento que deseje e os sensores serão retirados, sem que isso acarrete nenhum prejuízo para sua pessoa.

A sua participação nesta pesquisa não implicará em nenhum benefício pessoal, não é obrigatória e não trará riscos previsíveis. Os riscos possíveis são mínimos, relacionados aos procedimentos clínicos não invasivos, descritos acima. Você não receberá nenhum pagamento por sua participação nesta pesquisa, mas caso venha a ter despesas de transporte ou alimentação para poder realizar estes exames, elas serão ressarcidas.

Caso queira, você poderá desistir da sua participação a qualquer momento, sem que isso lhe cause prejuízo. Você será acompanhado e assistido pelo pesquisador responsável e a sua equipe durante esses procedimentos, podendo fazer perguntas sobre qualquer dúvida que apareça durante todo o estudo. Os dados coletados estarão sob o resguardo científico e o sigilo profissional, e contribuirão para o alcance dos objetivos deste trabalho e para posteriores publicações dos dados.

Para quaisquer dúvidas, você pode contactar os pesquisadores responsáveis deste projeto: o Dr. Li Li Min, no ambulatório de Neurologia (tel: 19 3521 7754, email: limin@fcm.unicamp.br, endereço: Departamento de Neurologia, Faculdade de Ciências Médicas, UNICAMP, Rua Tessália Vieira de Camargo, 126, CEP 13083-887, Campinas, SP),

ou a Dra. Gabriela Castellano (tel: 19 3521 5519, email: gabriela@ifi.unicamp.br, endereço: Departamento de Raios Cósmicos e Cronologia, Instituto de Física Gleb Wataghin, UNICAMP, Rua Sérgio Buarque de Holanda, 777, CEP 13083-859, Campinas, SP).

Para denúncias ou reclamações referentes aos aspectos éticos você pode contactar o Comitê de Ética em Pesquisa da UNICAMP (tel: 3521-8936, email: cep@fcm.unicamp.br, endereço: Rua Tessália Vieira de Camargo, 126, CEP 13083-887, Campinas, SP).

Você receberá uma cópia deste termo de consentimento esclarecido.

Eu li, entendi, e aceito participar voluntariamente desta pesquisa.

---

Nome legível do participante

Idade

---

Assinatura do participante

---

Assinatura do responsável

---

Assinatura do pesquisador

Campinas, \_\_\_\_/\_\_\_\_/20\_\_\_\_