



UNIVERSIDADE ESTADUAL DE CAMPINAS  
Faculdade de Engenharia Elétrica e de Computação

Guilherme Vettorazzi Vargas

**Filtragem espaço-temporal baseada no princípio  
MVDR aplicada a interfaces  
cérebro-computador sob o paradigma SSVEP**

Campinas

2021

Guilherme Vettorazzi Vargas

**Filtragem espaço-temporal baseada no princípio MVDR  
aplicada a interfaces cérebro-computador sob o  
paradigma SSVEP**

Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica, na Área de Engenharia de Computação.

Orientador: Prof. Dr. Levy Boccato

Este trabalho corresponde à versão final da dissertação defendida pelo aluno Guilherme Vettorazzi Vargas, e orientada pelo Prof. Dr. Levy Boccato.

Campinas

2021

Ficha catalográfica  
Universidade Estadual de Campinas  
Biblioteca da Área de Engenharia e Arquitetura  
Rose Meire da Silva - CRB 8/5974

V726f Vargas, Guilherme Vettorazzi, 1993-  
Filtragem espaço-temporal baseada no princípio MVDR aplicada a interfaces cérebro-computador sob o paradigma SSVEP / Guilherme Vettorazzi Vargas. – Campinas, SP : [s.n.], 2021.

Orientador: Levy Boccato.

Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Interfaces cérebro-computador. 2. Potenciais evocados. 3. Eletroencefalografia. 4. Processamento de sinais. 5. Filtros adaptativos. I. Boccato, Levy, 1986-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

Informações para Biblioteca Digital

**Título em outro idioma:** Spatiotemporal filtering based on MVDR principle applied to SSVEP brain-computer interfaces

**Palavras-chave em inglês:**

Brain-computer interfaces

Evoked potentials

Electroencephalography

Signal processing

Adaptive filters

**Área de concentração:** Engenharia de Computação

**Titulação:** Mestre em Engenharia Elétrica

**Banca examinadora:**

Levy Boccato [Orientador]

Rafael Ferrari

Diogo Coutinho Soriano

**Data de defesa:** 02-03-2021

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

**Identificação e informações acadêmicas do(a) aluno(a)**

- ORCID do autor: <https://orcid.org/0000-0002-6994-4179>

- Currículo Lattes do autor: <http://lattes.cnpq.br/5522297361466442>

## Comissão Julgadora – Dissertação de Mestrado

**Candidato:** Guilherme Vettorazzi Vargas RA 229960

**Data de defesa:** 02 de março de 2021

**Título da dissertação:** “Filtragem espaço-temporal baseada no princípio MVDR aplicada a interfaces cérebro-computador sob o paradigma SSVEP”

Profa. Dr. Levy Boccato (Presidente, FEEC/UNICAMP)

Prof. Dr. Rafael Ferrari (FEEC/UNICAMP)

Prof. Dr. Diogo Coutinho Soriano (UFABC)

A Ata de Defesa, com as respectivas assinaturas dos membros da Comissão Julgadora, encontra-se no SIGA (Sistema de Fluxo de Dissertação/Tese) e na Secretaria de Pós-Graduação da Faculdade de Engenharia Elétrica e de Computação.

*Dedico esta dissertação a todo mundo.*

# Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Agradeço a Deus, pela capacitação e pela força de conquistar os objetivos propostos.

Agradeço aos meus pais, Ézio e Cida, minha irmã, Tainá, e meu cunhado, Kassius, por todo apoio e incentivo durante o mestrado. Em especial, ao meu pai, por ser a inspiração da pesquisa em interfaces cérebro-computador, devido à sua luta contra a devastadora esclerose lateral amiotrófica. Que continue lutando fortemente.

Agradeço à Laura, por toda a parceria, amor, carinho e motivação, me dando coragem para enfrentar a jornada acadêmica.

Agradeço ao meu orientador Prof. Levy, por todo o conhecimento compartilhado, por servir de exemplo profissional e pelo auxílio acadêmico fornecido durante a jornada.

Agradeço à Prof. Sarah, por continuar sempre por perto, pelas conversas valiosas e por sua grande parceria continuada dos tempos de graduação.

Aos professores, Romis, Leonardo Abdala, Renato e Rafael Ferrari, agradeço pela riqueza dos conhecimentos fornecidos durante a jornada, contribuindo para o amadurecimento acadêmico e formação como pesquisador. Principalmente, ao Prof. Romis, por ser inspiração de ser humano para todos que têm a felicidade e privilégio de cruzar seu caminho.

Agradeço aos colegas do laboratório DSPCom. Em especial, ao Rafael Granzotti, pela vivência e parceria na produção acadêmica, ao Bulhões, por sua ajuda, principalmente com sugestões inestimáveis para o trabalho, ao Marcos e Maiane, por serem sempre solícitos em resolver problemas do dia-a-dia, e ao Renan, por sua enorme iniciativa em compartilhar conhecimento.

Aos colegas de pensão e agregados, Carol, Gabi, Iuri, Leandro, Letícia, Lucas, Luli, Maiara, Mari e Ric, pelos bons momentos vividos. Em especial, ao Lucas, pela parceria nas disciplinas cursadas e pelas inúmeras conversas importantes.

Aos amigos de Valinhos, Gustavo, Karina e Alan Patrik, pelas boas conversas e encontros aos finais de semana.

Agradeço aos demais funcionários da FEEC/UNICAMP, pela disponibilidade e cooperação, e pela infraestrutura disponibilizada.

Por fim, a todas as pessoas que, direta ou indiretamente, contribuíram para a

conclusão desse trabalho.

*“Mais importante do que interpretar o mundo, é contribuir para transformá-lo.”*  
*(Karl Marx)*

# Resumo

O desenvolvimento de tecnologias assistivas visa melhorar a qualidade de vida e a inclusão na sociedade de indivíduos que apresentem algum tipo de deficiência (como visual, motora e/ou intelectual). Em particular, as interfaces cérebro-computador baseadas no potencial evocado visualmente em regime permanente (BCI-SSVEP) constituem uma opção em desenvolvimento que permite a interação direta entre o cérebro humano e o computador, mapeando sinais cerebrais em comandos para dispositivos externos. Na construção de uma BCI-SSVEP, os sinais cerebrais registrados via eletroencefalografia (EEG) são amplificados e pré-processados a fim de remover artefatos e ruídos indesejados. Em seguida, feita a digitalização deste conjunto de sinais, faz-se a extração e seleção de atributos representativos e, por fim, a classificação, associando aos sinais de entrada uma classe que codifica o comando desejado pelo usuário. Neste trabalho, vamos estudar uma técnica promissora de filtragem espaço-temporal, denominada filtro MVDR (do inglês, *minimum variance distortionless response*). Essa técnica, por meio da combinação de sinais provenientes de diversos eletrodos, é capaz de atenuar componentes interferentes, preservando as frequências relacionadas aos estímulos visuais, de acordo com as restrições de minimização de variância. Inicialmente, de acordo com testes de sensibilidade, avaliou-se o comportamento do filtro com relação a alguns fatores do sistema BCI-SSVEP: proximidade entre frequências de estímulo, número de estímulos e tamanho da janela de estimulação. Em seguida, os principais parâmetros de ajuste do filtro foram alterados, como sua ordem e o número de eletrodos a serem combinados. Mediante a inferioridade do método proposto em relação às demais técnicas de pré-processamento empregadas, como o CAR e a CCA, propusemos uma extensão do MVDR na forma de um banco de filtros, FBMVDR, estendendo-o posteriormente para o modo de operação adaptativo. Resultados indicam que a implementação do banco de filtros, FBMVDR, proporcionou um aumento superior a 5% em relação ao MVDR, atingindo um desempenho de 92,6% em cenários com 4 estímulos visuais e janelas de 1 s. Em uma segunda abordagem, o FBMVDRR superou uma das técnicas estado da arte, o FBCCA, em pouco mais de 1 ponto percentual. Portanto, a técnica de filtragem espaço-temporal proposta se mostrou capaz de trazer benefícios relevantes para os sistemas BCI.

**Palavras-chaves:** Interfaces cérebro-computador, Potenciais evocados, Eletroencefalografia, Processamento de sinais, Filtros adaptativos.

# Abstract

The development of assistive technologies aims to improve the quality of life and the inclusion in society of individuals who have some type of disability (such as visual, motor and/or intellectual). In particular, brain-computer interfaces based on steady-state visually evoked potentials (BCI-SSVEP) constitute an option under development that allows direct interaction between the human brain and the computer, mapping signals into commands for external devices. When building a BCI-SSVEP, brain signals registered via electroencephalography (EEG) are amplified and pre-processed in order to remove artifacts and undesired noise. Then, the digitalization of this set of signals is provided, followed by the extraction and selection of representative attributes and, finally, the classification, assigning the input signals to a class that encodes the command selected by the user. In this work, we study a promising space-time filtering technique, called MVDR (minimum variance distortionless response filter). By combining the signals from different electrodes, this technique is capable of attenuating interfering components, while preserving the frequencies related to visual stimuli, according to the variance minimization restrictions. Initially, with the aid of sensitivity tests, the behavior of the MVDR filter was evaluated with respect to some factors of the BCI-SSVEP system: proximity amid stimulus frequencies, number of stimuli and stimulation window-length. Then, the main parameters of the filter were varied, such as the order and the number of electrodes to be combined. Due to the inferiority of the proposed method when compared with other pre-processing techniques, such as CAR and CCA, we proposed an extension of the MVDR in the form of a filter bank, FBMVDR, extending it later to the adaptive operation mode. The obtained results indicate that the implementation of the filter bank, FBMVDR, provided an increase of more than 5 % in relation to the MVDR, reaching a performance of 92.6 % in scenarios with 4 visual stimuli and 1 s window-length. In a second approach, the FBMVDR surpassed one of the state-of-the-art techniques, the FBCCA, by approximately 1 percentage point. Therefore, the proposed space-time filtering technique was capable of bringing relevant benefits to the BCI systems.

**Keywords:** Brain-computer interfaces, Evoked potentials, Electroencephalography, Signal processing, Adaptive filters.

# Lista de ilustrações

Figura 2.1 – Onda típica do paradigma P300. Figura adaptada de (CIPRESSO et al., 2012). . . . .	29
Figura 2.2 – Matriz de caracteres geralmente utilizada no paradigma P300. . . . .	29
Figura 2.3 – Espectro do sinal com estímulo em 8 Hz. . . . .	30
Figura 2.4 – Projeção de estímulos em monitor utilizada no paradigma SSVEP. . . . .	30
Figura 3.1 – Etapas de um sistema BCI-SSVEP, com destaque ao módulo de processamento de sinais de EEG. . . . .	32
Figura 3.2 – Efeito da filtragem CAR em sinal de paciente estimulado em 8 Hz. . . . .	35
Figura 4.1 – Estrutura geral do filtro espaço-temporal MVDR. . . . .	42
Figura 4.2 – Combinações de cenários experimentais. . . . .	49
Figura 4.3 – Esquema de treinamento e validação adotado pela BCI. . . . .	50
Figura 4.4 – Combinações de técnicas de pré-processamento analisadas nos cenários experimentais. . . . .	50
Figura 4.5 – Efeito de diferentes ordens do filtro MVDR considerando o cenário de mínimo espaçamento, com 8 frequências de estímulo. . . . .	55
Figura 4.6 – Efeito de diferentes ordens do filtro MVDR considerando o cenário de máximo espaçamento, com 8 frequências de estímulo. . . . .	56
Figura 4.7 – Efeitos da filtragem individual de estímulos. No primeiro caso, 4 estímulos são filtrados simultaneamente. No segundo, apenas a filtragem em 8 Hz. . . . .	58
Figura 5.1 – Estrutura geral do banco de filtros espaço-temporal MVDR. Os sinais de $k$ eletrodos são filtrados por $n_h \times F$ filtros MVDR, cada um dedicado a uma única frequência alvo; a partir das saídas dos filtros associados à mesma frequência fundamental $f_i$ , são extraídos atributos e aquele que apresentar a maior magnitude representa a informação corresponde a esta frequência. . . . .	61
Figura 5.2 – Identificação das grandezas representadas no <i>boxplot</i> . . . . .	64
Figura 5.3 – <i>Boxplot</i> para os 35 voluntários, confrontando os métodos FBMVDR/CAR-2h e CAR/CCA-2h em cenário com 4 frequências de estímulo 8, 10, 12 e 15 Hz. . . . .	65
Figura 5.4 – Velocidade de convergência para os algoritmos de Frost (1972) - CLMS e Resende, Romano e Bellanger (1996) - <i>Robust</i> CFLS para o paciente 9. . . . .	73
Figura 6.1 – Esquema de filtragem FBCCA. Adaptado de (CHEN et al., 2015). . . . .	75
Figura 6.2 – <i>Boxplots</i> comparativos entre FBMVDR e FBCCA para os voluntários 8 e 20. . . . .	78

# Lista de quadros

Quadro 1 – Passo-a-passo adotado pelo algoritmo <i>Robust CFLS</i> . . . . .	70
--	----

# Lista de tabelas

Tabela 4.1 – Resultados para os cenários considerando 4 frequências de estimulação.	52
Tabela 4.2 – Resultados para os cenários considerando 6 frequências de estimulação.	52
Tabela 4.3 – Resultados para os cenários considerando 8 frequências de estimulação.	53
Tabela 4.4 – Melhores resultados após análises de ordem do filtro MVDR. . . . .	55
Tabela 4.5 – Melhores resultados após análises do valor de $k$ . . . . .	57
Tabela 4.6 – Desempenho dos demais métodos considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz. . . . .	57
Tabela 5.1 – Desempenho do FBMVDR considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz. . . . .	62
Tabela 5.2 – Desempenhos individuais de 35 voluntários do FBMVDR/CCA-2h e CAR/CCA-2h considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz. . . . .	63
Tabela 5.3 – Análise de convergência para as técnicas adaptativas. . . . .	72
Tabela 5.4 – Desempenho do sistema BCI-SSVEP para extensões do MVDR. . . . .	73
Tabela 6.1 – Desempenhos individuais de 35 voluntários do FBMVDR e FBCCA considerando o cenário de 4 frequências de estímulo 8, 10, 12e 15 Hz. . . . .	77

# Lista de abreviaturas e siglas

BCI	<i>Brain-computer interface</i>
CAR	<i>Common average reference</i>
CCA	<i>Canonical correlation analysis</i>
CFLS	<i>Constrained fast least-squares</i>
CLMS	<i>Constrained least-mean squares</i>
DFT	<i>Discrete Fourier transform</i>
ECoG	Eletrocorticografia
EEG	Eletroencefalograma
FBCCA	<i>Filter bank canonical correlation analysis</i>
FBMVDR	<i>Filter bank minimum variance distortionless response</i>
FFT	<i>Fast Fourier transform</i>
fMRI	<i>Functional magnetic resonance imaging</i>
IBK	<i>Imagined body kinematics</i>
LFP	<i>Local field potential</i>
MEG	Magnetoencefalografia
MUA	<i>Multi-unit activity</i>
MVDR	<i>Minimum variance distortionless response</i>
NIRS	<i>Near-infrared spectroscopy</i>
PCA	<i>Principal component analysis</i>
PPS	Potencial pós-sináptico
SMR	<i>Sensorimotor rhythm</i>
SNC	Sistema Nervoso Central
SNR	<i>Signal-to-noise ratio</i>

SSVEP	<i>Steady-state visually evoked potential</i>
SUA	<i>Single unity activity</i>
SVM	<i>Support vector machine</i>

# Lista de símbolos

<b>A</b>	Matriz de atributos
$a$	Constante do banco de filtros CCA
$b$	Constante do banco de filtros CCA
<b>C</b>	Matriz de restrições
$C_{L,k}$	Combinação de $L$ eletrodos tomados $k$ a $k$
$cov(.,.)$	Covariância entre duas variáveis aleatórias
$d$	Número de amostras do sinal de EEG
$E_0$	Energia inicial do erro de predição progressivo
$F$	Número de estímulos/frequências de evocação
$f_i$	$i$ -ésima frequência de estímulo
<b>g</b>	Vetor de igualdades
$g(.)$	Função discriminante linear
$H(.)$	Função custo
<b>h</b>	Vetor de projeção canônica
$h$	Valor lógico para o Teste Wilcoxon Pareado
<b>I</b>	Matriz identidade
$k$	Número de eletrodos a serem combinados
$L$	Número de eletrodos disponíveis
$l$	Resolução espectral da DFT
<b>M</b>	Matriz intermediária utilizada pelo método de Frost
$m$	Número de coeficientes/ordem do filtro MVDR
$N$	Número de sub-bandas
$N_a$	Número de atributos da matriz de atributos

$n_h$	Número de componentes harmônicas
$N_s$	Número de amostras da matriz de atributos
$n_s$	Número de sessões/ <i>trials</i>
$\mathbf{P}$	Matriz intermediária utilizada pelo método de Frost
$p$	Número de janelas/segmentos
$p\text{-value}$	Probabilidade de rejeição da hipótese nula
$\mathbf{Q}$	Matriz intermediária utilizada pelo método <i>Robust</i> CFLS
$\mathbf{q}$	Vetor de projeção canônica
$\mathbf{R}$	Matriz de correlação dos dados de entrada
$\mathbb{R}$	Conjunto dos números reais
$\mathbf{r}$	Ganho de adaptação
$sb$	Sub-banda
$\mathbf{u}$	Vetor intermediário utilizado pelo método <i>Robust</i> CFLS
$V$	Fator de esquecimento
$\mathbf{v}$	Vetor intermediário utilizado pelo método <i>Robust</i> CFLS
$\mathbf{w}$	Concatenação dos coeficientes de $k$ filtros MVDR
$\mathbf{W}_c$	Matriz de pesos do classificador linear
$\mathbf{w}_i$	Coefficientes do filtro MVDR para o $i$ -ésimo eletrodo
$\mathbf{w}_N$	Vetor de pesos para $N$ sub-bandas
$\mathbf{w}_o$	Coefficientes do filtro ótimo
$\mathbf{X}$	Variável aleatória multidimensional
$X(\cdot)$	Função de transformação da DFT
$\mathbf{x}$	Concatenação de $m$ pontos dos sinais referentes a $k$ eletrodos
$x(\cdot)$	Sinal de entrada genérico
$\mathbf{x}_i(\cdot)$	Janela de $m$ pontos do sinal referente ao $i$ -ésimo eletrodo
$\mathbf{Y}$	Variável aleatória multidimensional

$\hat{\mathbf{Y}}$	Matriz de saídas do classificador linear
$y(\cdot)$	Sinal filtrado referente à combinação de $k$ eletrodos
$\mathbf{Y}_d$	Matriz de respostas desejadas/ <i>labels</i>
$\mathbf{Y}_f$	Sinal de referência da frequência $f$
$y_i(\cdot)$	Sinal filtrado referente ao $i$ -ésimo eletrodo
$\mathbf{\Gamma}$	Matriz intermediária utilizada pelo método <i>Robust</i> CFLS
$\lambda$	Multiplicadores de Lagrange
$\mu$	Passo de adaptação
$\rho(\cdot, \cdot)$	Correlação linear entre duas variáveis aleatórias
$\tilde{\rho}_f$	Soma ponderada dos coeficientes canônicos de $N$ sub-bandas
$\rho_f^N$	Coefficiente de correlação canônica referente à frequência $f$ e sub-banda $N$
$\sigma_{\mathbf{x}(\cdot)}^2$	Estimativa da potência do sinal de entrada
$\omega$	Frequência angular
$\nabla(\cdot)$	Operador gradiente
$\in$	Pertence

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
<b>1.1</b>	<b>Organização do Trabalho</b>	<b>22</b>
<b>1.2</b>	<b>Produção Científica</b>	<b>23</b>
<b>2</b>	<b>FUNDAMENTOS DE INTERFACES CÉREBRO-COMPUTADOR</b>	<b>24</b>
<b>2.1</b>	<b>Breve Relato Sobre a Gênese de Sinais Cerebrais</b>	<b>24</b>
<b>2.2</b>	<b>As Técnicas de Aquisição de Sinais Cerebrais</b>	<b>25</b>
2.2.1	Abordagens invasivas	25
2.2.2	Abordagens não-invasivas	26
<b>2.3</b>	<b>Os Paradigmas dos Sistemas BCI</b>	<b>27</b>
2.3.1	Imagética	27
2.3.2	Estimulação Externa	28
<b>3</b>	<b>O MÓDULO DE PROCESSAMENTO DE SINAIS DE EEG</b>	<b>32</b>
<b>3.1</b>	<b>Pré-Processamento</b>	<b>33</b>
3.1.1	<i>Common Average Reference</i>	33
3.1.2	Análise de Correlação Canônica	34
<b>3.2</b>	<b>Extração de Atributos</b>	<b>36</b>
3.2.1	Transformada Discreta de Fourier	37
3.2.2	CCA Como Técnica de Extração de Atributos	37
<b>3.3</b>	<b>Seleção de Características</b>	<b>38</b>
<b>3.4</b>	<b>Classificação</b>	<b>38</b>
3.4.1	Método dos Quadrados Mínimos	39
<b>4</b>	<b>FILTRO ESPAÇO-TEMPORAL MVDR</b>	<b>41</b>
<b>4.1</b>	<b>Análise do Filtro MVDR</b>	<b>46</b>
4.1.1	Base de Dados via SSVEP	46
4.1.2	Metodologia	48
4.1.3	Influência do Número de Estímulos, Espaçamento em Frequência e Duração da Janela	51
4.1.4	Efeitos da Ordem do Filtro $m$	54
4.1.5	Efeitos da Quantidade de Eletrodos Combinados $k$	55
<b>5</b>	<b>BANCO DE FILTROS ESPAÇO-TEMPORAL</b>	<b>60</b>
<b>5.1</b>	<b>A Ideia do Banco de Filtros</b>	<b>60</b>
<b>5.2</b>	<b>Estratégias de Adaptação</b>	<b>66</b>

5.2.1	Algoritmo de Frost . . . . .	66
5.2.2	Algoritmo <i>Robust</i> CFLS . . . . .	68
<b>5.3</b>	<b>Comparação entre Técnicas Adaptativas . . . . .</b>	<b>71</b>
<b>6</b>	<b>COMPARAÇÕES COM O ESTADO DA ARTE . . . . .</b>	<b>74</b>
<b>6.1</b>	<b>Banco de Filtros CCA (FBCCA) . . . . .</b>	<b>74</b>
<b>6.2</b>	<b>Análise Comparativa . . . . .</b>	<b>76</b>
<b>7</b>	<b>CONCLUSÕES . . . . .</b>	<b>79</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>81</b>

# 1 Introdução

O estudo dos processos fisiológicos relacionados ao cérebro humano, juntamente com os grandes avanços tecnológicos estabelecidos nos tempos recentes, vêm contribuindo fortemente para o desenvolvimento e aprimoramento de técnicas que permitam uma interação direta por meio de uma interface entre um computador e o cérebro. Este tipo de técnica, denominada interface cérebro-computador (BCI, do inglês *brain-computer interface*), permite o desenvolvimento de tecnologia assistiva para indivíduos com algum tipo de limitação física (MÜLLER; BASTOS; FILHO, 2013), possibilitando a elaboração de projetos como cadeiras de rodas automáticas (MÜLLER; BASTOS; FILHO, 2013) e próteses (ORTNER et al., 2010), que surgem como grande fator contribuinte em termos de melhoria de qualidade de vida de pacientes, no âmbito de tecnologias assistivas.

Mais especificamente, um sistema BCI refere-se a um dispositivo capaz de fornecer ao seu usuário um canal de comunicação considerado não-muscular (WOLPAW et al., 2002), relacionado com a mensuração das atividades cerebrais deste indivíduo e sua intenção de realizar determinada tarefa (GRAIMANN; ALLISON; PFURTSCHELLER, 2009). O processo de mensuração de sinais cerebrais e o paradigma que governa a geração desses sinais são considerados passos cruciais para o desenvolvimento de uma interface cérebro-computador. Dentre a vasta gama de técnicas de registro e paradigmas BCI presentes, o corrente trabalho aprofundará seus estudos em sistemas BCI sob o paradigma de potenciais visualmente evocados em regime permanente (SSVEP, do inglês *steady-state visually evoked potentials*), registrados por meio da eletroencefalografia (EEG).

Além da etapa de aquisição de sinais de EEG, os sistemas BCI-SSVEP possuem em seu núcleo um módulo de processamento de sinais, o qual é constituído de subetapas, como o pré-processamento, extração e seleção de atributos, e classificação, as quais são capazes de fornecer o ferramental tecnológico necessário para a interpretação dos sinais cerebrais, possibilitando o controle de dispositivos externos. Mais especificamente, na etapa de pré-processamento, os sinais registrados são filtrados digitalmente, com o principal intuito de se atenuar componentes indesejáveis (artefatos) presentes, aumentando assim a relação sinal-ruído (SNR, do inglês *signal-to-noise ratio*). Esta etapa pode contribuir significativamente para o estabelecimento de um sistema BCI robusto e eficiente, especialmente se o registro dos sinais cerebrais é feito em ambientes susceptíveis a ruído.

Existem diversas técnicas consagradas para o pré-processamento de sinais de EEG em uma BCI-SSVEP, como o CAR (do inglês, *common average reference*) (MCFARLAND et al., 1997) e a CCA (do inglês, *canonical correlation analysis*) (BIN et al., 2009). Neste trabalho, avaliaremos as contribuições de uma técnica de filtragem espaço-temporal

clássica na área de posicionamento de antenas, denominada resposta sem distorção de mínima variância (MVDR, do inglês, *minimum variance distortioless response*), adaptada ao contexto de sistemas BCI-SSVEP. Esta técnica é capaz de atenuar componentes interferentes, preservando o sinal de interesse de acordo com restrições previamente estabelecidas. Como os sinais de EEG via SSVEP apresentam picos de energia nas frequências para as quais o paciente é estimulado, o filtro MVDR surge como uma proposta promissora na minimização de ruídos e preservação do conteúdo evocado.

Em particular, nosso estudo está pautado na implementação de todas as etapas citadas de um sistema BCI sob o paradigma SSVEP, promovendo um enfoque maior na etapa de pré-processamento, por meio do estudo das potencialidades e das limitações do MVDR. Inicialmente, revisitaremos as contribuições propostas por Leite (2016), apresentando, primeiramente, uma nova formulação matemática da proposta de filtragem, e promovendo análises mais aprofundadas, especialmente em relação a parâmetros do sistema BCI-SSVEP, tais como o tamanho da janela temporal, o número de frequências de estímulo e a proximidade entre as frequências, bem como aspectos relacionados ao filtro, como a ordem de cada filtro individual e o número de eletrodos a serem combinados. O principal objetivo destas análises é a consolidação da técnica MVDR em sistemas BCI-SSVEP.

Em seguida, a partir da identificação dos fatores limitantes para o método, introduziremos uma extensão do MVDR na forma de um banco de filtros, de modo que cada filtro MVDR seja projetado tendo como referência somente uma frequência alvo, que pode ser uma das frequências originais de estímulo ou alguma harmônica. Conforme será demonstrado, esta perspectiva, combinada com uma estratégia simples de extração de atributos, pode superar as limitações encontradas e, assim, trazer contribuições importantes para uma BCI-SSVEP. Por fim, analisamos também o comportamento do banco de filtros MVDR quando seu projeto é feito de forma adaptativa.

## 1.1 Organização do Trabalho

A escrita deste trabalho foi dividida em sete capítulos. No Capítulo 2, os fundamentos introdutórios às interfaces cérebro-computador são apresentados, o que inclui conceitos básicos sobre a origem dos sinais cerebrais no corpo humano, informações sobre técnicas de registro e os paradigmas que regem os sistemas BCI. No Capítulo 3, apresentaremos conceitos teóricos sobre todas as técnicas computacionais empregadas no módulo de processamento de sinais, exceto pelo MVDR, que é descrito exclusivamente no Capítulo 4, juntamente com análises de desempenho para diversos cenários. Tendo como motivação os resultados observados nos testes de sensibilidade, propomos uma extensão ao MVDR na forma de um banco de filtros, no qual cada filtro é projetado tendo

em vista uma única frequência de evocação ou, também, uma de suas harmônicas. A formalização e análise desta proposta é feita no Capítulo 5. Ademais, uma implementação do banco de filtros MVDR baseada em algoritmos adaptativos também é apresentada. Subsequentemente, no Capítulo 6, em um experimento extra, confrontaremos a melhor versão obtida da técnica espaço-temporal proposta com uma técnica considerada parte do estado da arte em sistemas BCI-SSVEP. Por fim, o Capítulo 7 apresentará as conclusões gerais do trabalho, bem como perspectivas futuras sobre o MVDR.

## 1.2 Produção Científica

Os trabalhos produzidos durante este projeto de mestrado são citados abaixo:

1. R. A. GRANZOTTI; M. A. CHINELATTO; G. V. VARGAS; L. BOCCATO. Application of autoencoders for feature extraction in BCI-SSVEP. In: 7th Brainn Congress, Campinas-SP, 2020.
2. R. GRANZOTTI; G. V. VARGAS; L. BOCCATO. Application of Autoencoders for Feature Extraction in BCI-SSVEP. In: XXVII Congresso Brasileiro de Engenharia Biomédica, Vitória-ES, 2020.
3. S. N. CARVALHO; G. V. VARGAS; T. B. S. COSTA; H. M. A. LEITE; L. CO-RADINE; L. BOCCATO; D. C. SORIANO; R. ATTUX. Space-Time Filter for SSVEP Brain Computer Interface based on the Minimum Variance Distortionless Response. In: Medical & Biological Engineering & Computing, Springer (Aceito para publicação).

## 2 Fundamentos de Interfaces Cérebro-Computador

### 2.1 Breve Relato Sobre a Gênese de Sinais Cerebrais

O Sistema Nervoso Central (SNC) é uma complexa rede de mais de 100 bilhões de neurônios, que recebem diversos sinais de informação oriundos dos sistemas que compõem o corpo (GUYTON, 2006). Para que as funções vitais continuem ocorrendo, as informações são levadas ao cérebro pelos neurônios de fibras aferentes, componentes do Sistema Nervoso Periférico (SNP), por meio dos impulsos nervosos – potenciais de ação – que são transmitidos com base em um complexo mecanismo eletroquímico que se manifesta na região denominada fenda sináptica, a qual está situada na interface entre o neurônio pré-sináptico e o neurônio pós-sináptico (SILVERTHORN et al., 2010).

Para que o impulso nervoso seja gerado, são necessárias algumas alterações substanciais no potencial de membrana, que tende sempre ao equilíbrio com relação ao íon para o qual ela é mais permeável. O desenvolvimento de um potencial de ação ocorre da seguinte maneira: a membrana está em um potencial de repouso, que possui limiar de ação (valor em que a corrente de influxo é maior que a de efluxo, e o potencial de ação torna-se inevitável) de cerca de  $-70$  mV; neurotransmissores perturbam a membrana e ocorre o influxo de corrente até o limiar de ação ( $-55$  mV), causando a despolarização terminal do neurônio pré-sináptico, ou seja, o meio intracelular se torna mais negativo, se comparado ao meio extracelular. Após essa fase, os canais de potássio ( $K^+$ ) com carga positiva começam a se abrir, o que faz com que o meio intraneural retorne às suas cargas negativas, o que significa que a membrana ficará repolarizada (CONSTANZO, 2006).

Os passos descritos anteriormente sintetizam um dos processos necessários para a manutenção das funções do organismo: o neural. Conforme já antecipado, ele se desenvolve na sinapse. Tendo em vista que o neurônio biológico é constituído de três partes fundamentais – o corpo celular (ou soma), o axônio, que se estende a partir do corpo celular, e os dendritos, que são abundantes ramificações celulares através das quais o neurônio é estimulado –, a sinapse pode ser identificada como o ponto de encontro entre dois neurônios (tipicamente, entre prolongamentos do axônio do neurônio pré-sináptico e dendritos do neurônio pós-sináptico). Sendo assim, temos que os potenciais de ação atravessam todo o neurônio pré-sináptico e são codificados por neurotransmissores, os quais estimulam os elementos pós-sinápticos para que a transmissão da informação seja realizada. Os potenciais de ação são transmitidos na forma de impulsos elétricos – transmissão de íons direta entre as células - ou químicos, e o potencial pós-sináptico (PPS) é resultado

da integração de todos os potenciais pré-sinápticos, e é o que será captado pelo EEG (GUYTON, 2006).

## 2.2 As Técnicas de Aquisição de Sinais Cerebrais

Após esta exposição inicial a respeito da origem biológica dos sinais cerebrais, é necessário agora explorar as técnicas existentes para a aquisição desses sinais, etapa considerada primordial para o início do desenvolvimento de um sistema BCI. Nesse contexto, vamos apresentar algumas técnicas de mensuração invasivas e não-invasivas para o registro das atividades eletrofisiológicas.

### 2.2.1 Abordagens invasivas

De modo geral, as técnicas denominadas invasivas preveem a implantação de microeletrodos abaixo do crânio do paciente, por meio de neurocirurgias. Dessa forma, como os eletrodos estão espacialmente mais próximos da distribuição neuronal, existe uma boa relação sinal-ruído nesses sinais (RAMADAN; VASILAKOS, 2017). Entretanto, a necessidade de intervenções cirúrgicas pode ser um entrave para a aplicação dessas técnicas, seja por questões éticas ou até mesmo por motivos financeiros (LEITE, 2016), além da degradação gradual dos sinais coletados com o passar do tempo (ABIRI et al., 2019). As duas formas mais empregadas, eletrocorticografia e gravação do neurônio intracortical, são relatadas abaixo:

- **Eletrocorticografia (ECoG)**

Nesta técnica, conhecida também como EEG intra-cranial, o crânio do paciente é removido, via craniotomia, e os eletrodos são posicionados na superfície do córtex cerebral. O sinal resultante possui elevada relação sinal-ruído e ótima resolução espacial. Entretanto, é uma técnica altamente limitada ao uso em salas cirúrgicas e ainda não há um consenso com relação à estabilidade a longo prazo dos registros (NICOLAS-ALONSO; GOMEZ-GIL, 2012; RAMADAN; VASILAKOS, 2017; KURUVILLA; FLINK, 2003).

- **Gravação do neurônio intracortical**

Com essa modalidade de registro, é possível mensurar a atividade elétrica do interior da massa cinzenta cerebral. Para isso, é necessária a implantação de uma matriz de microeletrodos dentro do córtex, podendo ser registradas as atividades de um único neurônio (SUA, *single-unit activity*), de um conjunto de neurônios (MUA, *multi-unit activity*) e potenciais de campo local (LFPs, *local field potentials*) (WALDERT et al., 2009; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

## 2.2.2 Abordagens não-invasivas

Na abordagem não-invasiva, a aquisição dos sinais é realizada sem a necessidade de penetração do escalpo do paciente e, por isso, é amplamente empregada por evitar procedimentos cirúrgicos, sendo considerada, de certa forma, uma técnica de menor custo associado (RAMADAN; VASILAKOS, 2017; LEITE, 2016). As principais formas de registro são elencadas a seguir:

- **Eletroencefalografia (EEG)**

A EEG pode ser considerada a técnica de registro de atividade cerebral mais popular entre pesquisadores, seja por sua portabilidade vasta, pelo baixo custo associado em comparação com as demais técnicas e, ademais, pelos resultados robustos obtidos em sistemas BCI que a empregam. Além disso, os sinais de eletroencefalograma fornecem uma alta resolução temporal, apesar de uma pior qualidade em relação ao ECoG, por exemplo, por ter que cruzar todas as camadas do cérebro (GARCIA-MOLINA; ZHU, 2011; RAMADAN; VASILAKOS, 2017; ABIRI et al., 2019). No registro, há o posicionamento dos eletrodos sobre o escalpo do paciente, sem que haja a necessidade de intervenções cirúrgicas (JASPER, 1958).

- **Magnetoencefalografia (MEG)**

A magnetoencefalografia é empregada na análise do campo magnético gerado pelas atividades cerebrais. É uma técnica consagrada em análises clínicas, pois é possível determinar áreas ativas e/ou danificadas do cérebro (RAMADAN; VASILAKOS, 2017; WANG et al., 2010), e possui uma resolução espaço-temporal superior ao EEG, propiciando comunicações confiáveis entre cérebro e máquina (MELLINGER et al., 2007).

- **Ressonância magnética funcional (fMRI)**

Essa técnica utiliza a variação do fluxo sanguíneo e oxigenação cerebral para mensurar as atividades cerebrais por meio de campos eletromagnéticos. Possui alta resolução espacial, mas uma baixa resolução temporal (WEISKOPF et al., 2004), sendo considerada instável para comunicações rápidas em BCI e é altamente susceptível a ação de artefatos de movimento.

- **Espectroscopia de infravermelho próximo (NIRS)**

Neste método, o monitoramento do fluxo de oxigenação cerebral e metabolismo de certas regiões do cérebro é obtido por meio de feixes de luz no espectro infra-vermelho, que são capazes de atingir o cérebro humano em uma profundidade de 1 a 3 cm a partir do crânio (COYLE et al., 2004). Assim como a fMRI, possui baixa resolução temporal, e por isso, não é muito utilizada pela comunidade científica (SONG et al., 2014).

## 2.3 Os Paradigmas dos Sistemas BCI

Os paradigmas que regem a construção de BCIs estão associados aos mecanismos de geração de sinais cerebrais e podem ser divididos em dois grupos: endógenos e exógenos. Nos processos endógenos, os sinais são gerados sem que haja a necessidade de alguma estimulação externa. Com isso, é possível desenvolver BCIs baseadas em tarefas de imaginação, como a imagética motora. No caso dos processos exógenos, em resposta a estímulos externos, sejam eles visuais, auditivos ou somatossensoriais, há a geração de sinais de modo inconsciente pelo paciente. Assim, a resposta evocada no cérebro a partir da estimulação externa constitui o cerne da BCI neste paradigma.

A determinação do paradigma mais adequado para a operação de uma BCI depende de diversos fatores. Principalmente, devem ser considerados o tipo de aplicação e controle a ser exercido pela BCI, o poderio computacional disponível e as habilidades e/ou limitações do paciente (LEITE, 2016). Além disso, como será visto posteriormente, o cientista deve analisar quais técnicas de processamento de sinais possuem uma melhor relação com o paradigma adotado, a fim de se estabelecer um sistema altamente robusto e apto para o uso em ambientes não laboratoriais.

### 2.3.1 Imagética

De acordo com Pfurtscheller e Neuper (1997), tarefas de imaginação motora são responsáveis por ativar áreas do cérebro relacionadas ao movimento. Pensando nisso, diversos sistemas BCIs têm sido desenvolvidos baseados em duas vertentes de maior destaque: ritmos sensório-motor (SMR, *sensorimotor rhythems*) e IBK (*imagined body kinematics*) (ABIRI et al., 2019), que serão discutidas posteriormente. É importante também pontuar a existência de um paradigma relacionado a atividades de imaginação não-motora. Nesse paradigma, o voluntário deve ser capaz de mentalizar certas tarefas, como cálculos mentais, ou a imaginação de figuras geométricas, de forma que o monitoramento da atividade cerebral mediante tais tarefas possibilite a construção de uma BCI (CURRAN et al., 2004).

No primeiro caso, SMR, um dos mais populares, é solicitado ao indivíduo que imagine a realização do movimento de grandes membros do corpo, como as mãos, pés ou a língua. Essas tarefas, assim como a realização do movimento propriamente dito, produzem padrões característicos na região do córtex motor cerebral, que podem ser interpretados para o controle de uma BCI. Uma das principais desvantagens dessa vertente decorre da dificuldade associada à tarefa de imaginação, pois existe uma forte tendência que o paciente imagine uma representação visual do movimento, o que exige certo treinamento antes da realização da tarefa de modo efetivo (NEUPER et al., 2005). Desde a sua primeira implementação por uma BCI em 1991 (WOLPAW et al., 1991), onde foi realizado o controle

de um cursor em uma dimensão, muito avanços foram obtidos, chegando ao controle de um robô de reabilitação (ANG et al., 2009).

O IBK, por sua vez, é considerado um paradigma independente do SMR, pois apresenta protocolos de treinamento e análises fundamentalmente distintos dos empregados pela SMR (ABIRI et al., 2019). Sua origem está intimamente ligada a registros invasivos (KIM et al., 2008; HOCHBERG et al., 2006), sendo posteriormente adotado em registros não-invasivos (YUAN; HE, 2014). A tarefa de imaginação está associada ao movimento contínuo de apenas uma parte de corpo e, por esta razão, é também denominada de paradigma de movimento imaginário natural. Embora algumas contribuições com esse paradigma sejam encontrados na literatura, como a investigação do controle de um cursor 2D (BRADBERRY; GENTILI; CONTRERAS-VIDAL, 2011) e a decodificação de dois movimentos imaginários do pulso direito em duas velocidades diferentes (GU; DREMSTRUP; FARINA, 2009), sua aplicação em sistemas BCI ainda é limitada e encontra-se em investigação (ABIRI et al., 2019).

### 2.3.2 Estimulação Externa

Como citado anteriormente, é possível monitorar alterações das atividades cerebrais causadas por estímulos visuais, auditivos e somatossensoriais. O registro dessas atividades proporciona o controle de interfaces cérebro-computador. Nesta dissertação, discorreremos principalmente sobre os dois principais paradigmas baseados em estimulação externa encontrados na literatura: P300 e SSVEP.

A BCI-P300 baseia-se em um determinado potencial relacionado ao evento (ERP, do inglês *event related potential*), o P300. A onda P300, por sua vez, é caracterizada por uma resposta que ocorre aproximadamente 300 ms após o evento de interesse, representado pela aparição de estímulos inesperados (DONCHIN; SMITH, 1970). Tipicamente, as aplicações do paradigma P300 em sistemas BCI compreendem a utilização de uma matriz de letras, números ou outros símbolos, onde suas colunas e linhas destacam-se aleatoriamente, conforme indicado na Figura 2.2. À medida que uma linha ou coluna revela o caractere desejado pelo usuário, é possível monitorar a evocação da onda P300 (MUGLER et al., 2010). Por exemplo, se observarmos a Figura 2.2, a linha contendo as letras de A até F está destacada. Caso o paciente esteja interessado na letra D, seria possível observar a resposta cerebral semelhante àquela mostrada na Figura 2.1.

Os sinais provenientes desse paradigma possuem uma relação sinal-ruído considerada baixa e, por isso, apenas uma sessão de estimulação não é suficiente. Assim, das diversas sessões observadas, toma-se a média, melhorando assim a acurácia do processo de identificação (NICOLAS-ALONSO; GOMEZ-GIL, 2012), de modo que o paradigma possa ser aplicado por sistemas BCI com grande facilidade de utilização, exigindo mínimo treinamento prévio (LEITE, 2016).

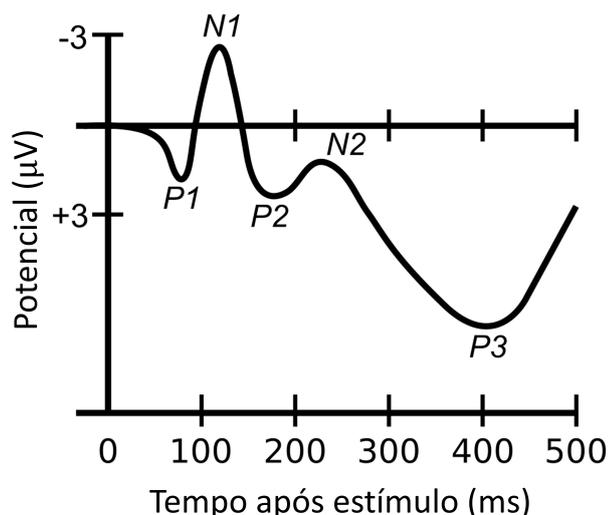


Figura 2.1 – Onda típica do paradigma P300. Figura adaptada de (CIPRESSO et al., 2012).

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 2.2 – Matriz de caracteres geralmente utilizada no paradigma P300.

No caso do paradigma SSVEP, os estímulos são apresentados ao paciente, oscilando a uma determinada taxa, denominada frequência de estímulo ou evocação. Perante certo estímulo, células do córtex visual promovem o sincronismo de sua frequência de disparos com a frequência de oscilação do estímulo, surgindo um aumento de energia do sinal cerebral em torno da frequência correspondente, bem como em suas harmônicas, principalmente nos registros extraídos da região occipital do cérebro, pois é nessa região que estímulos visuais são prioritariamente processados (HERRMANN, 2001). Na Figura 2.3, podemos observar o módulo da transformada discreta de Fourier de um sinal de EEG sob o paradigma SSVEP, com estimulação em 8 Hz. É possível observar picos na frequência fundamental e nas componentes harmônicas, principalmente em 16, 24 e 32 Hz.

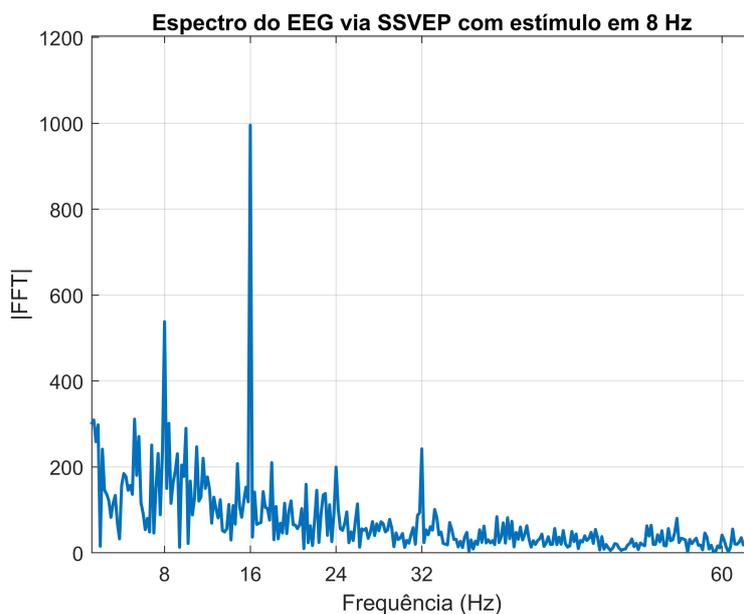


Figura 2.3 – Espectro do sinal com estímulo em 8 Hz.

O estímulo pode ser concebido de diversas formas. Classicamente, as duas formas mais utilizadas são por projeção em monitor e LEDs (ZHU et al., 2010). A Figura 2.4 exibe uma tela projetada em um monitor mostrando os estímulos visuais relacionados ao sistema BCI-SSVEP. Cada quadro no padrão xadrez oscila de acordo com uma frequência de evocação e pode ser associado a um comando específico. Neste exemplo em particular, teríamos quatro possíveis comandos, os quais poderiam significar movimento para a frente, para trás, para a esquerda e para a direita em uma aplicação de cadeira de rodas motorizada.

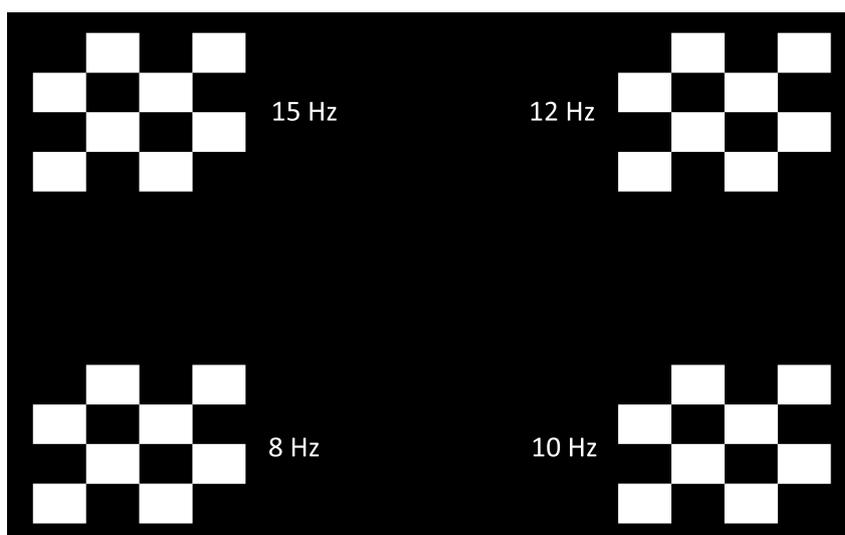


Figura 2.4 – Projeção de estímulos em monitor utilizada no paradigma SSVEP.

Os sistemas BCI-SSVEP apresentam diversas vantagens. Geralmente, esses sistemas empregam frequências de estímulo em uma faixa de 5 a 30 Hz. Deste modo,

inúmeros graus de liberdade são proporcionados ao sistema, possibilitando o controle de uma grande gama de aplicações (ABIRI et al., 2019). O paradigma pode ser usado pela maioria dos pacientes (VOLOSYAK et al., 2011), existindo, porém, certa dificuldade para usuários que possuam alguma deficiência visual. Além disso, alguns pacientes podem apresentar fadiga, desconforto e até mesmo ataques epiléticos, principalmente em baixas frequências (CHANG et al., 2014; LIN et al., 2012; HARDING; JEAUVONS, 1994), o que pode contribuir para uma queda de desempenho do sistema BCI, ou até inviabilizar seu uso em alguns casos.

Além dos paradigmas P300 e SSVEP apresentados, muitas pesquisas têm sido realizadas buscando o estabelecimento de uma interface híbrida, que aprimore o desempenho da BCI (AMIRI; FAZEL-REZAI; ASADPOUR, 2013). Via de regra, para ser considerada híbrida, a interface pode combinar, serialmente ou paralelamente, duas ou mais técnicas de registro de sinais fisiológicos, desde que pelo menos uma seja EEG (PFURTSCHELLER et al., 2010). Por exemplo, Luth et al. (2007) combinaram os paradigmas P300 e SSVEP para o controle de um braço robótico assistivo.

Os paradigmas explorados neste trabalho, juntamente com as técnicas de registro apresentadas, constituem o ferramental básico para o estabelecimento das primeiras etapas de uma interface cérebro-computador. No próximo capítulo, vamos explorar com maior atenção os elementos que compõem o módulo de processamento de sinais em um sistema BCI-SSVEP. Com a inserção dessa etapa, podemos estabelecer uma BCI capaz de promover contribuições significativas nos âmbitos da neuroreabilitação e da tecnologia assistiva.

### 3 O Módulo de Processamento de Sinais de EEG

O módulo de processamento de sinais de EEG é responsável pela integração entre a etapa de aquisição de dados cerebrais e a interpretação e tradução dos sinais adquiridos para a aplicação em algum dispositivo de controle externo.

Na grande maioria das interfaces cérebro-computador estabelecidas, o processamento de sinais engloba os seguintes estágios, ilustrados na Figura 3.1: (1) pré-processamento, para a remoção dos artefatos que persistiram na base de dados; (2) extração de atributos, de modo a ter uma descrição compacta e representativa das informações mais relevantes dos sinais cerebrais observados; (3) seleção de atributos, em que ocorre uma redução do volume de dados tendo em vista melhorias de desempenho em termos de acurácia preditiva; e, finalmente, (4) classificação, onde se identifica o comando desejado pelo usuário a partir do processamento dos atributos extraídos (GRAIMANN; ALLISON; PFURTSCHELLER, 2009). Através da realimentação (*feedback*), seja por mecanismos visuais e/ou auditivos, o usuário toma ciência do progresso do experimento e pode tentar ajustar sua ação para melhorar o desempenho da BCI-SSVEP (BENDA; VOLOSYAK, 2020).

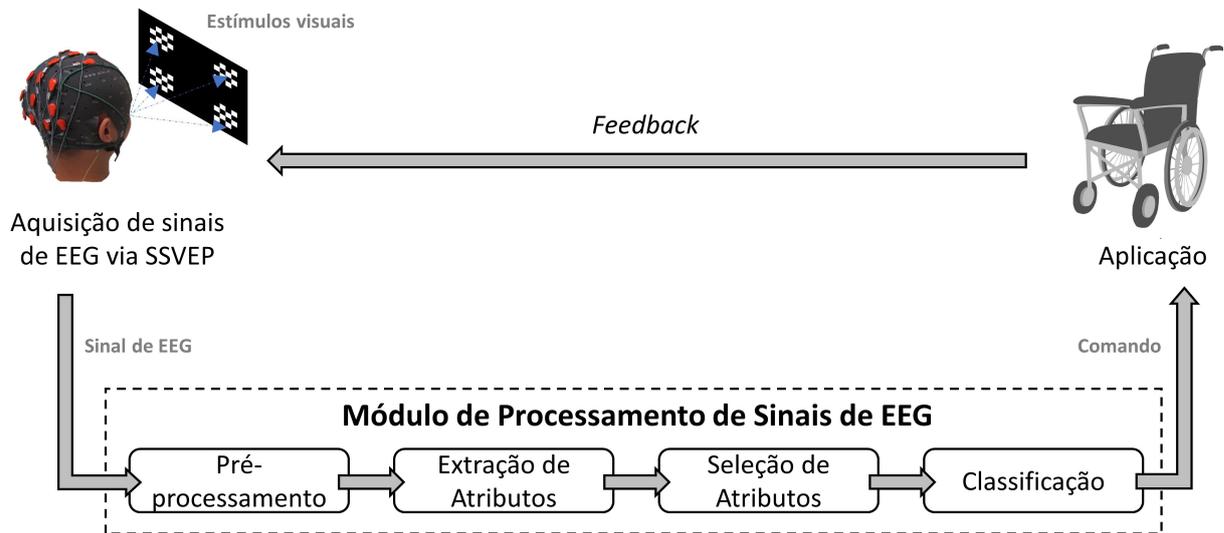


Figura 3.1 – Etapas de um sistema BCI-SSVEP, com destaque ao módulo de processamento de sinais de EEG.

## 3.1 Pré-Processamento

Antes de serem digitalizados, os sinais cerebrais coletados são filtrados analogicamente para remoção de artefatos provenientes da rede elétrica do país onde a coleta foi realizada e, também, de artefatos fisiológicos, como aqueles gerados pelos batimentos cardíacos, piscamento de olhos, deglutição e atividades musculares em geral (MARKAND, 1996). Para isso, na grande maioria dos casos, internamente ao aparelho de coleta, aplica-se um filtro *notch*, com a frequência central variando entre 50 ou 60 Hz, bem como um filtro passa-faixas do tipo *Butterworth* no intervalo de frequência de 5 a 60 Hz. Essa faixa de frequências do filtro *Butterworth* advém da taxa de atualização dos monitores tradicionais onde os estímulos são projetados, 60 Hz. Como as frequências dos estímulos devem ser submúltiplos dessa taxa, limita-se a ocupação espectral do sinal de EEG registrado. Subsequentemente, os sinais são amplificados e digitalizados para o posterior processamento digital.

A primeira etapa de processamento digital corresponde ao pré-processamento. Esta etapa é responsável pela atenuação dos artefatos que ainda estão presentes na base de dados obtida e, conseqüentemente, busca promover um aumento da relação sinal-ruído (SNR, do inglês *signal-to-noise ratio*). Existem inúmeras técnicas de filtragem empregadas, como o filtro espacial CAR (do inglês *common average reference*) (GARCIA-MOLINA; ZHU, 2011), que consiste na remoção do valor médio, observado em todos os eletrodos, do sinal de cada eletrodo individual, e também o método da filtragem espaço-temporal MVDR (BENESTY; CHEN; HUANG, 2005; LEITE, 2016), que representa o principal foco de estudo neste trabalho.

Além do processo de filtragem, no processamento *offline*, a base de dados está sujeita a uma segmentação de dados. Tendo em vista os vários perfis de janelas existentes (e.g., Hamming) (OPPENHEIM; SCHAFER, 2010), os sinais coletados são segmentados em blocos com sobreposição ou não, de modo a ajustar o tempo de execução do sistema projetado a um cenário de aplicação em tempo real. Neste projeto, serão consideradas janelas de Hamming de 3, 2 e 1 s de duração.

### 3.1.1 *Common Average Reference*

O processo de coleta de dados de sinais de EEG via SSVEP, em sua grande maioria, mede a diferença de potencial elétrico entre um eletrodo, denominado ativo, e um eletrodo de referência, por meio da distribuição de diversos eletrodos sobre o escalpo de um paciente (BERTRAND; PERRIN; PERNIER, 1985). Na escolha do eletrodo de referência, é desejável o seu posicionamento em um local onde haja a presença de um potencial elétrico aproximadamente nulo, ou com a mínima atuação de biopotenciais indesejáveis. Para isso, algumas opções são usualmente adotadas, como o posicionamento nos processos mastoideis,

no eletrodo Cz, extremidade do nariz ou lóbulos das orelhas (LEITE, 2016).

Em seu trabalho, Bertrand, Perrin e Pernier (1985) demonstram que o valor médio de potencial de um grande número de eletrodos dispostos regularmente no escalpo de um indivíduo é proporcional à estimativa da integral da distribuição de potencial elétrico no escalpo. Essa integral, por sua vez, tem valor nulo, indicando que o valor médio atua como uma ótima referência para os eletrodos empregados. Entretanto, sistemas BCI-SSVEP, em sua grande maioria, englobam apenas os eletrodos da região occipital e, por isso, não fornecem uma completa cobertura do escalpo. Ainda assim, o filtro espacial CAR é capaz de promover uma referência com potencial praticamente nulo (MCFARLAND et al., 1997).

Em suas premissas de funcionamento, o filtro CAR revela artefatos fortemente presentes no conjunto de eletrodos avaliados, já que existe uma forte tendência que os artefatos apareçam de modo simultâneo e com amplitudes bastante semelhantes em todos os eletrodos, enquanto o potencial evocado apresenta-se, de certa forma, restrito aos eletrodos situados na região occipital (MCFARLAND et al., 1997). Para isso, em cada instante de tempo, do potencial registrado em cada eletrodo subtrai-se o valor médio de todos os eletrodos. Desta forma, para um número  $L$  de eletrodos, há a formação de  $L$  canais filtrados pelo CAR, com potenciais elétricos calculados de acordo com a seguinte expressão:

$$Pot_i^{CAR} = Pot_i^{ele} - \frac{1}{L} \sum_{j=1}^L Pot_j^{ele} \quad (3.1)$$

onde  $Pot_i^{ele}$  é o potencial do  $i$ -ésimo eletrodo e  $Pot_i^{CAR}$  o potencial de cada novo canal espacialmente filtrado.

Embora seja bastante simples, o filtro CAR desempenha um papel importante no ajuste do potencial dos eletrodos e, também, contribui para a atenuação dos artefatos, pois conforme a Figura 3.2, é possível perceber que há uma atenuação de componentes espectrais indesejáveis, sendo mantidos os picos representativos na frequência com que o paciente foi estimulado. Por fim, é importante destacar que, por atuar amostra por amostra, o filtro espacial CAR também pode ser empregado em operações que exijam o pré-processamento em tempo real (LEITE, 2016).

### 3.1.2 Análise de Correlação Canônica

A análise de correlação canônica (CCA, do inglês *canonical correlation analysis*), é uma técnica estatística multivariada desenvolvida inicialmente por Hotelling (1992). Na sua definição primária, a CCA é utilizado para maximizar a correlação entre dois conjuntos de dados, para os quais supõe-se alguma correlação prévia. Assim sendo, para duas variáveis

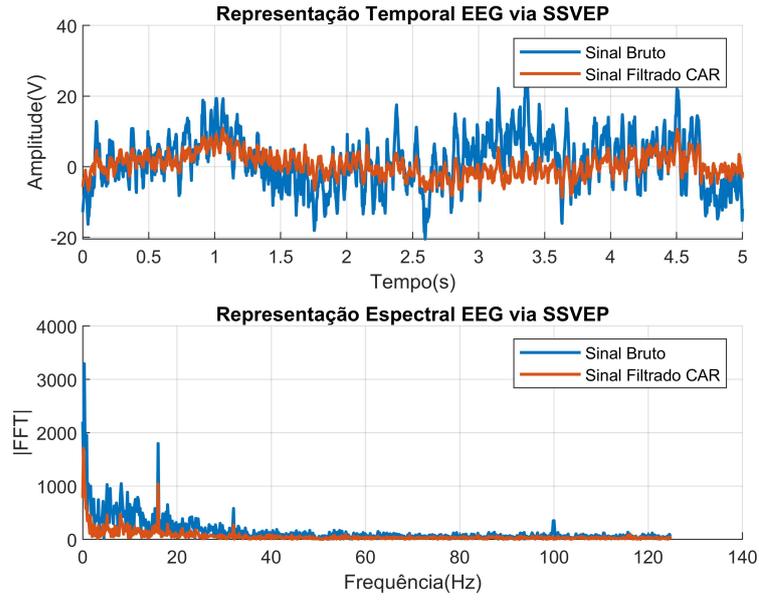


Figura 3.2 – Efeito da filtragem CAR em sinal de paciente estimulado em 8 Hz.

aleatórias multivariadas  $\mathbf{X}$  e  $\mathbf{Y}$ , o método deve ser capaz de obter os vetores  $\mathbf{h}$  e  $\mathbf{q}$ , com os quais as combinações lineares  $\mathbf{h}^T \mathbf{X}$  e  $\mathbf{q}^T \mathbf{Y}$  apresentem a maior correlação canônica  $\rho(\mathbf{h}^T \mathbf{X}, \mathbf{q}^T \mathbf{Y})$ . A restrição imposta ao problema de maximização requer que os vetores de transformação linear,  $\mathbf{h}$  e  $\mathbf{q}$ , possuam variância unitária e que sejam decorrelacionados. Matematicamente, o problema é escrito como:

$$\begin{aligned} & \max_{\mathbf{h}, \mathbf{q}} \mathbf{h}^T \mathbf{R}_{\mathbf{X}\mathbf{Y}} \mathbf{q} \\ & \text{s.a. } \mathbf{h}^T \mathbf{R}_{\mathbf{X}\mathbf{X}} \mathbf{h} = 1, \\ & \mathbf{q}^T \mathbf{R}_{\mathbf{Y}\mathbf{Y}} \mathbf{q} = 1 \end{aligned} \quad (3.2)$$

onde  $\mathbf{R}_{\mathbf{X}\mathbf{X}} = \text{cov}(\mathbf{X}, \mathbf{X})$ ,  $\mathbf{R}_{\mathbf{Y}\mathbf{Y}} = \text{cov}(\mathbf{Y}, \mathbf{Y})$  e  $\mathbf{R}_{\mathbf{X}\mathbf{Y}} = \text{cov}(\mathbf{X}, \mathbf{Y})$ .

Os detalhes referentes à obtenção da solução ótima do problema proposto em (3.2) são descritos em (KLETT, 1972).

Em sistemas BCI-SSVEP, a CCA pode ser empregado tanto como técnica de filtragem espacial, quanto como técnica de extração de atributos. Na atuação como filtro, consideramos que  $\mathbf{X}$  seja representado pela concatenação de  $p$  janelas temporais de uma matriz de  $L \times d$  sinais de EEG, em que  $L$  denota o número de eletrodos e  $d$  é o número de amostras, de modo que  $\mathbf{X}$  possua dimensão  $L \times (p \cdot d)$  (SPÜLER et al., 2013). O conjunto de dados  $\mathbf{Y}$ , também denominado de vetor de referências, de acordo com Bin et al. (2009), deve conter sinais que simulam os potenciais evocados por meio de senos e cossenos definidos para a frequência de estímulo fundamental e também para suas componentes harmônicas. Para uma única frequência evocada  $f_i$ ,  $i = 1, 2, \dots, F$ , o

vetor de referências  $\mathbf{Y}_i \in \mathbb{R}^{2n_h \times p \cdot d}$ , com  $n_h$  sendo o número de componentes harmônicas, é representado abaixo:

$$\mathbf{Y}_i = \begin{bmatrix} \sin(2\pi f_i \mathbf{t}) & & \sin(2\pi f_i \mathbf{t}) \\ \cos(2\pi f_i \mathbf{t}) & & \cos(2\pi f_i \mathbf{t}) \\ \vdots & \dots & \vdots \\ \sin(2\pi n_h f_i \mathbf{t}) & & \sin(2\pi n_h f_i \mathbf{t}) \\ \cos(2\pi n_h f_i \mathbf{t}) & & \cos(2\pi n_h f_i \mathbf{t}) \end{bmatrix} \quad (3.3)$$

$\underbrace{\hspace{10em}}_{\text{janela 1}}$ 
 $\underbrace{\hspace{10em}}_{\text{janela p}}$

onde o vetor  $\mathbf{t} \in \mathbb{R}^{1 \times d}$  representa a amostragem temporal adotada em cada janela.

No caso de  $F$  frequências evocadas, a matriz  $\mathbf{Y}$  é escrita como

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_F \end{bmatrix}, \quad (3.4)$$

com dimensão  $2n_h F \times p \cdot d$ . Desta forma, estabelecemos a restrição  $2n_h F \leq L$ , pois todos os coeficientes de correlação canônica que excedem o número de eletrodos tornam-se nulos.

## 3.2 Extração de Atributos

A extração de atributos dos sinais de EEG é a etapa responsável por promover uma representação compacta e eficiente do conjunto de dados presente, sendo conveniente o mapeamento dos sinais de entrada em outro espaço. As características extraídas da base de dados são reunidas em uma matriz de atributos com o objetivo de facilitar a tarefa de discriminação realizada no estágio de classificação e, por esta razão, o desempenho do sistema classificador é geralmente utilizado para julgar a qualidade dos atributos extraídos.

Algumas técnicas clássicas são utilizadas, tais como transformada discreta de Fourier, a transformada Wavelet, a PCA (do inglês, *principal component analysis*), a CCA, entre outras, sendo a melhor técnica empregada dependente de qual paradigma é utilizado pelo sistema BCI (BISHOP et al., 1995). No sistema BCI-SSVEP implementado, abordaremos a transformada de Fourier na etapa de extração de características (OPPENHEIM; SCHAFER, 2010), em virtude de sua simplicidade computacional aliada a um bom desempenho, como analisado em (CARVALHO et al., 2015), comparando seu desempenho com a CCA.

### 3.2.1 Transformada Discreta de Fourier

A transformada discreta de Fourier (DFT, do inglês *discrete Fourier transform*) é capaz de fornecer um mapeamento consistente entre os domínios do tempo e frequência. Para isso, a DFT promove uma representação de uma sequência igualmente espaçada de  $p$  amostras de um sinal de EEG,  $x[n]$ , em uma sequência também de  $p$  amostras igualmente espaçadas, representando, agora, frequências discretas (OPPENHEIM; SCHAFER, 2010). A função de transformação, que engloba informações de magnitude e fase do sinal, é representada abaixo:

$$X[l] = \sum_{n=0}^{p-1} x[n] e^{-j\left(\frac{2\pi}{p}\right)ln} \quad (3.5)$$

onde  $l \in [0, 1, \dots, p-1]$ . A resolução espectral é dada por  $\frac{2\pi}{p}$ .

De acordo com Leite (2016), com a DFT, uma relação inversa entre a precisão da estimação espectral e o tamanho do segmento temporal é estabelecida. Assim sendo, o emprego da técnica é indicado principalmente para sinais com lentas variações temporais, ou que sejam, pelo menos, quase estacionários (KAY, 2006). Contudo, em sinais de EEG obtidos sob o paradigma SSVEP, podemos adotar, sem maiores prejuízos, principalmente em termos de desempenho do sistema BCI, a aproximação de que os sinais sejam estacionários e, com isso, a DFT é considerada adequada para este fim.

Entretanto, em termos de complexidade computacional, a DFT possui desempenho prejudicado à medida que a quantidade de amostras de um sinal,  $p$ , se eleva, pois necessita realizar  $p^2$  operações. Felizmente, os algoritmos da classe conhecida como FFT (do inglês, *fast Fourier transform*) são capazes de computar de forma exata e eficiente as amostras em frequência da DFT, com custo computacional proporcional a  $p \log p$  (OPPENHEIM; SCHAFER, 2010).

### 3.2.2 CCA Como Técnica de Extração de Atributos

Para a CCA atuando como técnica de extração de atributos, o mesmo problema de otimização descrito na Equação (3.2) deve ser resolvido. Desta vez, entretanto,  $\mathbf{X}$  pode ser representado apenas por um segmento  $p$  com  $d$  amostras do sinal de EEG de cada vez. Assim, obtém-se os coeficientes de correlação canônica para cada segmento do sinal e o vetor de referências está associado à frequência de estímulo (e suas harmônicas) para a qual se deseja extrair atributos. Ou seja, o CCA fornecerá um mapeamento consistente de acordo com os atributos  $\rho_i(\mathbf{X}, \mathbf{Y}_i)$ , para  $i = 1, 2, \dots, F$ , e  $\mathbf{Y}_i$  de acordo com a Equação (3.3).

### 3.3 Seleção de Características

Em termos gerais, o principal objetivo desta etapa é selecionar os atributos mais relevantes para o sistema classificador, considerando o número elevado de variáveis envolvidas na descrição de determinado conjunto de dados. Com isso, além da diminuição do conjunto de dados, a seleção pode promover um aprimoramento do desempenho do sistema classificador, permitindo, em certa medida, uma melhor compreensão dos dados analisados (BISHOP, 2006). As principais estratégias empregadas em sistemas BCI são filtros e *wrappers* (GUYON; ELISSEEFF, 2003), explorando diferentes critérios, como os baseados em coeficientes de correlação de Pearson e no índice de Davies-Bouldin (GUYON et al., 2008).

Os *wrappers* selecionam um subconjunto de atributos de acordo com o treinamento e validação do modelo. Para isso, a técnica avalia o erro de classificação para identificar o melhor subconjunto de atributos (KOHAVI; JOHN et al., 1997). Existem duas formas de seleção. Na primeira, denominada *forward selection*, o subconjunto ótimo de atributos inicia vazio, sendo preenchido pelos atributos segundo a regra de seleção. Na segunda, *backward elimination*, a procura pelo subconjunto ótimo parte do oposto, ou seja, supõe-se inicialmente que todos os atributos sejam relevantes, sendo avaliado o efeito da remoção de atributos a cada época de seleção (DEVIJVER; KITTLER, 1982).

Os filtros, por sua vez, não utilizam um *feedback* do classificador para ordenar os atributos, e sim métricas obtidas a partir dos próprios dados de entrada. No caso dos filtros baseados na correlação de Pearson, por exemplo, há uma associação dos atributos com as classes correspondentes, de acordo com os coeficientes de correlação (BISHOP, 2006), eliminando os atributos descorrelacionados. Já o índice de Davies-Bouldin mensura a separabilidade entre as classes considerando a distância dentro de uma classe e a maximização da distância entre classes para realizar a seleção dos atributos mais significativos (DAVIES; BOULDIN, 1979).

### 3.4 Classificação

A tarefa de classificação é caracterizada pelo desafio de categorizar variáveis de entrada de acordo com as possíveis classes, considerando as similaridades encontradas. No contexto de uma BCI, as variáveis de entrada são representadas pelas características extraídas dos sinais cerebrais, enquanto as classes estão associadas aos possíveis comandos desejados pelo usuário, conforme as frequências dos estímulos visuais disponíveis, no caso de um paradigma SSVEP (LEITE, 2016).

Os classificadores podem ser lineares ou não-lineares, sendo compostos basicamente pelas etapas de treinamento, validação e teste. Desta forma, é possível determinar o

percentual de acerto do sistema BCI. As principais técnicas utilizadas são as redes neurais artificiais (HAYKIN, 2010), SVM (do inglês, *support vector machines*) (HAYKIN, 2010), classificador linear (BISHOP et al., 1995), entre outros.

Neste trabalho, empregamos um classificador linear baseado no método dos quadrados mínimos, devido a sua simplicidade e robustez em termos de desempenho em sistemas BCI-SSVEP (CARVALHO et al., 2015).

### 3.4.1 Método dos Quadrados Mínimos

No contexto de problemas de classificação, o método dos quadrados mínimos assume função discriminante linear. Essa função discriminante, em sua definição mais básica, é vista como uma combinação linear entre um padrão  $\mathbf{x}$ , caracterizado por  $N_a$  atributos, um vetor de pesos  $\mathbf{w}_c$  e o *bias*  $w_b$ , conforme indicado na equação abaixo:

$$g(\mathbf{x}) = \mathbf{w}_c^T \mathbf{x} + w_b \quad (3.6)$$

O hiperplano definido por  $g(\cdot)$  é capaz de decidir à qual classe esse padrão  $\mathbf{x}$  pertence, de acordo com uma direção imposta pelo vetor de pesos  $\mathbf{w}_c$ .

Para a classificação em sistemas BCI-SSVEP, devemos primeiramente compreender a organização da matriz de atributos fornecida à etapa de classificação. Essa matriz, aqui denotada por  $\mathbf{A}$ , contém, em suas linhas,  $N_s$  amostras de treinamento representadas por uma parcela de  $p$  janelas/segmentos,  $n_s$  *trials*/sessões e  $F$  frequências de estímulo/classes, definida previamente de acordo com a divisão entre treinamento e validação adotada na validação cruzada. Os  $N_a$  atributos, por sua vez, compõem as colunas da matriz  $\mathbf{A}$ , e representam os coeficientes obtidos de acordo com o método de extração de atributos empregado, considerando cada eletrodo e referentes a cada frequência de estímulo, totalizando  $L \times F$  colunas.

Desta forma, a associação entre os padrões de entrada, agora representados pela matriz  $\mathbf{A}$ , e o vetor de pesos é expandida da seguinte maneira:

$$\hat{\mathbf{Y}} = \mathbf{A}\mathbf{W}_c \quad (3.7)$$

onde  $\mathbf{W}_c \in \mathbb{R}^{(N_a+1) \times F}$  representa os vetores de pesos para as  $F$  classes envolvidas e  $\hat{\mathbf{Y}}$  a saída do classificador. O termo  $+1$  na dimensão de  $\mathbf{W}_c$  sinaliza a incorporação do *bias* a cada vetor de pesos, assim como a inserção de uma entrada adicional unitária na matriz  $\mathbf{A}$  de atributos.

Na busca do hiperplano ótimo, devemos minimizar a diferença quadrática entre o vetor que contém as respostas desejadas (rótulos),  $\mathbf{Y}_d$ , e a resposta fornecida pelo classificador. O vetor de rótulos, por sua vez, é definido de modo que as amostras

pertencentes à classe  $i$  recebam o rótulo  $+1$ , enquanto as demais,  $-1$ . Matematicamente, o problema de otimização é descrito abaixo:

$$\min_{\mathbf{W}_c} \|\mathbf{Y}_d - \hat{\mathbf{Y}}\|^2 \quad (3.8)$$

A solução do problema de otimização proposto na Equação (3.8) pode ser encontrada utilizando o cálculo da matriz pseudo-inversa de Moore-Penrose (THEODORIDIS; KOUTROUMBAS et al., 2008). No caso onde o número de amostras é maior que a quantidade de atributos (situação presente em grande parte dos casos), isto é,  $N_s > N_a$ , a solução é obtida derivando a função custo a ser minimizada, igualando-a a zero e isolando o termo  $\mathbf{W}_c$ , de modo que:

$$\mathbf{W}_c = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{Y}_d \quad (3.9)$$

No capítulo seguinte, vamos voltar a atenção à etapa de pré-processamento, formalizando uma técnica de filtragem espaço-temporal originalmente empregada em problemas de posicionamento de arranjos de antenas, o filtro MVDR. Vamos apresentar toda a formulação matemática desta técnica e analisaremos o desempenho do sistema de acordo com diferentes configurações da BCI-SSVEP.

## 4 Filtro Espaço-Temporal MVDR

Para operações de sistemas BCI-SSVEP em ambientes não-laboratoriais, geralmente susceptíveis à incidência de ruídos, é desejável que o sinal registrado possua uma quantidade ínfima de artefatos. No caso de sinais de EEG via SSVEP, devido à dinâmica do sinal, com picos de energia representativos nas frequências de estimulação, acredita-se que a adaptação dos conceitos do filtro espaço-temporal MVDR em sistemas BCI-SSVEP possa ser bastante interessante. Uma das propostas desta adaptação surgiu com [Leite \(2016\)](#), onde o MVDR é avaliado em uma BCI, considerando prioritariamente janelas temporais de 3 s de duração. Inspirados neste trabalho, fazemos um resgate desta ideia, rerepresentando-a com outra formatação matemática, e estendendo sua análise a fim de entender suas potencialidades e limitações, visando, em última análise, chegar ao cenário mais próximo do uso em tempo real, com janelas de curta duração.

Originalmente desenvolvido para problemas de processamento de arranjos de antenas ([CAPON, 1969](#)), o método de filtragem espaço-temporal MVDR é definido como uma técnica não paramétrica destinada a estimação espectral, filtragem temporal e *beamforming* ([BENESTY; CHEN; HUANG, 2005](#)). Esta técnica visa o cancelamento de frequências interferentes, preservando o conteúdo na frequência de interesse. Em uma analogia aos sinais de EEG via SSVEP, seria razoável afirmar que o MVDR alia as informações de frequências evocadas de maneira dependente do posicionamento dos eletrodos e dos dados de entrada, de modo a atenuar os artefatos e realçar a energia do sinal de EEG nas frequências de evocação. Desta forma, é necessário que o método seja capaz de combinar informações de diferentes eletrodos e frequências, mas sem comprometer a resposta presente em cada frequência evocada.

Inicialmente, consideremos que  $L$  eletrodos estejam disponíveis para a etapa de pré-processamento. O sinal associado a cada eletrodo  $i$  em um instante de tempo  $n$  é denotado por  $\mathbf{x}_i(n)$ . O filtro MVDR, por sua vez, é capaz de processar, simultaneamente, a combinação de  $2 \leq k \leq L$  eletrodos, utilizando filtros FIR de tamanho  $m$  e com coeficientes na forma de  $\mathbf{w}_i = [w_{i,0} \dots w_{i,m-1}]^T$ . Assim, a saída correspondente à filtragem de cada eletrodo pode ser escrita como:

$$y_i(n) = \mathbf{w}_i^T \mathbf{x}_i(n) \quad (4.1)$$

onde  $\mathbf{x}_i(n) = [x_i(n) \dots x_i(n - m + 1)]^T$ , para  $i = 1, \dots, k$ .

Para a combinação de  $k$  eletrodos, temos a resposta geral  $y(n)$  dada pela soma de cada parcela filtrada  $y_i(n)$ , como é indicado na Figura 4.1. É importante destacar que,

para  $L$  eletrodos combinados por um fator  $k$ , obtemos novos sinais, denominados canais, de acordo com a relação de combinação

$$C_{L,k} = \frac{L!}{k!(L-k)!} \quad (4.2)$$

e, para cada canal, ocorre a filtragem descrita na Figura 4.1.

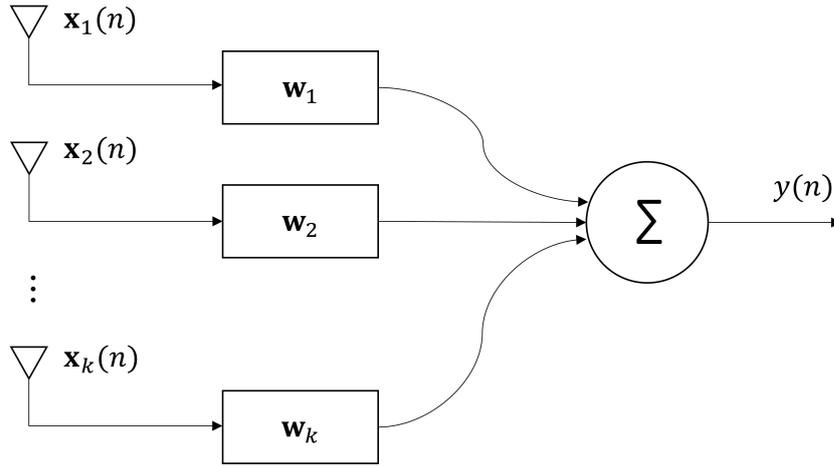


Figura 4.1 – Estrutura geral do filtro espaço-temporal MVDR.

Essa formulação pode ser reescrita de uma forma mais compacta se considerarmos versões expandidas dos vetores de coeficientes dos filtros,  $\mathbf{w}$ , e do sinal de entrada,  $\mathbf{x}$ , que são:

$$\mathbf{w} = [w_{1,0} \cdots w_{1,m-1} \ w_{2,0} \cdots w_{2,m-1} \ \cdots \ w_{k,0} \cdots w_{k,m-1}]^T \quad (4.3)$$

e

$$\mathbf{x} = [x_1(n) \cdots x_1(n-m+1) \ \cdots \ x_k(n) \cdots x_k(n-m+1)]^T. \quad (4.4)$$

Deste modo, a saída é reescrita como:

$$y(n) = \mathbf{w}^T \mathbf{x}(n) \quad (4.5)$$

No processo de filtragem aplicado ao contexto de sistemas BCI-SSVEP, o filtro é projetado para minimizar a potência do sinal de saída,  $y(n)$ , ou seja, sua variância, garantindo, porém, que o conteúdo nas frequências de evocação seja mantido com ganho unitário.

Para a modelagem do problema, consideremos que os sinais observados em cada eletrodo possam ser idealmente representados como uma soma de sinais senoidais, oscilando a uma determinada frequência evocada  $\omega_j$ ,  $j = 1, \dots, F$ :

$$x_i(n) = \sum_{j=1}^F A_{ij} \cos(\omega_j n + \theta_{ij}) \quad (4.6)$$

onde  $A_{ij}$  denota a amplitude do cosseno e  $\theta_{ij}$  a fase, ambos representando o  $i$ -ésimo eletrodo e a  $j$ -ésima frequência de evocação.

Em um primeiro momento, por simplicidade, consideremos que há apenas uma frequência evocada,  $\omega_1$ . De acordo com a Equação (4.1), cada saída filtrada é escrita como:

$$y_i(n) = w_{i,0} A_{i1} \cos(\omega_1 n + \theta_{i1}) + w_{i,1} A_{i1} \cos(\omega_1(n-1) + \theta_{i1}) \\ + \dots + w_{i,m-1} A_{i1} \cos(\omega_1(n-m+1) + \theta_{i1}) \quad (4.7)$$

Utilizando propriedades trigonométricas, podemos reescrever o sinal filtrado como:

$$y_i(n) = w_{i,0} A_{i1} \cos(\omega_1 n + \theta_{i1}) + w_{i,1} A_{i1} \{ \cos(\omega_1 n + \theta_{i1}) \cos(-\omega_1) \\ - \sin(\omega_1 n + \theta_{i1}) \sin(-\omega_1) \} + w_{i,2} A_{i1} \{ \cos(\omega_1 n + \theta_{i1}) \cos(-2\omega_1) \\ - \sin(\omega_1 n + \theta_{i1}) \sin(-2\omega_1) \} + \dots \quad (4.8)$$

É importante destacar que os múltiplos da frequência  $\omega_1$  presentes nos cossenos e senos não representam componentes harmônicas. Na verdade, eles surgem do atraso imposto pela linha de coeficientes do filtro. Reescrevendo (4.8) e explorando propriedades de simetria, obtemos:

$$y_i(n) = A_{i1} \cos(\omega_1 n + \theta_{i1}) \{ w_{i,0} + w_{i,1} \cos(\omega_1) + w_{i,2} \cos(2\omega_1) + \dots \} \\ + A_{i1} \sin(\omega_1 n + \theta_{i1}) \{ w_{i,1} \sin(\omega_1) + w_{i,2} \sin(2\omega_1) + \dots \} \quad (4.9)$$

Para preservar a energia do sinal na frequência evocada  $\omega_1$ , devemos satisfazer duas restrições: o fator que multiplica o cosseno deve valer 1, enquanto o segundo termo, associado ao seno, deve ser nulo. Assim, temos que:

$$\begin{cases} w_{i,0} + w_{i,1} \cos(\omega_1) + w_{i,2} \cos(2\omega_1) + \dots + w_{i,m-1} \cos((m-1)\omega_1) = 1 \\ w_{i,1} \sin(\omega_1) + w_{i,2} \sin(2\omega_1) + \dots + w_{i,m-1} \sin((m-1)\omega_1) = 0 \end{cases} \quad (4.10)$$

Na forma vetorial, reescrevemos (4.10) como:

$$\mathbf{w}_i^T \mathbf{C}_i(\omega_1) = \mathbf{g}_i^T \quad (4.11)$$

onde  $\mathbf{g}_i = [1 \ 0]^T$  e

$$\mathbf{C}_i(\omega_1) = \begin{bmatrix} 1 & 0 \\ \cos(\omega_1) & \text{sen}(\omega_1) \\ \cos(2\omega_1) & \text{sen}(2\omega_1) \\ \vdots & \vdots \\ \cos((m-1)\omega_1) & \text{sen}((m-1)\omega_1) \end{bmatrix}$$

Essa formulação, para apenas um eletrodo, pode ser estendida para o caso de  $k$  eletrodos. Para isso, é necessário incorporar um par de restrições descrito em (4.10) para cada eletrodo adicional. Desta maneira, agora de forma mais genérica, reescrevemos (4.11) como:

$$\mathbf{w}^T \mathbf{C}(\omega_1) = \mathbf{g}(\omega_1)^T \quad (4.12)$$

onde

$$\mathbf{C}(\omega_1) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ \cos(\omega_1) & 0 & 0 & \text{sen}(\omega_1) & 0 & 0 \\ \cos(2\omega_1) & 0 & 0 & \text{sen}(2\omega_1) & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \cos((m-1)\omega_1) & 0 & 0 & \text{sen}((m-1)\omega_1) & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & \cos(\omega_1) & 0 & 0 & \text{sen}(\omega_1) & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ 0 & \cos((m-1)\omega_1) & 0 & 0 & \text{sen}((m-1)\omega_1) & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 1 & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cos((m-1)\omega_1) & 0 & 0 & \text{sen}((m-1)\omega_1) \end{bmatrix}$$

$\underbrace{\hspace{15em}}_{\mathbf{C}_1(\omega_1)} \quad \underbrace{\hspace{15em}}_{\mathbf{C}_2(\omega_1)}$

e

$$\mathbf{g}(\omega_1) = \left[ \overbrace{1 \ \dots \ 1}^k \ \overbrace{0 \ \dots \ 0}^k \right]^T$$

A equação (4.12) pode ser também expandida em termos de um número arbitrário de frequências evocadas  $F$ . Para isso, devemos primeiramente definir a matriz  $\mathbf{C} \in \mathbb{R}^{km \times 2kF}$  e o vetor  $\mathbf{g} \in \mathbb{R}^{2kF \times 1}$  como sendo:

$$\mathbf{C} = [\mathbf{C}_1(\omega_1) \cdots \mathbf{C}_1(\omega_F) \quad \mathbf{C}_2(\omega_1) \cdots \mathbf{C}_2(\omega_F)] \quad (4.13)$$

$$\mathbf{g} = \left[ \overbrace{1 \cdots 1}^{kF} \quad \overbrace{0 \cdots 0}^{kF} \right]^T \quad (4.14)$$

Como desejamos minimizar a variância de  $y(n)$ , surge um problema de otimização com restrições de igualdade. Para a solução, consideramos primeiramente que os sinais possuem média nula. Matematicamente, o problema é descrito como:

$$\begin{aligned} \min_{\mathbf{w}} E[|y(n)|^2] &= \mathbf{w}^T \mathbf{R} \mathbf{w} \\ \text{s.a. } \mathbf{w}^T \mathbf{C} &= \mathbf{g}^T \end{aligned} \quad (4.15)$$

onde  $\mathbf{R} = E[\mathbf{x}(n)\mathbf{x}(n)]^T$  é a matriz de correlação que engloba informações espaço-temporais dos sinais cerebrais.

Na solução do problema apresentado, recorreremos ao método dos multiplicadores de Lagrange, como descrito em (BRYSON, 1975). Uma possível abordagem seria reunir, na mesma equação, a função a ser minimizada e as restrições a serem satisfeitas. No caso das restrições, existe uma multiplicação por um vetor  $\boldsymbol{\lambda}$ , que contém os multiplicadores de Lagrange. Deste modo, a seguinte equação é obtida:

$$H(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{R} \mathbf{w} + \boldsymbol{\lambda} (\mathbf{w}^T \mathbf{C} - \mathbf{g}^T) \quad (4.16)$$

onde o fator  $\frac{1}{2}$  foi utilizado para simplificações matemáticas futuras.

Para um valor estacionário de  $\mathbf{w}^T \mathbf{R} \mathbf{w}$ , devemos garantir que  $\mathbf{w}^T \mathbf{C} - \mathbf{g}^T$  seja igual a zero. Para que isso aconteça, o gradiente de  $H(\mathbf{w})$  em relação a  $\mathbf{w}$  deve ser igual a zero. Desta maneira:

$$\nabla_{\mathbf{w}} H(\mathbf{w}) = \mathbf{R} \mathbf{w} + \mathbf{C} \boldsymbol{\lambda} = 0 \quad (4.17)$$

Assim, o vetor de coeficientes do filtro  $\mathbf{w}$  é escrito como:

$$\mathbf{w} = -\mathbf{R}^{-1} \mathbf{C} \boldsymbol{\lambda} \quad (4.18)$$

De acordo com as restrições em (4.15), podemos reescrever (4.18) como:

$$-\mathbf{C}^T \mathbf{R}^{-1} \mathbf{C} \boldsymbol{\lambda} = \mathbf{g} \quad (4.19)$$

Os multiplicadores de Lagrange são obtidos da seguinte maneira:

$$\boldsymbol{\lambda} = -(\mathbf{C}^T \mathbf{R}^{-1} \mathbf{C})^{-1} \mathbf{g} \quad (4.20)$$

Finalmente, substituindo  $\boldsymbol{\lambda}$  na Equação (4.18), obtemos a equação dos pesos ótimos para o filtro MVDR:

$$\mathbf{w} = \mathbf{R}^{-1} \mathbf{C} (\mathbf{C}^T \mathbf{R}^{-1} \mathbf{C})^{-1} \mathbf{g} \quad (4.21)$$

Maiores detalhes sobre os procedimentos de otimização para o problema de restrição de igualdade podem ser encontrados em (BRYSON, 1975).

É pertinente destacar que, em sua formulação original, a filtragem MVDR parte da hipótese de que os sinais possuem média nula. Assim, para que essa condição não seja violada no contexto de uma BCI-SSVEP, é necessário subtrair dos sinais provenientes de cada eletrodo o valor médio observado em todos os eletrodos, o que corresponde à operação do CAR.

## 4.1 Análise do Filtro MVDR

Após toda a fundamentação teórica fornecida a respeito do filtro espaço-temporal MVDR, vamos agora avaliar o seu desempenho, de acordo com diversos cenários referentes a uma BCI-SSVEP. Primeiramente, apresentaremos a base de dados empregada no trabalho, seguida da metodologia adotada nos experimentos, bem como o ajuste de parâmetros do filtro utilizado em cada caso. Subsequentemente, avaliaremos os efeitos que o número de estímulos, o espaçamento entre frequências e o tamanho da janela temporal têm sobre o desempenho do sistema BCI. Por fim, as contribuições de variações da ordem do filtro e do número de eletrodos a serem combinados serão expostas.

### 4.1.1 Base de Dados via SSVEP

Para a análise da proposta de filtragem, foi escolhida a base de dados pública, desenvolvida por um grupo de pesquisa da Universidade de Tsinghua, China. Com ela, foi possível realizar a busca dos melhores parâmetros da técnica de filtragem espaço-temporal proposta, bem como avaliar fatores limitadores de seu uso em interfaces cérebro-computador. Todas as informações aqui descritas podem ser encontradas com maiores detalhes em (WANG et al., 2016).

Basicamente, o conjunto de dados de EEG coletado sob o paradigma SSVEP se refere a 35 voluntários saudáveis, dos quais 8 possuíam experiência prévia com sistemas BCI-SSVEP, enquanto os 27 restantes foram considerados inexperientes. O procedimento de coleta de dados foi realizado de acordo com aprovações do Comitê de Ética da Universidade de Tsinghua.

Primeiramente, em um monitor de 23,6 polegadas, foi apresentada uma matriz de  $5 \times 8$  estímulos, totalizando 40 frequências evocadas nos seguintes valores: 8 a 15,8 Hz, com incrementos de 0,2 Hz. Esta configuração foi elaborada tendo como pano de fundo a construção de um soletrador (em inglês, *speller*). Desta forma, durante o procedimento experimental de coleta, para cada participante, um estímulo de cada vez foi apresentado de modo aleatório e com duração total de 6 s. Nessa janela de 6 s, apenas 5 s realmente tinham uma estimulação visual, pois foi reservado 0,5 s antes e depois da tarefa visual, com o objetivo de instruir o paciente para alterar o olhar para a próxima frequência. Esse procedimento, correspondente a um bloco ou *trial*, foi repetido seis vezes, com um intervalo para descanso após dois blocos sucessivos.

No protocolo de coleta de dados utilizado, adotou-se inicialmente uma taxa de 1000 Hz para amostrar os sinais provenientes dos 64 eletrodos posicionados de acordo com o padrão internacional 10-20. Um filtro *notch* ajustado em 50 Hz foi empregado, com o propósito de remover artefatos provenientes da rede elétrica. Após a digitalização, os dados passaram pelo processo de decimação (*downsampling*), sendo a frequência de amostragem reduzida para 250 Hz.

Além de todo o procedimento experimental citado, algumas particularidades associadas a essa base devem ser destacadas. A primeira delas seria o ambiente onde a coleta foi realizada: uma sala à prova de som com iluminação reduzida. Essa configuração beneficia a aquisição de dados, pois é bem robusta em relação a componentes interferentes externos. Contudo, pensando no desenvolvimento de um sistema BCI-SSVEP capaz de controlar algum dispositivo externo em tempo real, poderia ser considerada uma situação difícil de ser obtida. Por isso, tomou-se bastante cuidado com possíveis generalizações com os resultados obtidos.

A segunda particularidade advém de análises conduzidas visando avaliar a latência visual nos sinais de EEG obtidos, etapa considerada de extrema importância para que se tenha a garantia de obter sinais contendo apenas respostas aos estímulos apresentados. De acordo com Wang et al. (2016), é recomendado considerar um atraso temporal de cerca de 130 ms correspondente à latência, sendo necessária a sua remoção durante a extração de épocas (ou janelas) do sinal a ser analisado, além da remoção dos trechos de 0,5 s de pré e pós-estímulo citados anteriormente.

## 4.1.2 Metodologia

Nos primeiros experimentos conduzidos neste projeto, buscou-se inicialmente o levantamento de fatores considerados dificultadores para o filtro MVDR, de forma a estabelecer os cenários mais adequados nos quais o emprego do método realmente gerasse contribuições para sistemas BCI-SSVEP.

Em primeiro lugar, identificamos a quantidade de frequências evocadas (ou, equivalentemente, de classes) como um aspecto crítico para o sistema BCI-SSVEP desenvolvido. Tendo em mente o contexto original no qual o filtro MVDR foi elaborado, a saber, o problema de conformação de feixes (*beamforming*) e de posicionamento de antenas, sabe-se que a quantidade de frequências de alinhamento aumenta os graus de liberdade a serem analisados e, conseqüentemente, torna a busca pela solução ótima mais custosa. Em uma analogia direta com o mundo das interfaces cérebro-computador, seria válido afirmar que o número de frequências de alinhamento corresponderia ao número de estímulos empregados pela BCI. Além disso, em tarefas de classificação aplicadas a sistemas BCI-SSVEP, o número de classes é determinante para o desempenho do classificador, havendo, em certa medida, uma relação inversamente proporcional entre essas duas variáveis. Desta forma, além de ser considerado um fator desfavorável para o MVDR, o número de estímulos é, por si só, um fator também agravante para a etapa de classificação.

Subseqüentemente, novamente em uma analogia com o mundo de antenas, temos que a distância espacial entre antenas constitui outro fator de grande impacto. No nosso caso, podemos dizer que essa distância seria equivalente à diferença numérica, ou espaçamento, entre os estímulos, em Hz. No primeiro exemplo, o papel dificultador da distância é classicamente conhecido e, por isso, acredita-se que essa variável também exerça o mesmo papel em nosso problema. Por fim, o terceiro fator está relacionado com a duração da janela de estímulos. Por ser um fator determinante para a diminuição da energia do sinal na região de evocação, várias pesquisas vêm sendo desenvolvidas com o objetivo de se obter valores aceitáveis de desempenho para janelas cada vez menores.

A fim de avaliar o comportamento da filtragem espaço-temporal MVDR e, em última análise, da BCI-SSVEP em função dos três fatores supracitados – número de frequências evocadas, espaçamento entre frequências evocadas e tamanho da janela –, desenvolvemos cenários de testes considerando as possibilidades detalhadas abaixo e acompanhadas das respectivas justificativas:

- **Número de frequências evocadas:** 4, 6 e 8 estímulos. Originalmente, a base de dados registrada objetiva a construção de um soletrador (*speller*) com 40 caracteres disponíveis. Entretanto, acredita-se que essa variação proposta, com menos estímulos, constitui um conjunto representativo de possibilidades de aplicação de um sistema BCI-SSVEP, como, por exemplo, para o controle de uma cadeira de rodas. Por isso,

além de servir como cenário de teste para os levantamentos anteriores, também possui um apelo prático;

- **Espaçamento entre frequências evocadas:** espaçamentos máximo e mínimo. Para cada quantidade de estímulos analisada, avaliou-se quais seriam os espaçamentos máximo e mínimo possíveis, de acordo com as 40 possibilidades de estímulos disponíveis, sempre iniciando da menor frequência, 8 Hz, considerando espaçamentos uniformes entre estímulos. Em termos de espaçamento mínimo, os mesmos 0,2 Hz foram adotados para todos os números de estímulos acima. Já para o máximo, o espaçamento surgiu de uma relação entre a maior e menor frequência disponível, 8 e 15,8 Hz, e o número de estímulos desejado. Assim, para 4 estímulos, por exemplo, o cenário de espaçamento máximo correspondeu a 8, 10,6, 13,2 e 15,8 Hz;
- **Duração da janela de estímulos:** janelas de 3, 2 e 1 s. A justificativa é análoga ao caso do número de frequências evocadas.

A combinação das variações descritas resultou em um conjunto composto por 18 experimentos, conforme ilustrado na Figura 4.2. Para a apresentação dos resultados na forma de desempenho do sistema BCI-SSVEP, avaliou-se como métrica a taxa de acerto média das  $F$  frequências evocadas obtida pelo classificador, seguindo um esquema de validação cruzada. Na validação cruzada, uma vez obtida a matriz de atributos, as amostras foram aleatoriamente selecionadas, destinando 80% dos dados disponíveis para treinamento e 20% para validação, conforme o esquema *holdout*. Como as amostras da matriz de atributos foram separadas aleatoriamente, 20 repetições independentes do processo de treinamento/validação foram realizados, de modo que a média das 20 repetições fornecesse um desempenho com maior robustez estatística para cada um dos 35 voluntários avaliados. A Figura 4.3 resume o procedimento adotado na etapa de classificação da BCI.

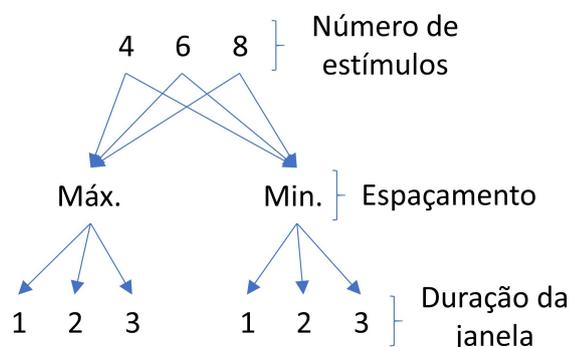


Figura 4.2 – Combinações de cenários experimentais.

Em relação às técnicas de pré-processamento, primeiramente avaliamos as variações com respeito à etapa de filtragem. Nessa etapa, analisamos dados sem filtragem

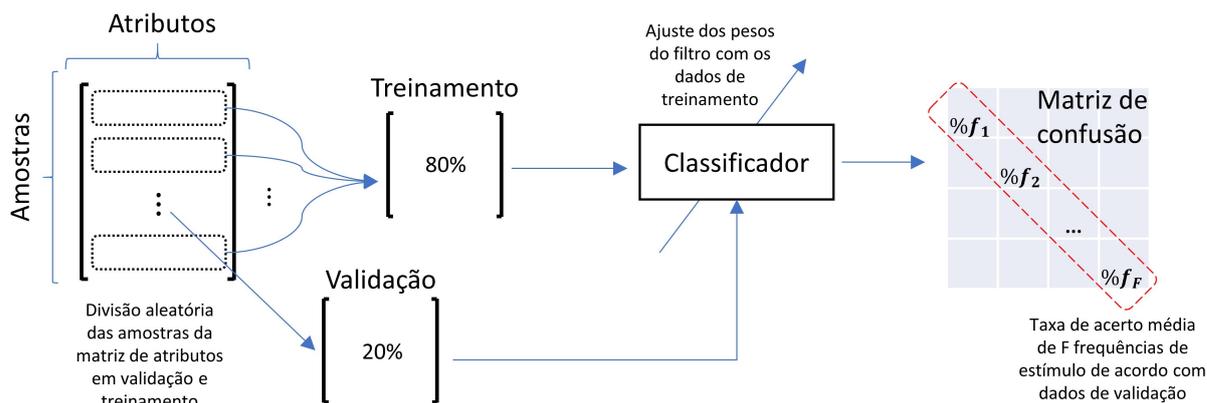


Figura 4.3 – Esquema de treinamento e validação adotado pela BCI.

(dados brutos), com filtragem CAR, CCA e MVDR. Na extração de atributos, confrontamos a FFT com o CCA com 1 harmônica (CCA-1h) e 2 harmônicas (CCA-2h). Por fim, na etapa de classificação, todas as variações citadas foram avaliadas por um classificador linear baseado no método dos quadrados mínimos. A Figura 4.4 indica o arranjo de técnicas adotadas nos experimentos.

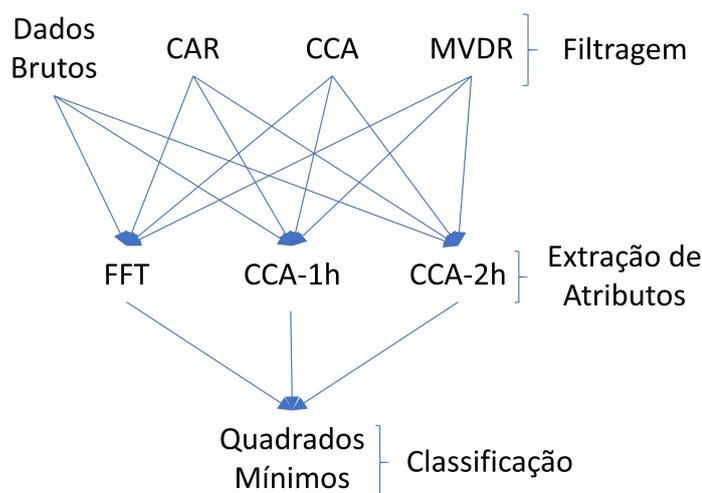


Figura 4.4 – Combinações de técnicas de pré-processamento analisadas nos cenários experimentais.

Além dos três fatores citados anteriormente, a filtragem espaço-temporal MVDR é regida por outros três parâmetros: a ordem do filtro ( $m$ ), o número de eletrodos ( $L$ ) e o número de eletrodos a serem combinados ( $k$ ). Esses dois últimos, em conjunto, sugerem a criação de novos canais em quantidade máxima definida pela Equação (4.2). Tais parâmetros, nos procedimentos experimentais iniciais foram ajustados de acordo com as contribuições propostas por (LEITE, 2016).

Assim sendo, para os cenários citados anteriormente, adotamos  $m = 30$ , 16 eletrodos (O1, O2, Oz, POz, Pz, PO3, PO4, PO7, PO8, P1, P2, Cz, C1, C2, CPz, FCz) e  $k = 2$ . Mais especificamente em relação ao número de eletrodos empregados, sua escolha

também foi baseada na restrição matemática imposta pelo filtro CCA. Como citado anteriormente na subseção 3.1.2, o número de canais e/ou eletrodos deve ser maior ou igual a duas vezes o número de frequências evocadas multiplicado pelo número de componentes harmônicas avaliadas. Conseqüentemente, para o cenário com 8 estímulos, necessitaríamos de, no mínimo, 16 eletrodos.

Outra importante informação a ser destacada está relacionada com a quantidade de amostras disponíveis por sinal na base de dados considerada no trabalho. Como cada sinal possui duração de 5 s e desejamos avaliar o comportamento do filtro para janelas de 3 e 2 s, por exemplo, foi necessário lançar mão do artifício da sobreposição durante o janelamento, a fim de se obter uma quantidade representativa de dados para o treinamento do sistema BCI-SSVEP. A sobreposição foi adotada para todos os métodos, não existindo formas de favorecimento ao método proposto. Desta maneira, para janelas de 3 s, adotamos uma sobreposição de 2 s, totalizando 3 janelas; para 2 s, uma sobreposição de 1 s, resultando em total de 4 janelas. Para janelas de 1 s, não houve a necessidade de sobreposição.

### 4.1.3 Influência do Número de Estímulos, Espaçamento em Frequência e Duração da Janela

De acordo com todas as possíveis variantes do filtro MVDR, vamos primeiramente avaliar a sensibilidade do filtro com respeito ao número de estímulos, ao afastamento entre frequências e à duração de janelas de estímulos, considerando as três variações de técnicas para extração de atributos: FFT, CCA-1h e CCA-2h. As Tabelas 4.1, 4.2 e 4.3 reúnem os resultados referentes às três variações citadas, apresentando a taxa de acerto média de 35 voluntários, considerando para cada um, a média de 20 realizações independentes do processo de classificação. Cada realização, por sua vez, adotou a taxa de acerto média das  $F$  frequências de estímulo empregadas pelo sistema BCI-SSVEP. O desvio-padrão entre os voluntários também é apresentado para cada método.

A partir dos resultados mostrados na Tabela 4.1, podemos verificar os efeitos do tamanho da janela de estimulação e, também, do espaçamento entre frequências. Para todos os métodos analisados, quedas significativas de desempenho foram observadas, seja com a diminuição da janela, ou com a diminuição de espaçamento entre frequências. Com a adição de outro fator considerado dificultador, o número de estímulos, e análises complementares das Tabelas 4.2 e 4.3, podemos perceber novamente uma queda de desempenho para todos os métodos, nos cenários com janelas de 2 e 1 s. Excepcionalmente para janelas de 3 s, se comparado aos demais métodos, o MVDR não apresentou variações significativas com o aumento do número de frequências de evocação.

De modo geral, a combinação MVDR/CCA-2h obteve os melhores resultados para janelas de 3 e 2 s. Para janelas de 1 s, entretanto, observamos uma drástica queda de

	Estímulo (Hz)	Afastamento Mínimo			Afastamento Máximo			
		8	8,2	8,4	8,6	8	10,6	13,2
	Janela (s)	3	2	1	3	2	1	
F F T	Dados Brutos	54,3±10,9	43,4±9,0	31,5±5,7	77,6±13,3	72,4±14,6	67,1±15,2	
	CAR	62,2±12,1	47,6±9,5	35,0±6,3	83,1±12,0	79,3±13,2	73,9±13,3	
	CCA	81,3±11,3	64,8±11,4	40,9±7,5	95,2±6,8	91,7±10,2	83,9±12,8	
	MVDR	88,1±8,2	66,4±10,4	35,5±6,9	98,7±2,0	95,7±5,2	81,7±13,1	
C	Dados Brutos	55,6±11,2	41,9±9,1	33,5±7,2	73,2±14,9	68,1±14,7	64,5±15,9	
C	CAR	61,6±13,4	46,3±9,5	34,7±6,9	79,7±14,1	75,0±15,2	73,0±14,1	
A	CCA	81,3±11,4	64,6±10,8	41,4±7,9	94,9±6,2	91,6±9,3	83,9±13,0	
1h	MVDR	91,0±8,5	69,1±10,9	38,8±7,5	99,1±1,6	96,5±4,8	82,0±11,8	
C	Dados Brutos	65,4±13,6	56,9±10,9	43,8±7,0	75,4±13,6	71,5±14,5	67,0±12,8	
C	CAR	72,3±14,7	63,7±11,8	47,8±8,6	82,9±14,0	78,2±13,2	74,5±12,3	
A	CCA	92,6±9,2	85,3±12,3	<b>56,3±8,9</b>	96,6±5,7	94,4±8,3	<b>85,7±11,2</b>	
2h	MVDR	<b>96,5±6,0</b>	<b>87,4±9,9</b>	51,3±8,5	<b>99,2±1,7</b>	<b>99,0±5,6</b>	83,0±11,9	

Tabela 4.1 – Resultados para os cenários considerando 4 frequências de estimulação.

	Estímulo (Hz)	Afastamento Mínimo					Afastamento Máximo				
		8	8,2	8,4	8,6	8,8	9,0	8	9,4	10,8	12,2
	Janela (s)	3	2	1	3	2	1				
F F T	Dados Brutos	48,3±10,1	38,2±9,7	25,1±6,2	75,2±15,7	67,6±16,4	55,5±19,1				
	CAR	55,8±12,2	43,1±10,7	27,8±5,9	81,9±12,9	76,1±14,8	66,5±16,6				
	CCA	58,3±12,1	54,3±12,9	29,6±6,5	83,5±13,2	82,5±15,3	67,3±17,7				
	MVDR	84,7±11,5	58,0±12,8	26,4±3,9	97,7±4,7	94,6±7,9	75,8±17,1				
C	Dados Brutos	46,5±12,4	35,6±9,5	24,7±5,5	69,8±17,3	65,7±17,6	58,5±19,2				
C	CAR	54,0±12,9	40,9±11,6	28,0±7,1	76,5±18,7	73,4±17,7	68,9±18,0				
A	CCA	57,3±13,1	53,8±13,0	28,9±6,2	82,6±13,9	82,5±14,9	67,3±17,9				
1h	MVDR	85,9±10,7	58,9±12,2	26,1±5,2	97,7±5,8	93,5±10,9	77,2±17,7				
C	Dados Brutos	58,6±14,9	49,8±11,9	34,2±8,3	74,2±16,8	71,4±16,5	64,6±18,1				
C	CAR	66,9±14,6	57,9±12,2	39,5±8,1	80,4±16,9	77,8±16,5	74,9±15,4				
A	CCA	74,0±13,2	73,3±13,2	<b>41,5±9,5</b>	86,8±12,4	88,7±12,2	75,9±15,7				
2h	MVDR	<b>93,9±9,0</b>	<b>75,3±12,5</b>	34,2±6,9	<b>98,3±4,7</b>	<b>96,0±8,1</b>	<b>82,6±15,2</b>				

Tabela 4.2 – Resultados para os cenários considerando 6 frequências de estimulação.

	Estímulo (Hz)	Afastamento Mínimo			Afastamento Máximo				
		8	8,2	8,4	8,6	8,8	9,0	9,2	9,4
		3	2	1	3	2	1		
F F T	Dados Brutos	45,2±11,3	34,3±9,7	21,8±6,1	67,8±18,0	62,4±20,6	53,0±22,4		
	CAR	53,3±13,2	39,7±10,7	25,0±6,6	76,3±15,7	70,9±18,3	61,9±20,4		
	CCA	52,9±12,9	34,6±9,8	21,7±5,3	74,5±18,3	63,2±19,9	52,4±21,2		
	MVDR	91,6±7,4	61,6±12,8	20,7±3,8	93,9±9,9	85,8±11,7	55,0±20,6		
C	Dados Brutos	42,6±12,3	33,2±10,2	21,4±5,7	64,1±19,8	59,4±20,3	53,5±22,0		
C	CAR	50,5±14,2	39,3±12,0	24,8±6,5	71,7±20,0	68,9±19,9	63,5±21,0		
A	CCA	54,6±14,1	34,4±10,6	21,6±5,9	74,2±15,9	61,6±19,2	51,8±20,9		
1h	MVDR	91,8±8,1	61,9±12,6	21,0±3,6	94,5±9,4	86,6±15,5	57,4±21,0		
C	Dados Brutos	56,6±15,5	45,8±12,1	29,5±7,7	69,4±20,0	67,6±20,5	60,3±21,2		
C	CAR	64,9±16,6	54,0±13,8	<b>35,2±8,1</b>	77,2±19,0	75,4±18,6	<b>70,0±18,4</b>		
A	CCA	71,5±14,0	49,0±11,9	29,9±7,3	80,6±15,0	70,2±18,2	60,5±20,0		
2h	MVDR	<b>92,6±8,0</b>	<b>63,1±11,4</b>	21,9±4,1	<b>95,7±8,0</b>	<b>92,2±10,1</b>	64,3±20,4		

Tabela 4.3 – Resultados para os cenários considerando 8 frequências de estimulação.

desempenho dessa configuração, sendo superada por combinações como CCA/CCA-2h e/ou CAR/CCA-2h. É importante destacar que todas as melhores configurações obtidas empregaram o CCA com duas componentes harmônicas na etapa de extração de atributos. É possível inferir que a incorporação de uma segunda componente harmônica acabou sendo decisiva para a superioridade desta abordagem em relação às demais que empregam apenas uma, tendo em vista a ótima relação sinal-ruído observada também na segunda harmônica para essa base de dados (WANG et al., 2016). Além disso, em uma comparação direta entre FFT e CCA-1h, podemos perceber uma grande similaridade nos valores de acurácia média (ou taxa de acerto média), existindo certa equivalência entre elas.

Em um primeiro momento, consideramos os resultados obtidos bastante interessantes, pois foi possível obter um entendimento mais sólido do comportamento do filtro em cenários adversos. Em uma conclusão precoce, baseados nos resultados do MVDR para janelas de 1 s, seria possível dizer que a utilização do método é inviável para essa duração de estímulo, pois se comparado com os resultados dos dados brutos (sem filtragem), observamos certa igualdade ou até inferioridade da filtragem espaço-temporal. Para a FFT, por exemplo, o desempenho para os dados brutos correspondeu a 21,8%, contra 20,7% para o MVDR. Já para extração com CCA utilizando duas componentes harmônicas, esse desempenho correspondeu a 29,5% para os dados brutos, enquanto o MVDR atingiu desempenho de 21,9%.

Por um lado, os resultados revelam uma possível fragilidade da técnica MVDR. Por outro lado, eles encorajam um aprofundamento dos estudos pautados nesse cenário em questão, por meio da preparação de testes adicionais, com a finalidade de tornar visíveis possíveis caminhos para melhorias em termos de desempenho. Assim sendo, avaliamos

agora os efeitos das diferentes ordens do filtro MVDR, considerando exclusivamente os casos com janelas de 1 s, por ser este o cenário mais desafiador para o sistema BCI-SSVEP proposto.

#### 4.1.4 Efeitos da Ordem do Filtro $m$

Como avaliado por (LEITE, 2016), a ordem do filtro é de extrema importância na garantia de um bom desempenho por parte do filtro MVDR. O tamanho do filtro deve ser pensado de acordo com o número de amostras da janela temporal analisada, pois ordens consideradas pequenas e/ou muito grandes podem levar o filtro à instabilidade, o que seria desastroso para uma técnica de filtragem. Por isso, quantificaremos agora as contribuições da ordem do filtro, considerando as configurações do MVDR utilizando os métodos CCA-1h, CCA-2h e FFT como extratores de atributos. Os cenários empregados serão os de mínimo e máximo espaçamento, com 8 frequências de estimulação, com a ordem variando de 10 a 110, com passos de 20.

As Figuras 4.5 e 4.6 exibem as curvas de desempenho do sistema BCI-SSVEP de acordo com a variação da ordem do filtro e para cada método avaliado. Em ambos os cenários, é possível notar um comportamento semelhante entre as técnicas de extração de atributos FFT e CCA. De modo geral, a taxa de acerto apresentou uma queda à medida que o tamanho do filtro se eleva, exceto para o cenário de máximo espaçamento, visto o aumento do desempenho observado para  $m = 50$ , seguido novamente de uma queda de desempenho. Entretanto, em todos os casos, é possível concluir que um filtro com 10 coeficientes foi o que mais contribuiu para o desempenho da BCI, podendo ser considerado, agora, a ordem ideal para a operação do filtro MVDR.

Para ordens superiores a  $m = 90$ , o filtro MVDR enfrentou fortes dificuldades na obtenção da solução ótima, apresentando divergências para alguns voluntários. Como os resultados apresentados correspondem à média dos 35 indivíduos, consideramos um resultado global de divergência para ordens superiores a 90. Esse resultado é, de certa forma, esperado, pois de acordo com a análise anterior da relação entre número de pontos da janela de estímulo e ordem do filtro, podemos ponderar que para esse caso, com 250 amostras por janela, uma ordem acima de 90 é relativamente alta, não sendo adequada para essas condições de aplicação.

Por fim, a Tabela 4.4 resgata os resultados obtidos anteriormente para o MVDR considerando uma ordem  $m = 30$ , de acordo com as técnicas de extração propostas, mostrando a evolução de desempenho obtida com a melhor ordem encontrada. Se lembrarmos que a melhor configuração obtida para os cenários de mínimo e máximo espaçamento, considerando oito estímulos, eram oriundas do CAR/CCA-2h, com taxas de acerto de 35,2% e 70,0%, respectivamente, é possível afirmar que o MVDR/CCA-2h forneceu resultados superiores, 42,2% e 84,0%, apresentando agora contribuições também em cenários

com janelas de 1 s de duração. Neste ponto, estamos progredindo em direção a uma configuração mais adequada dos parâmetros do filtro espaço-temporal proposto. Desta forma, avaliaremos na próxima seção o efeito que novas combinações de eletrodos podem ter, computando o desempenho da BCI para diferentes valores de  $k$ .

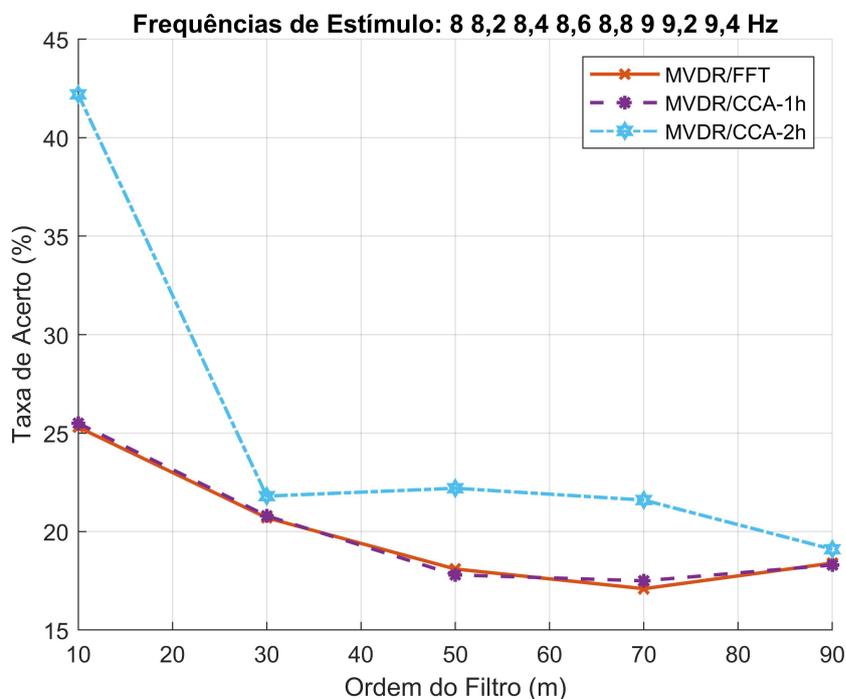


Figura 4.5 – Efeito de diferentes ordens do filtro MVDR considerando o cenário de mínimo espaçamento, com 8 frequências de estímulo.

		Afastamento Mínimo								Afastamento Máximo							
Estímulo (Hz)		8	8,2	8,4	8,6	8,8	9,0	9,2	9,4	8	9	10	11	12	13	14	15
M V D R	FFT	20,7 → 25,3 ( $m = 10$ )								55,0 → 72,4 ( $m = 10$ )							
	CCA-1h	21,0 → 25,5 ( $m = 10$ )								57,4 → 73,3 ( $m = 10$ )							
	CCA-2h	21,9 → <b>42,2</b> ( $m = 10$ )								64,3 → <b>84,0</b> ( $m = 10$ )							

Tabela 4.4 – Melhores resultados após análises de ordem do filtro MVDR.

#### 4.1.5 Efeitos da Quantidade de Eletrodos Combinados $k$

Recordemos que o filtro proposto, seguindo as ideias originais do trabalho Leite (2016), pode ser descrito como um sistema de múltiplas entradas e múltiplas saídas, conforme relatado no Capítulo 4. No caso das saídas, aqui descritas como canais, sua quantidade é determinada pela relação de combinação, de acordo com a Equação (4.2). Se levarmos em consideração que, até o momento, estamos utilizando 16 eletrodos, a análise de um valor de  $k$  maior que 2 inviabilizaria o emprego do método em aplicações reais.

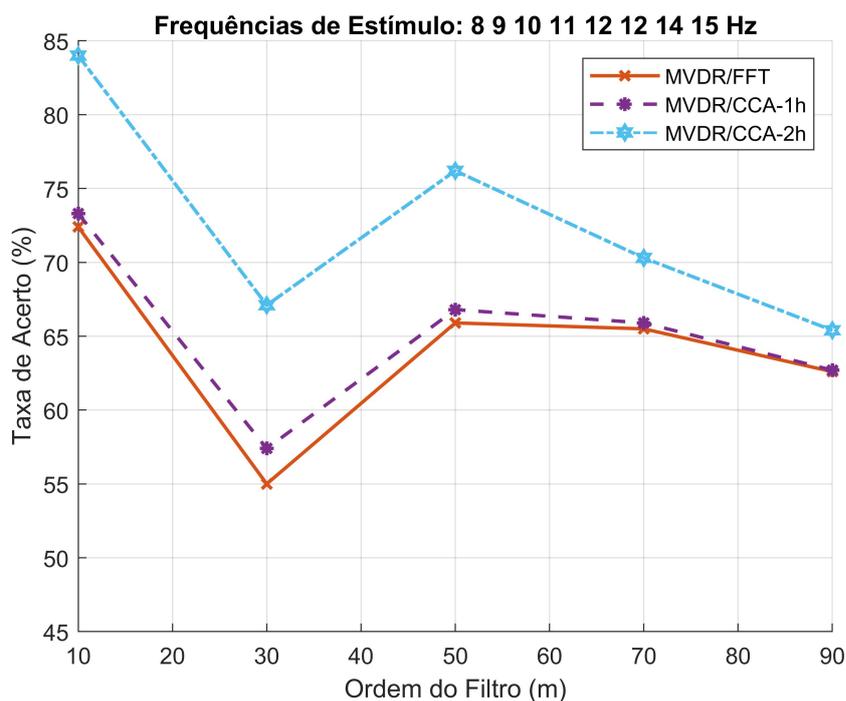


Figura 4.6 – Efeito de diferentes ordens do filtro MVDR considerando o cenário de máximo espaçamento, com 8 frequências de estímulo.

Imagine, por exemplo, que  $k$  fosse igual a 8. Neste caso, teríamos  $\frac{16!}{8!(16-8)!} = 12870$  novos canais. Essa quantidade de canais é compilada em uma matriz de atributos para todas as janelas e todos os *trials*. Seria realmente uma quantidade volumosa de dados para o modelo proposto.

Com isso em mente, surgiu a decisão de reduzir o número de eletrodos para 9. A escolha por esta quantidade foi motivada por uma análise da literatura, como, por exemplo, o trabalho de Wang et al. (2016), o qual sugere inclusive quais os eletrodos mais informativos para a base de dados utilizada. Não obstante, adotamos um conjunto de nove eletrodos ligeiramente diferente daquele indicado por Wang et al. (2016), pois se mostrou mais favorável ao desempenho do sistema BCI em nossos experimentos. Ao final, os eletrodos explorados em nosso trabalho foram os seguintes: P1, Pz, P2, P03, POz, PO4, O1, Oz e O2. A partir dessa escolha, recordemos novamente também da restrição matemática imposta ao CCA como técnica de filtragem indicada na subseção 3.1.2. Para  $L = 9$ , o número máximo de classes que o sistema poderia operar seria 4. Por isso, os testes subsequentes referem-se ao cenário com 4 estímulos, de modo a confrontar novamente o MVDR com demais técnicas clássicas aplicadas a sistemas BCI-SSVEP.

O cenário de testes escolhido empregou as seguintes frequências evocadas: 8, 10, 12 e 15 Hz, para janelas de 1 s de duração. Essa escolha pode ser justificada com os resultados construídos anteriormente, a partir dos quais percebemos que todos os métodos avaliados apresentam desempenho superior em cenários com maior espaçamento entre

frequências de estímulo. Além disso, como desejamos obter o melhor desempenho possível para a obtenção de um sistema BCI-SSVEP realizável e robusto, o cenário citado atua no favorecimento desse objetivo.

Antes da apresentação dos resultados obtidos, é importante destacar que nos experimentos realizados, o valor de  $k$  variou de 2 a 8, com passo unitário. Em relação à ordem do filtro adotada, testou-se previamente a ordem ótima para esse número de eletrodos e, conseqüentemente, utilizamos  $m = 10$ . Os resultados são apresentados na Tabela 4.5. Por fim, para uma análise mais completa, os resultados obtidos para o MVDR são confrontados com as demais técnicas, sendo indicados na Tabela 4.6.

$k$	MVDR		
	FFT	CCA-1h	CCA-2h
2	71,6	68,2	75,8
3	77,9	76,5	83,9
4	78,2	78,0	85,0
5	78,0	78,2	85,2
6	77,8	76,5	84,0
7	71,4	68,3	75,9
8	81,6	80,2	<b>87,2</b>

Tabela 4.5 – Melhores resultados após análises do valor de  $k$ .

Primeiramente, de acordo com a Tabela 4.5, evidenciamos a grande importância de uma escolha adequada para  $k$ . Com esses resultados, é possível levantar a hipótese de que certa combinação de eletrodos pode não favorecer o desempenho do MVDR. Contudo, para  $k = 8$ , obtivemos a melhor configuração do MVDR combinado com as técnicas de extração de atributos avaliadas. Novamente, a configuração MVDR/CCA-2h foi a

		Desempenho (%)
FFT	Dados Brutos	74,7±17,3
	CAR	82,6±15,5
	CCA	78,3±15,1
CCA-1h	Dados Brutos	73,8±17,6
	CAR	82,0±15,3
	CCA	78,2±15,6
CCA-2h	Dados Brutos	82,3±14,7
	CAR	<b>89,0±11,6</b>
	CCA	86,0±13,8

Tabela 4.6 – Desempenho dos demais métodos considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz.

que retornou a maior taxa de acerto dentre as técnicas estudadas nesse experimento. Entretanto, se agora conectarmos os resultados das Tabelas 4.5 e 4.6, é possível concluir que a melhor configuração citada anteriormente é superada pelo CAR em conjunto com CCA-2h.

Aparentemente, surge um gargalo para o método proposto, visto a inferioridade em relação ao método clássico CAR. Contudo, de acordo com as análises até então realizadas, o MVDR, para uma mesma ordem, tende a proporcionar um melhor desempenho ao sistema, quando um número menor de frequências evocadas é apresentado ao filtro, especialmente para janelas de 1 s. Para ilustrar a situação, consideremos a filtragem de um sinal com 5 s de duração, obtido a partir do eletrodo Oz. Para uma mesma ordem,  $m = 125$ , o sinal foi filtrado considerando as frequências de evocação 8, 10, 12 e 15 Hz, e somente para 8 Hz. A Figura 4.7 apresenta a comparação entre o sinal sem filtragem e com filtragem, para as duas variações citadas.

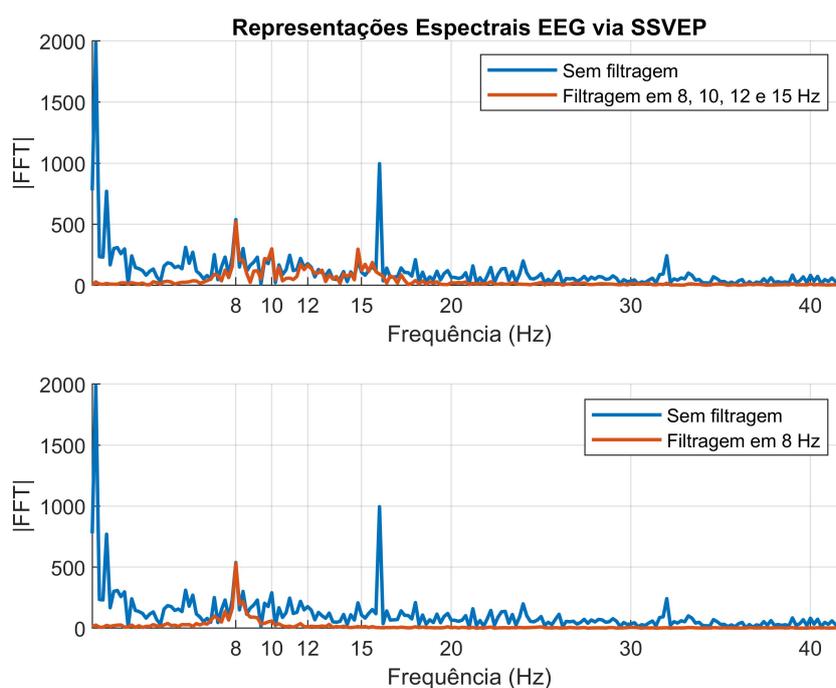


Figura 4.7 – Efeitos da filtragem individual de estímulos. No primeiro caso, 4 estímulos são filtrados simultaneamente. No segundo, apenas a filtragem em 8 Hz.

Pela Figura 4.7, podemos concluir que, para a mesma ordem do filtro, a filtragem individual proporcionou um pico bem definido na frequência de interesse, 8 Hz, enquanto a filtragem para quatro estímulos apresentou resquícios de outras componentes espectrais, além de pico pouco representativo em 12 Hz. Um aumento da ordem do filtro poderia redefinir os picos nas quatro frequências com maior exatidão. Entretanto, como avaliado na subseção 4.1.4, o aumento da ordem tende a não favorecer o desempenho do sistema BCI-SSVEP.

Desta maneira, uma extensão do filtro MVDR na forma de um banco de filtros, identificado pela abreviação FBMVDR (do inglês, *filter bank minimum variance distortionless response*) surge como uma alternativa promissora para contornar esse impasse, já que considera a filtragem individual de cada estímulo e, conseqüentemente, permite a adoção de uma ordem inferior, se comparado aos casos de filtragem de mais estímulos. Em vista disso, discutiremos no próximo capítulo todas as premissas do FBMVDR, avaliando sua aplicabilidade em sistemas BCI-SSVEP.

## 5 Banco de Filtros Espaço-Temporal

Neste capítulo, vamos formalizar a proposta de um banco de filtros MVDR, no qual cada filtro é projetado para preservar uma única frequência de interesse (uma das frequências de estimulação ou alguma harmônica). Em seguida, vamos analisar o desempenho do sistema BCI-SSVEP empregando esta técnica, contrastando-o com os melhores resultados obtidos até este ponto da dissertação. Finalmente, exploraremos conceitos de filtragem adaptativa a fim de estudar o funcionamento do FBMVDR adaptativo.

### 5.1 A Ideia do Banco de Filtros

Nas análises realizadas no Capítulo 4, foi possível observar que o número de estímulos empregados pelo sistema BCI-SSVEP influencia consideravelmente o seu desempenho. Mais especificamente, verificamos que a utilização de mais classes dificulta a ação do filtro, apesar de fornecer mais graus de liberdade para uma possível aplicação do sistema BCI proposto.

Neste contexto, a construção de um banco de filtros MVDR desponta como uma alternativa promissora. Uma vez que cada filtro é dedicado a uma única frequência, o número de classes não é mais um fator complicador para o filtro. Além disso, o processo de filtragem não necessita de ordens muito elevadas para ser efetivo. Não obstante, esta abordagem eleva o custo computacional devido ao maior número de filtros individuais, como será visto mais adiante.

Outra importante questão associada ao FBMVDR está relacionada com a possibilidade de avaliar componentes harmônicas para a FFT, como no caso da CCA, por exemplo. Dos resultados anteriores, a CCA com duas componentes harmônicas foi a técnica que contribuiu de maneira mais efetiva para o MVDR, devido principalmente ao emprego da segunda harmônica na obtenção dos atributos do sistema. Acreditamos, então, que essa opção do FBMVDR possa beneficiar uma melhor avaliação da FFT como método de extração de atributos.

No desenvolvimento do método, retornemos ao diagrama geral do MVDR, indicado na Figura 4.1. Agora, suponhamos que  $F$  estímulos estejam disponíveis, representados por  $f_1, f_2, \dots, f_F$ , sendo que para cada frequência serão consideradas  $n_h$  componentes harmônicas. Para um conjunto de  $k$  eletrodos combinados, o FBMVDR constroi  $F \times n_h$  filtros MVDR, conforme indicado na Figura 4.1, produzindo, assim, uma saída  $y(n)$  para cada filtro. Ou seja, o FBMVDR prevê o projeto de um filtro MVDR para cada frequência de estimulação e para cada harmônica. As saídas dos filtros relacionados à mesma frequên-

cia fundamental são agrupadas em um novo conjunto, a partir do qual são extraídos os atributos conforme a técnica de extração escolhida. Dentre os atributos obtidos, escolhemos o de maior amplitude para compor a matriz de atributos de entrada do classificador, a fim de assegurar que sua dimensão continue idêntica àquela utilizada no caso do filtro MVDR convencional. Este procedimento é repetido para as  $F$  frequências de estimulação, conforme ilustrado no diagrama da Figura 5.1.

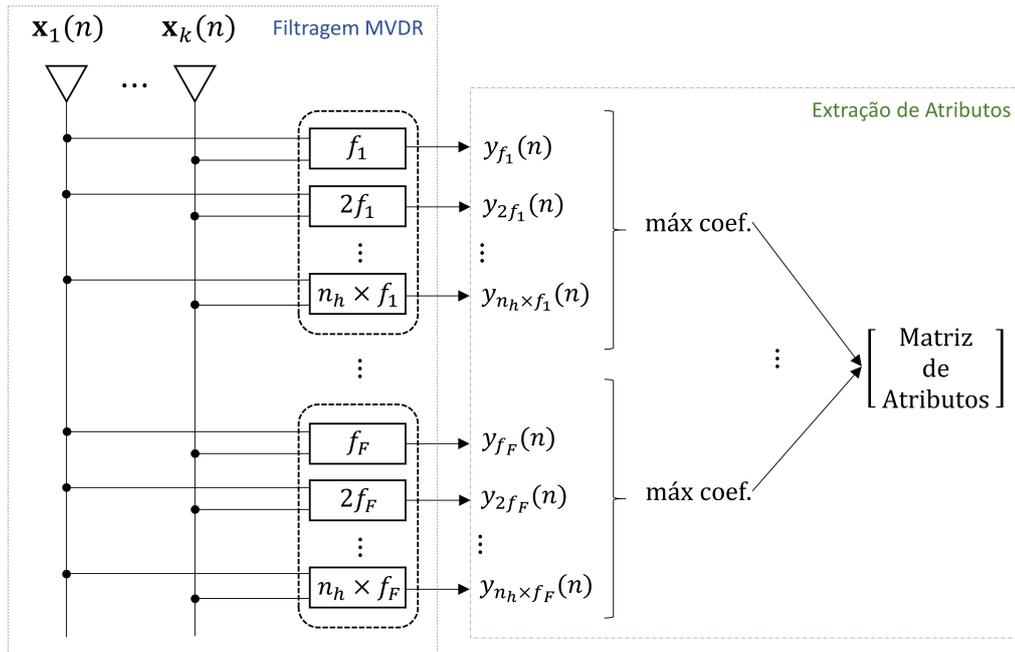


Figura 5.1 – Estrutura geral do banco de filtros espaço-temporal MVDR. Os sinais de  $k$  eletrodos são filtrados por  $n_h \times F$  filtros MVDR, cada um dedicado a uma única frequência alvo; a partir das saídas dos filtros associados à mesma frequência fundamental  $f_i$ , são extraídos atributos e aquele que apresentar a maior magnitude representa a informação corresponde a esta frequência.

É inegável que exista um aumento do custo computacional proveniente do FBMVDR, se comparado à técnica inicialmente proposta. Antes, se o número de filtros para cada janela e *trial* no MVDR decorria da relação de combinação  $C_{L,k}$ , agora esse número corresponde a  $C_{L,k} \times n_h \times F$ . Contudo, as contribuições que essa extensão traz podem contrabalançar esse aumento de custo computacional, por meio de um aprimoramento do desempenho do sistema BCI-SSVEP estudado.

Para a avaliação dessas contribuições, utilizaremos novamente o último cenário testado: 4 frequências de estimulação (8, 10, 12 e 15 Hz), para janelas de 1s, pois foi nesse cenário que o método MVDR mostrou-se inferior, em termos de desempenho, em relação ao CAR. Os mesmos parâmetros considerados ótimos obtidos anteriormente, como ordem do filtro ( $m = 10$ ) e quantidade de eletrodos combinados ( $k = 8$ ) serão adotados também para o FBMVDR. A CCA-1h, como técnica de extração de atributos, não será utilizado nesse experimento, uma vez que se mostrou inferior às demais técnicas no cenário supracitado.

Deste modo, a Tabela 5.1 apresenta os resultados para o FBMVDR, considerando a FFT e a CCA como técnicas de extração, ambas empregando duas componentes harmônicas.

FBMVDR	
FFT-2h	92,4±9,8
CCA-2h	<b>92,6±10,1</b>

Tabela 5.1 – Desempenho do FBMVDR considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz.

A Tabela 5.1 revela resultados positivos para a extensão do MVDR proposta. Antes, o melhor desempenho do MVDR era de 87,2%, com uma combinação com o CCA-2h (MVDR/CCA-2h). Com a aplicação da ideia do banco de filtros, esse resultado saltou para 92,6%, novamente com a combinação com o CCA-2h (FBMVDR/CCA-2h), representando um aumento acima de 5 pontos percentuais. Além disso, se compararmos com o melhor desempenho global antes obtido, que foi de 89% com a combinação CAR/CCA-2h, o FBMVDR/CCA-2h promoveu um aumento próximo de 4 pontos percentuais, atingindo um desempenho bastante satisfatório e superando todas as alternativas estudadas. Para se ter uma ideia do desempenho para cada indivíduo, confrontamos os resultados associados às combinações CAR/CCA-2h e FBMVDR/CCA-2h na Tabela 5.2, com informações de desvio-padrão referentes às 20 repetições independentes realizadas pelo classificador.

Além da taxa de acerto do classificador, introduzimos uma análise estatística de acordo com o Teste de Wilcoxon Pareado (do inglês, *Wilcoxon rank sum test*). Nessa abordagem, o teste avalia a hipótese de que dois conjuntos de dados são representados por distribuições contínuas de mesma mediana (GIBBONS; CHAKRABORTI, 2020). No contexto estudado, é possível avaliar, par-a-par, para quais voluntários é possível aceitar ou rejeitar a hipótese de que os resultados apresentados possuem mesma mediana, ou seja, se existiu um empate estatístico em termos de desempenho, de acordo com valores lógicos de  $h$ , onde  $h = 1$  indica rejeição da hipótese nula e  $h = 0$  o contrário. Desta forma, também na Tabela 5.2, apresentaremos a probabilidade de rejeição da hipótese nula, *p-value*, bem como o valor de  $h$  para todos os 35 voluntários.

Voluntário	CCA-2h		Teste de Wilcoxon	
	FBMVDR	CAR	<i>p-value</i>	$h$
1	90,1±5,7	87,9±7,2	0,6460	0
2	93,0±4,6	92,7±5,0	0,0064	1
3	99,9±1,2	94,2±5,0	0,0000	1
4	98,6±1,7	95,6±3,0	0,0000	1
5	100,0±0,0	98,0±2,6	0,0000	1

6	99,0±1,2	94,2±5,8	0,0000	1
7	84,9±6,5	80,5±8,7	0,0000	1
8	95,3±3,9	92,1±4,7	0,0088	1
9	86,9±6,1	82,1±8,0	0,0001	1
10	96,0±3,9	93,5±4,7	0,0000	1
11	73,9±9,6	74,0±9,2	0,0008	1
12	99,9±0,8	82,3±8,6	0,0000	1
13	96,2±3,4	94,4±4,7	0,9250	0
14	98,3±2,6	99,3±2,2	0,6560	0
15	97,9±1,3	96,2±3,2	0,0000	1
16	88,6±5,7	74,7±8,8	0,0000	1
17	95,4±3,0	95,6±3,9	0,9173	0
18	82,0±7,2	81,4±8,0	0,8086	0
19	76,3±9,4	76,0±9,6	0,0434	1
20	97,4±2,3	95,7±4,5	0,0000	1
21	93,3±4,6	87,4±7,5	0,0000	1
22	98,9±2,5	95,0±4,0	0,1712	0
23	89,2±5,8	79,4±9,3	0,0000	1
24	99,2±1,6	96,0±3,2	0,0000	1
25	100,0±0,0	96,0±4,6	0,0000	1
26	99,3±1,1	98,3±2,6	0,0002	1
27	96,1±3,5	96,4±3,8	0,2931	0
28	95,6±5,6	84,9±7,2	0,0000	1
29	69,4±8,8	58,0±10,3	0,0000	1
30	97,8±3,0	97,1±2,3	0,4651	0
31	100,0± 0,0	99,9±0,4	0,3222	0
32	99,3± 0,0	99,7±2,0	0,0005	1
33	59,3±9,2	51,3±9,6	0,0003	1
34	100,0±0,0	98,±1,6	0,0131	1
35	95,5±4,6	94,9±3,7	0,6835	0
<b>Média</b>	<b>92,6±9,8</b>	<b>89,0±11,5</b>	-	-

Tabela 5.2 – Desempenhos individuais de 35 voluntários do FBMVDR/CCA-2h e CAR/CCA-2h considerando o cenário de 4 frequências de estímulo 8, 10, 12 e 15 Hz.

Complementarmente, na Figura 5.3 apresentamos o *boxplot* para os 35 volun-

tários, novamente, em uma análise par-a-par. No *boxplot* apresentado, de acordo com o número de repetições independentes do processo de classificação realizado, é possível avaliar informações sobre a taxa de acerto da BCI-SSVEP, como valores máximo e mínimo, média e mediana, localização dos percentis, e a presença de *outliers*. Mais especificamente em relação aos percentis, os valores empregados corresponderam ao 25º e ao 75º, que representam as arestas das extremidades da caixa, vistas verticalmente. Isso significa dizer que, se o 75º percentil corresponde a uma taxa de acerto de 80% no eixo das ordenadas, 75% das repetições independentes resultaram em uma taxa de acerto de 80%. De modo geral, a Figura 5.2 ilustra o significado de cada parcela representada em um *boxplot*.

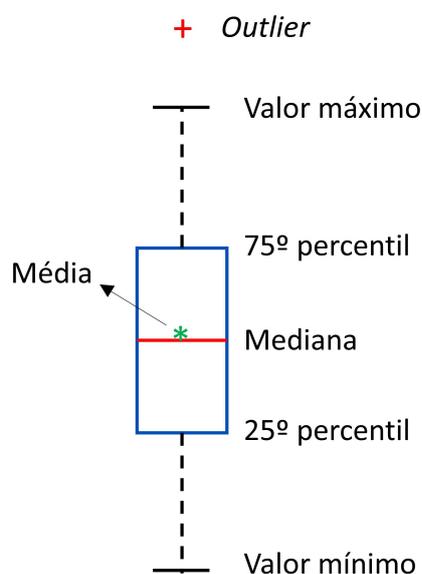


Figura 5.2 – Identificação das grandezas representadas no *boxplot*.

Analisando a Tabela 5.2 e a Figura 5.3, podemos concluir que o FBMVDR foi superior ao CAR para a maioria dos 35 voluntários. Nas análises recorrentes do Teste de Wilcoxon com um nível de confiança de 0,05, é possível perceber que, para alguns voluntários, como o 1, 13, 14, 17, 18 e o 35, temos indícios suficientes para decretar um empate estatístico entre os dois métodos avaliados. Para os voluntários 22, 27, 30 e 31, entretanto, apesar do valor de  $h$  indicar a não-rejeição de medianas iguais, o  $p$ -value não fornece uma probabilidade suficiente para aceitarmos essa conclusão. Para os demais voluntários, o FBMVDR apresentou uma melhora significativa de desempenho. Em alguns momentos, obtivemos um aumento de performance maior que 10 pontos percentuais, chegando próximo a 18 pontos percentuais, como no caso do voluntário 12, por exemplo.

Outra importante constatação levantada está relacionada com a variabilidade das repetições independentes do classificador. Na grande maioria dos voluntários analisados, além de elevar a taxa de desempenho médio do sistema BCI-SSVEP, o FBMVDR foi capaz de diminuir a variabilidade de desempenho, de forma que as repetições independentes apresentassem valores próximos uns dos outros, o que revela uma regularidade de

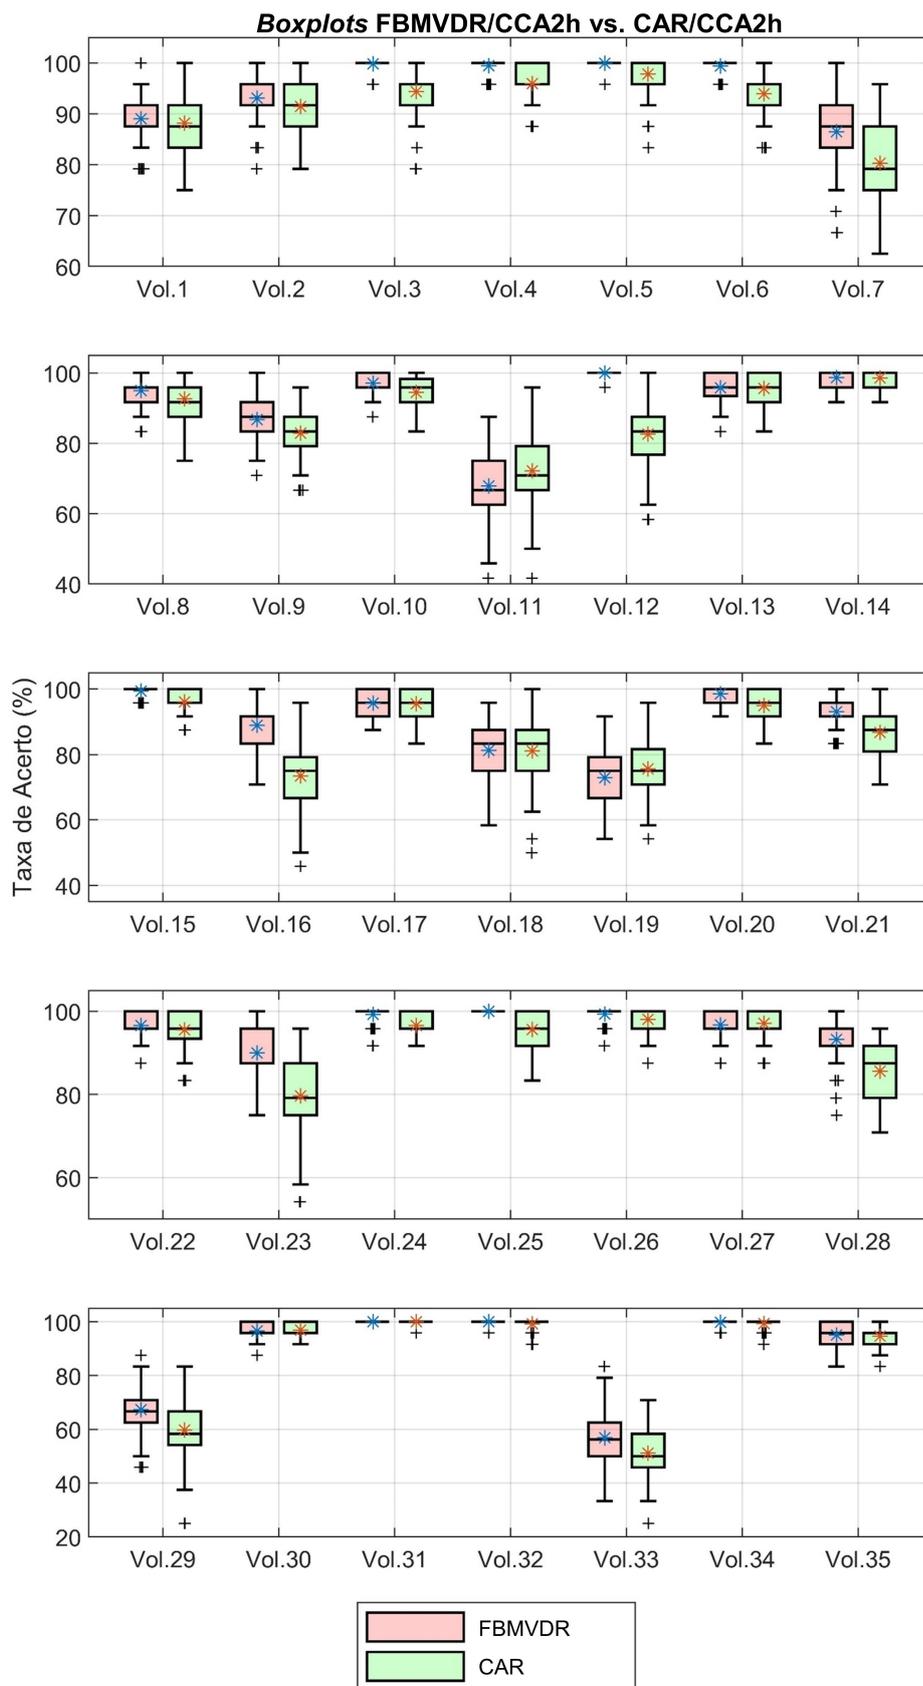


Figura 5.3 – *Boxplot* para os 35 voluntários, confrontando os métodos FBMVDR/CA-2h e CAR/CCA-2h em cenário com 4 frequências de estímulo 8, 10, 12 e 15 Hz.

desempenho do método. Em um dos casos mais marcantes, novamente para o paciente 12, a caixa do *boxplot* colapsou para o FBMVDR, indicando que todas as representações estatísticas avaliadas no *boxplot* convergiram para o mesmo valor, próximo a 100%, exceto pela presença de um *outlier* próximo a 95%.

Tais resultados consolidam a busca da melhor versão do MVDR, por meio de sua extensão na forma de um banco de filtros. Em resumo, para uma ordem 10, combinando 9 eletrodos 8 a 8, foi possível observar que a técnica de filtragem espaço-temporal MVDR proposta traz contribuições relevantes para sistemas BCI-SSVEP, principalmente na busca de um sistema robusto com alta taxa de desempenho.

Finalmente nessa dissertação, após a obtenção da melhor configuração do filtro espaço-temporal, vamos considerar mais uma variante do filtro MVDR por meio de um paralelo com a área de filtragem adaptativa. Dessa forma, surge a proposta de um banco de filtros adaptativo, aqui denominado de FBMVDR adaptativo.

## 5.2 Estratégias de Adaptação

Na busca pela incorporação de conceitos adaptativos aliados ao MVDR, avaliaremos dois conhecidos algoritmos: o Algoritmo de Frost (1972), também conhecido como CLMS (do inglês *constrained least-mean squares*), e a técnica proposta por Resende, Romano e Bellanger (1996), o *Robust CFLS* (do inglês *constrained fast least-squares*). A abordagem do problema será a mesma adotada anteriormente, seguindo o diagrama da Figura 4.1, exceto pela maneira com que os coeficientes do filtro são obtidos, agora, de modo iterativo.

### 5.2.1 Algoritmo de Frost

Assim como o MVDR, o Algoritmo de Frost tem suas origens nos problemas de posicionamento de antenas. Neste contexto em particular, Frost (1972) propôs uma solução de ajuste de sensores para operação em tempo real, de acordo com a aplicação do LMS com restrições lineares, utilizando o gradiente descendente nas iterações adaptativas.

Da formulação do MVDR desenvolvida no Capítulo 4, temos que o vetor ótimo de coeficientes é dado pela Equação (4.21), reproduzida abaixo para facilitar a discussão.

$$\mathbf{w} = \mathbf{R}^{-1}\mathbf{C}(\mathbf{C}^T\mathbf{R}^{-1}\mathbf{C})^{-1}\mathbf{g} \quad (5.1)$$

É possível inferir que o cálculo de  $\mathbf{w}$  envolve certa complexidade associada à inversão da matriz de autocorrelação ( $\mathbf{R}$ ) dos dados de entrada, calculada a cada obtenção de um novo canal. No algoritmo agora proposto, assumimos inicialmente que essa matriz  $\mathbf{R}$  seja desconhecida, sendo estimada de maneira adaptativa. Essa facilidade fornecida

pelo algoritmo é relevante no sentido de evitar inversões de  $\mathbf{R}$ , que possivelmente pode ser mal condicionada e, conseqüentemente, diminui o custo computacional da tarefa de determinação dos coeficientes do filtro. Em termos numéricos, Frost (1972) estima que o custo computacional para a solução dos coeficientes  $\mathbf{w}$  na forma fechada, conforme a Equação (5.1), seja proporcional ao cubo do número de coeficientes desejados para o filtro, enquanto para a técnica adaptativa, esse número se reduz ao quadrado do valor de  $m$ .

Na derivação da extensão adaptativa do MVDR, é necessário supor *a priori* que a matriz  $\mathbf{R}$  seja conhecida, de forma que a equação de atualização dos coeficientes de  $\mathbf{w}$  na iteração  $n$ , segundo o LMS com gradiente descendente, seja representada da seguinte forma (FROST, 1972):

$$\begin{aligned}\mathbf{w}(n+1) &= \mathbf{w}(n) - \mu \nabla_{\mathbf{w}} H(\mathbf{w}(n)) \\ &= \mathbf{w}(n) - \mu(\mathbf{R}\mathbf{w}(n) + \mathbf{C}\boldsymbol{\lambda}(n))\end{aligned}\tag{5.2}$$

onde  $\mu$  é o passo de adaptação adotado.

No modo adaptativo, as restrições impostas em (4.15) passam agora a considerar o processo iterativo, de modo que:

$$\mathbf{C}^T \mathbf{w}(n+1) = \mathbf{g}\tag{5.3}$$

Combinando as Equações (5.3) e (5.2):

$$\mathbf{C}^T(\mathbf{w}(n) - \mu(\mathbf{R}\mathbf{w}(n) + \mathbf{C}\boldsymbol{\lambda}(n))) = \mathbf{g}\tag{5.4}$$

Encontrando  $\boldsymbol{\lambda}(n)$  e substituindo-o em (5.2):

$$\begin{aligned}\mathbf{w}(n+1) &= \mathbf{w}(n) - \mu(\mathbf{I} - \mathbf{C}(\mathbf{C}^T \mathbf{C}^{-1})\mathbf{C}^T)\mathbf{R}\mathbf{w}(n) \\ &\quad + \mathbf{C}(\mathbf{C}^T \mathbf{C}^{-1})(\mathbf{g} - \mathbf{C}^T \mathbf{w}(n))\end{aligned}\tag{5.5}$$

Para deixar a equação em uma forma mais enxuta, vamos definir os seguintes vetores e matrizes:

$$\mathbf{M} \triangleq \mathbf{C}(\mathbf{C}^T \mathbf{C}^{-1})\mathbf{g}\tag{5.6a}$$

$$\mathbf{P} \triangleq \mathbf{I} - \mathbf{C}(\mathbf{C}^T \mathbf{C}^{-1})\mathbf{C}^T\tag{5.6b}$$

Assim, reescrevendo a Equação (5.5), chegamos a:

$$\mathbf{w}(n+1) = \mathbf{P}(\mathbf{w}(n) - \mu\mathbf{R}(n)\mathbf{w}(n)) + \mathbf{M}\tag{5.7}$$

Há, porém, um entrave para o uso efetivo da regra de atualização em (5.7): em sistemas BCI-SSVEP, não temos informações *a priori* sobre a matriz de correlação dos sinais de EEG. Felizmente, seguindo o espírito da aproximação estocástica (ROBBINS; MONRO, 1951), podemos substituir a matriz  $\mathbf{R}$  na iteração  $n$  simplesmente pelo valor instantâneo aproximado pelo produto externo do vetor de entrada com ele próprio, ou seja,  $\mathbf{x}(n)\mathbf{x}^T(n)$ . Assim:

$$\mathbf{w}(n+1) = \mathbf{P}(\mathbf{w}(n) - \mu y(n)\mathbf{x}(n)) + \mathbf{M} \quad (5.8)$$

Subsequentemente, é necessário comentar a respeito da inicialização do vetor de coeficientes do filtro. De modo a satisfazer as restrições impostas em (4.15), estabelece-se que no instante zero, o vetor de pesos seja tal que  $\mathbf{w}(0) = \mathbf{M}$ . Essa inicialização, juntamente com a Equação (5.8), formam o par de equações que regem a regra adaptativa proposta para o MVDR, segundo o algoritmo de Frost.

Por fim, devemos comentar a respeito do passo de adaptação  $\mu$ . Em seu trabalho, com base em análises da estabilidade do algoritmo, Frost (1972) sugere faixas de valores para  $\mu$  que garantem a convergência dos coeficientes do filtro para solução ótima. Entretanto, tais recomendações envolvem operações, como o traço e o cálculo de autovalores da matriz  $\mathbf{R}$ . Bellanger (2001), por sua vez, sugere a determinação de  $\mu$  por meio de uma relação entre o número de coeficientes do filtro e estimativas em tempo real da potência do sinal de entrada, de modo que:

$$\mu(n) = \frac{1}{m\sigma_{\mathbf{x}(n)}^2} \quad (5.9)$$

### 5.2.2 Algoritmo *Robust* CFLS

Em cenários onde as variáveis de entrada envolvidas possuem alto nível de correlação, espera-se que métodos baseados no LMS apresentem certa inferioridade em termos de velocidade de adaptação (convergência) e acurácia. Motivados por esses fatores, Resende, Romano e Bellanger (1996) apresentam uma nova abordagem para o problema de filtragem com restrições lineares, propondo uma solução mais robusta ao algoritmo FLS (do inglês, *fast least-squares*).

O desenvolvimento do método se inicia com a determinação da função custo a ser minimizada, que é representada por:

$$H(n) = \sum_{i=1}^n V^{n-i} (\mathbf{w}^T(n)\mathbf{x}(i))^2 \quad (5.10)$$

onde  $V$  é o fator de esquecimento e é regido pela condição  $0 \ll V \leq 1$ .

Assim como proposto anteriormente, a minimização de (5.10) está sujeita às restrições representadas em (4.15). A solução encontrada, obviamente, é a mesma indicada em (4.21), exceto pelo cálculo da matriz de correlação dos sinais de entrada que agora incorpora o fator de esquecimento em sua construção, como indicado na equação abaixo:

$$\mathbf{R}(n) = \sum_{i=1}^n V^{n-i} \mathbf{x}(i) \mathbf{x}^T(i) \quad (5.11)$$

Na apresentação da solução ótima por Resende, Romano e Bellanger (1996), é definido  $\mathbf{\Gamma}(n) = \mathbf{R}^{-1}(n) \mathbf{C}$ , de modo que a solução ótima em (4.21) é reescrita como:

$$\mathbf{w}(n) = \mathbf{\Gamma}(n) (\mathbf{C}^T \mathbf{\Gamma}(n))^{-1} \mathbf{g} \quad (5.12)$$

Para que as restrições desejadas sejam incluídas em cada iteração, reescrevemos a Equação (5.12) como:

$$\mathbf{w}(n+1) = \mathbf{Q}(n+1) \mathbf{g} \quad (5.13)$$

onde a matriz  $\mathbf{Q}(n+1)$  é tal que  $\mathbf{Q}(n+1) = \mathbf{\Gamma}(n+1) (\mathbf{C}^T \mathbf{\Gamma}(n+1))^{-1}$ .

O algoritmo robusto é obtido de acordo com uma equação de recursividade para  $\mathbf{Q}(n+1)$ . Essa equação será apenas indicada abaixo. Toda a fundamentação omitida pode ser encontrada com detalhes no trabalho de Resende, Romano e Bellanger (1996).

$$\mathbf{Q}(n+1) = \left[ \mathbf{Q}(n) - \mathbf{r}(n+1) \mathbf{v}^T(n+1) \right] \left[ \mathbf{I} + \frac{\mathbf{u}(n+1) \mathbf{v}^T(n+1)}{1 - \mathbf{v}^T(n+1) \mathbf{u}(n+1)} \right], \quad (5.14)$$

onde os vetores  $\mathbf{u}$  e  $\mathbf{v}$  são definidos como sendo:

$$\mathbf{u}(n+1) = \mathbf{C}^T \mathbf{r}(n+1) \quad (5.15)$$

$$\mathbf{v}^T(n+1) = \mathbf{x}^T(n+1) \mathbf{Q}(n) \quad (5.16)$$

com  $\mathbf{r}(n)$  sendo o ganho de adaptação.

Para conceber a robustez esperada, assumimos que a Equação (5.14) possa conter erros de arredondamento numérico, sendo agora denominada  $\mathbf{Q}'(n+1)$ . Com a inserção de um termo de correção, obtemos  $\mathbf{Q}(n+1)$  como:

$$\mathbf{Q}(n+1) = \mathbf{Q}'(n+1) + \mathbf{C} (\mathbf{C}^T \mathbf{C})^{-1} (\mathbf{I} - \mathbf{C}^T \mathbf{Q}'(n+1)) \quad (5.17)$$

---

 Algoritmo *Robust* CFLS
 

---

1. Novos dados em um instante  $(n + 1)$ :  $\mathbf{x}(n + 1)$
  2. Computar o ganho de adaptação:  $\mathbf{r}(n + 1)$
  3. Atualizar a matriz  $\mathbf{Q}(n + 1)$ :
 
$$\mathbf{u}(n + 1) = \mathbf{C}^T \mathbf{r}(n + 1)$$

$$\mathbf{v}^T(n + 1) = \mathbf{x}^T(n + 1) \mathbf{Q}(n)$$

$$\mathbf{Q}'(n + 1) = \left[ \mathbf{Q}(n) - \mathbf{r}(n + 1) \mathbf{v}^T(n + 1) \right] \left[ \mathbf{I} + \frac{\mathbf{u}(n + 1) \mathbf{v}^T(n + 1)}{1 - \mathbf{v}^T(n + 1) \mathbf{u}(n + 1)} \right]$$

$$\mathbf{Q}(n + 1) = \mathbf{Q}'(n + 1) + \mathbf{C}(\mathbf{C}^T \mathbf{C})^{-1} (\mathbf{I} - \mathbf{C}^T \mathbf{Q}'(n + 1))$$
  4. Computar a saída do filtro:  $y(n + 1) = \mathbf{w}^T \mathbf{x}(n + 1)$
  5. Atualizar os coeficientes do filtro:  $\mathbf{w}(n + 1) = \mathbf{Q}(n + 1) \mathbf{g}$
- 

Quadro 1 – Passo-a-passo adotado pelo algoritmo *Robust* CFLS.

Assim, obtemos a recursão proposta para o algoritmo. Em resumo, o Quadro 1 reúne o passo-a-passo para se computar o *Robust* CFLS.

Para o funcionamento do algoritmo *Robust* CFLS, necessitamos primeiramente determinar os valores de  $\mathbf{R}(0)$ ,  $\mathbf{Q}(0)$  e  $\mathbf{\Gamma}(0)$ . Os autores [Resende, Romano e Bellanger \(1996\)](#) recomendam as seguintes inicializações:

$$\mathbf{R}(0) = E_0 \begin{bmatrix} \mathbf{R}_1(0) & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & \mathbf{R}_k(0) \end{bmatrix}$$

onde  $E_0$  é a energia do erro de predição progressivo,  $\mathbf{R}_k(0)$  a matriz de autocorrelação no instante zero para o  $k$ -ésimo eletrodo

$$\mathbf{R}_k(0) = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & V^{-1} & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & V^{-(m-1)} \end{bmatrix},$$

$$\mathbf{Q}(0) = \mathbf{\Gamma}(0) (\mathbf{C}^1 \mathbf{\Gamma}(0))^{-1}$$

e

$$\mathbf{\Gamma}(0) = \mathbf{R}(0)\mathbf{C}$$

Mais especificamente para  $\mathbf{R}(0)$ , também é necessário o ajuste do parâmetro  $E_0$ . Em sua análise dos valores iniciais para a energia do erro de predição progressiva, [Bellanger \(2001\)](#) sugere que, para valores tais que  $E_0 \geq 0, 1$ , operações satisfatórias do algoritmo são obtidas.

Por fim, é necessário comentar a respeito do ganho de adaptação  $\mathbf{r}(n+1)$ . Dentre os algoritmos existentes para esse cálculo, optamos pelo algoritmo FLS, que é descrito pelo par de equações abaixo, segundo [Bellanger \(2001\)](#):

$$\mathbf{r}(n+1) = \frac{1}{V + \mathbf{x}^T(n+1)\mathbf{R}(n)\mathbf{x}(n+1)}\mathbf{R}^{-1}\mathbf{x}(n+1) \quad (5.18a)$$

$$\mathbf{R}^{-1}(n+1) = \frac{1}{V}(\mathbf{R}^{-1}(n) - \mathbf{r}(n+1)\mathbf{x}^T(n+1)\mathbf{R}^{-1}(n)) \quad (5.18b)$$

### 5.3 Comparação entre Técnicas Adaptativas

Dadas as formulações teóricas e matemáticas das duas técnicas de adaptação propostas, realizamos inicialmente uma análise comparativa em termos de velocidade de convergência e quantificação do erro. Para efeitos de exemplificação, de acordo com a segmentação dos sinais disponíveis em janelas de 1 s, selecionamos a primeira janela de estimulação, correspondente ao primeiro *trial*, dos sinais com estímulo em 8 Hz para os 10 primeiros voluntários. Desta forma, os resultados aqui apresentados representam os coeficientes do FBMVDR-CAR adaptativo para filtragem em 8 Hz.

Na validação dos resultados obtidos, empregamos as melhores configurações previamente obtidas para o MVDR, que foi o FBMVDR com 10 coeficientes ( $m = 10$ ), utilizando 9 eletrodos combinados 8 a 8. O cenário avaliado também foi o mesmo: 8, 10, 12 e 15 Hz. A métrica adotada foi a norma Euclidiana da diferença entre os coeficientes ótimos ( $\mathbf{w}_o$ ) e os coeficientes obtidos por cada técnica,  $\|\mathbf{w}_o - \mathbf{w}\|_2$ . Para a inicialização dos métodos, ambos partiram dos mesmos valores, seguindo as recomendações propostas por [Frost \(1972\)](#).

No primeiro momento, selecionamos o voluntário 9 como o paciente base, encontrando para ele o melhor valor de  $\mu$  para a janela citada, de acordo com o CLMS. Esse valor de  $\mu$  encontrado foi, então, empregado para os demais voluntários, como forma de evidenciar os efeitos de uma escolha inapropriada para o passo de adaptação. Subsequentemente, buscamos o valor do passo que retornasse o menor erro para todos os pacientes, contrastando com os resultados obtidos para o *Robust* CFLS. A Tabela 5.3

exibe os valores da norma Euclidiana para os casos citados, considerando os voluntários de 1 a 10 da base de dados utilizada.

É possível constatar na Tabela 5.3 uma certa inferioridade do CLMS em relação ao *Robust* CFLS, pois para o método de Frost necessitamos de um ajuste adequado para  $\mu$ , visto os altos valores da norma Euclidiana quando ajustado de acordo com o passo de adaptação ótimo de paciente 9. Além disso, para o *Robust* CFLS, o mesmo ajuste de parâmetros,  $E_o$  e  $V$ , foi replicado para todos os voluntários, sendo possível obter taxas mínimas de erro. Para o caso do método de Frost, isso não foi possível de ser obtido, visto que cada voluntário requereu um ajuste diferente para  $\mu$ .

Voluntário	CLMS			<i>Robust</i> CFLS
	$\ \mathbf{w}_o - \mathbf{w}\ _2$ $\mu = 0,00003$	$\mu$	$\ \mathbf{w}_o - \mathbf{w}\ _2$	$\ \mathbf{w}_o - \mathbf{w}\ _2$ $E_o = 0,1$ e $V = 0,9999$
1	1,1067	0,00035	0,1853	0,0085
2	1,3658	0,0002	0,3070	0,0134
3	0,8986	0,00045	0,3303	0,018
4	0,2891	0,0001	0,0709	0,0085
5	1,1476	0,00025	0,2119	0,012
6	0,2680	0,0001	0,0597	0,0118
7	1,9159	0,00015	0,5889	0,0164
8	0,3087	0,000075	0,1539	0,0114
9	0,0372	0,00003	0,0372	0,0043
10	0,6183	0,0002	0,0691	0,01

Tabela 5.3 – Análise de convergência para as técnicas adaptativas.

Além da facilidade fornecida pelo *Robust* CFLS em termos de ajuste inicial de parâmetros, é possível também apontar uma superioridade do método em termos de velocidade de convergência. Na análise realizada para o voluntário 9, ilustrada na Figura 5.4, é evidente essa superioridade do algoritmo, atingindo uma convergência satisfatória já na segunda época de adaptação. O CLMS, por outro lado, apresentou uma convergência extremamente mais lenta, atingindo o regime após a milésima época de adaptação, aproximadamente.

Foi possível avaliar também os dois métodos em termos da taxa de acerto do sistema BCI-SSVEP. Nos experimentos realizados, os sinais foram filtrados seguindo o protocolo adaptativo; porém, as etapas subsequentes, extração de atributos e classificação, seguiram o padrão *offline*. Com isso, apenas após a obtenção de todas as amostras do sinal filtrado é que o classificador entrou em cena para determinar a classe correspondente.

Como o CLMS exige um ajuste prévio do passo de adaptação, optamos por utilizar o passo de acordo com a Equação (5.9), a qual, de acordo com análises preliminares, não fornece a menor norma em relação a  $\mathbf{w}_o$ . Contudo, em termos da taxa de acerto do

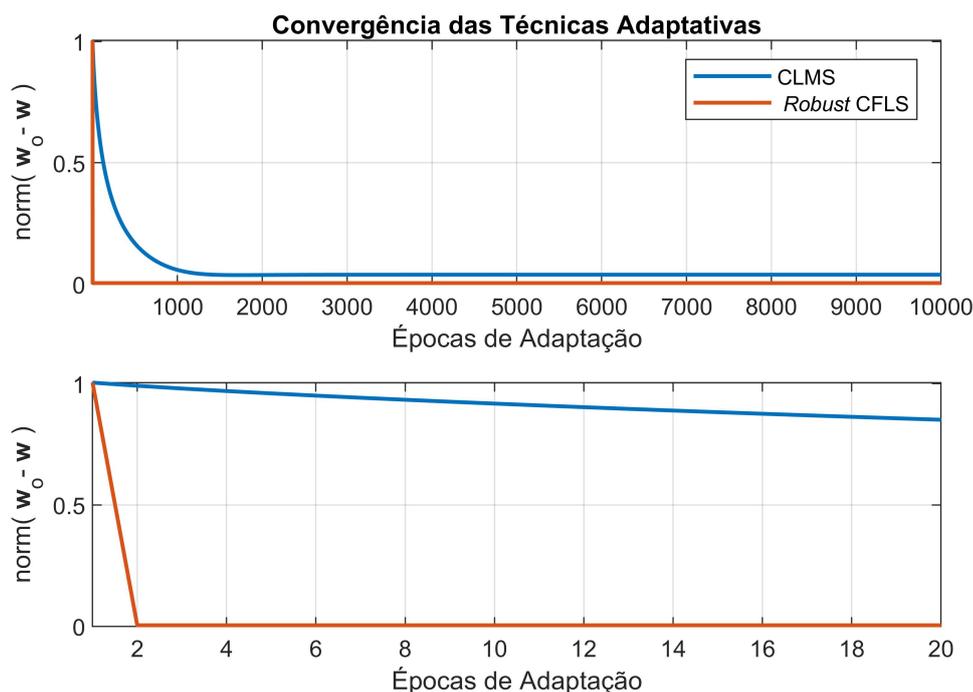


Figura 5.4 – Velocidade de convergência para os algoritmos de Frost (1972) - CLMS e Resende, Romano e Bellanger (1996) - Robust CFLS para o paciente 9.

sistema, forneceu resultados próximos aos obtidos pelo FBMVDR/CCA-2h com solução fechada, conforme pode ser revisto na Tabela 5.1. O mesmo aconteceu para o Robust CFLS, sendo os resultados das técnicas adaptativas apresentados na Tabela 5.4.

Técnica	Taxa de Acerto (%)
Solução fechada	$92,6 \pm 10,1$
CLMS	$92,3 \pm 10,3$
Robust CFLS	$92,5 \pm 10,9$

Tabela 5.4 – Desempenho do sistema BCI-SSVEP para extensões do MVDR.

Apesar de diferenças marcantes entre as duas técnicas adaptativas propostas, principalmente em termos de sensibilidade aos parâmetros, podemos concluir que os métodos promovem resultados satisfatórios, principalmente se pensarmos exclusivamente na taxa de acerto do sistema. Assim, ambas as técnicas são realizáveis no contexto de sistemas BCI-SSVEP, apesar da superioridade evidente do Robust CFLS.

## 6 Comparações com o Estado da Arte

Neste capítulo, abordaremos brevemente uma técnica considerada estado da arte para sistemas BCI-SSVEP, o banco de filtros CCA (FBCCA, do inglês *filter bank canonical correlation analysis*), confrontando-a com a melhor configuração obtida para o FBMVDR-CAR.

Nas análises comparativas, seguiremos o mesmo protocolo adotado por [Chen et al. \(2015\)](#) e [Wang et al. \(2016\)](#), o qual apresenta algumas diferenças em relação ao procedimento que temos empregado até o momento. Neste novo protocolo, o sinal de EEG é representado por um conjunto de dados correspondendo a  $n_s$  *trials*,  $L$  eletrodos,  $F$  estímulos e  $d$  amostras. Não há mais um conjunto de  $p$  janelas/segmentos do sinal, pois o processo de segmentação consiste em selecionar amostras igualmente espaçadas de todo o sinal com duração de 5 s, de acordo com a latência visual de 130 *ms*, conforme indicado na subseção 4.1.1.

Outra diferença está na forma de contabilização do desempenho do sistema. No protocolo anterior, o experimento de treinamento e validação do sistema BCI-SSVEP era repetido, de modo independente, 20 vezes, tomando-se a média dessas repetições. No novo protocolo, os *trials* são classificados separadamente, sendo o resultado médio por paciente obtido pela média dos  $n_s$  *trials*.

### 6.1 Banco de Filtros CCA (FBCCA)

Para o entendimento da técnica FBCCA, proposta por ([CHEN et al., 2015](#)), devemos considerar inicialmente a análise de um conjunto multicanal de dados de EEG, representado por  $L$  eletrodos  $\times$   $d$  amostras. Sobre este conjunto de dados é feita uma divisão em  $N$  sub-bandas, de acordo com filtros *Chebyshev* tipo I, IIR e fase mínima. Para cada sub-banda, determina-se o coeficiente de correlação canônica entre o sinal filtrado e o sinal de referência correspondente a determinada frequência de estímulo, conforme descrito na subseção 3.2.2. Desta forma, cada frequência de evocação possuirá uma soma ponderada dos coeficientes citados, de modo que o coeficiente máximo determinará a classificação da classe. A Figura 6.1 ilustra o esquema de filtragem proposto.

A ponderação das sub-bandas, representada no somatório pelo vetor de pesos  $\mathbf{w}_N$ , é determinada de acordo com a relação  $\mathbf{w}_N(sb) = sb^{-a} + b$ ,  $sb \in [1 N]$ . Os valores de  $a$  e  $b$  são constantes empregadas para que o desempenho da etapa classificadora seja maximizado e são determinadas por mecanismos de busca profunda. De acordo com [Wang et al. \(2016\)](#), para  $a = 1,25$  e  $b = 0,25$ , o banco de filtros CCA promove o melhor

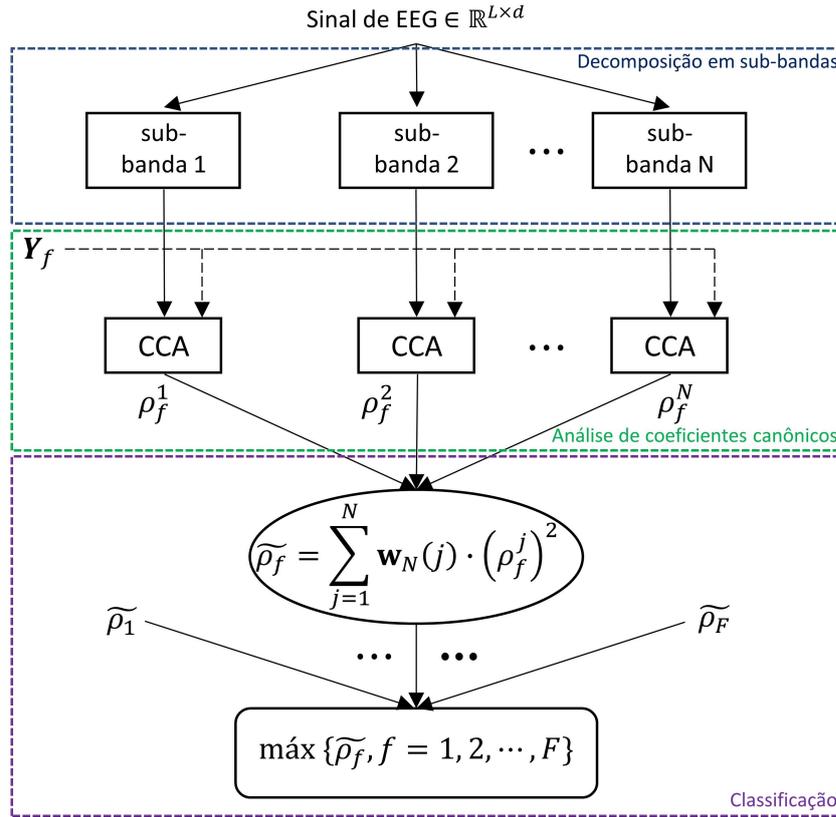


Figura 6.1 – Esquema de filtragem FBCCA. Adaptado de (CHEN et al., 2015).

desempenho dentre todos os valores avaliados. Além das constantes  $a$  e  $b$ , é necessário também determinar o número ótimo de sub-bandas  $N$ , bem como o número de componentes harmônicas  $n_h$  a serem avaliadas na determinação de cada sinal de referência. Novamente, Wang et al. (2016) indicam valores ótimos para  $N$  e  $n_h$ , sendo ambos iguais a 5.

O método analisado, apesar de envolver a parametrização de um número considerável de constantes, apresenta-se como uma técnica livre de treinamento. Essa facilidade remove uma etapa considerada exaustiva em sistemas BCI-SSVEP, contribuindo para diminuir a chance de ocorrência de fadiga visual no paciente durante a operação do sistema.

A diferença substancial entre o FBCCA e o FBMVDR proposto se dá na divisão do sinal de EEG. Enquanto o FBCCA divide o sinal em  $N$  sub-bandas, o FBMVDR calcula filtros individuais para cada frequência de estímulo e suas componentes harmônicas, conforme indicado no esquema da Figura 5.1. Por essa razão, o FBMVDR é considerado computacionalmente mais custoso que o FBCCA e, por isso, a comparação entre os dois métodos será baseada no último cenário proposto, com 4 frequências de estímulo (8, 10, 12 e 15 Hz) e janelas de 1 s, e não no cenário com 40 estímulos para o qual o FBCCA foi originalmente proposto.

## 6.2 Análise Comparativa

Além de empregarmos o mesmo cenário nos testes finais, os parâmetros de ajuste do FBMVDR-CAR também seguiram as mesmas escolhas indicadas no Capítulo 5:  $m = 10$ ,  $n_h = 2$ ,  $L = 9$  e  $k = 8$ , exceto por quais eletrodos foram utilizados. Para haver uma comparação equiparada, empregamos sinais dos nove eletrodos propostos por Wang et al. (2016), que são: Pz, PO5, PO3, POz, PO4, PO6, O1, Oz e O2.

Para o FBCCA, ajustamos os parâmetros de acordo com Wang et al. (2016), sendo eles:  $a = 1,25$ ,  $b = 0,25$ ,  $sb = 5$  e  $n_h = 5$ . No caso do FBMVDR, a utilização de cinco componentes harmônicas não alterou o desempenho do sistema de modo significativo e, por isso, a configuração anterior foi mantida. Além disso, adotamos o modelo de classificação proposto para o FBCCA também para o FBMVDR, de modo que os mesmos valores de  $a$  e  $b$  foram sintonizados, não havendo a necessidade de obtenção de matriz de atributos e atuação do classificador baseado nos quadrados mínimos. Os resultados por voluntário estão indicados na Tabela 6.1, contendo a média e desvio-padrão dos 35 pacientes e o desvio-padrão entre os *trials* para cada voluntário.

Voluntário	FBMVDR	FBCCA
1	95,8±10,2	100,0±0,0
2	95,8±10,2	95,8±10,2
3	100,0±0,0	100,0±0,0
4	95,8±10,2	100,0±0,0
5	100,0±0,0	100,0±0,0
6	91,7±12,9	91,7±12,9
7	95,8±10,2	87,5±20,9
8	100,0±0,0	79,2±18,8
9	83,3±20,4	83,3±20,4
10	95,8±10,2	100,0±0,0
11	66,7±20,4	62,5±26,2
12	100,0±0,0	100,0±0,0
13	91,7±12,9	91,7±12,9
14	91,7±12,9	95,8±10,2
15	95,8±10,2	95,8±10,2
16	83,3±25,8	91,7±12,9
17	91,7±12,9	83,3±20,4
18	87,5±13,7	83,3±20,4
19	50,0±27,4	45,8±24,6
20	91,7±20,4	79,2±18,8
21	83,3±12,9	87,5±13,7

22	95,8±10,2	100,0±0,0
23	87,5±13,7	95,8±10,2
24	100,0±0,0	95,8±10,2
25	100,0±0,0	100,0±0,0
26	100,0±0,0	100,0±0,0
27	91,7±12,9	95,8±10,2
28	95,8±10,2	100,0±0,0
29	91,7±12,9	87,5±13,7
30	95,8±10,0	87,5±20,9
31	100,0±0,0	100,0±0,0
32	100,0±0,0	100,0±0,0
33	83,3±20,4	75,0±27,4
34	100,0±0,0	100,0±0,0
35	87,5±20,9	83,3±12,9
<b>Média</b>	<b>91,9±10,1</b>	<b>90,7±11,8</b>

Tabela 6.1 – Desempenhos individuais de 35 voluntários do FBMVDR e FBCCA considerando o cenário de 4 frequências de estímulo 8, 10, 12e 15 Hz.

Dentre os resultados exibidos na Tabela 6.1, merecem um destaque especial aqueles associados aos voluntários 8 e 20. Nestes casos, o FBMVDR superou o FBCCA em mais de 10 pontos percentuais, atingindo mais de 20 pontos para o voluntário 8. Em uma análise mais completa, por meio de *boxplots*, foi possível realizar comparações em termos de taxa de acerto do sistema, considerando cada *trial* como uma realização independente do processo de identificação/classificação. A Figura 6.2 exibe os *boxplots* obtidos.

É possível constatar na Figura 6.2 uma grande variabilidade de resultados entre os *trials* para o FBCCA, para ambos os voluntários analisados. Nos dois casos, a mediana correspondeu a 75%, e o valor mínimo a uma taxa de acerto de 50%, não havendo, contudo, a presença de *outliers*. Já para o FBMVDR, para o voluntário 8, todos os *trials* resultaram em uma taxa de acerto de 100%, enquanto para o voluntário 20, em um dos *trials*, o resultado foi de 50% de acerto, sendo considerado um *outlier*, o que contribuiu fortemente para a redução do valor médio da taxa de acerto para 91,7%.

Também pela Tabela 6.1, podemos concluir que, na média, o FBMVDR foi ligeiramente superior ao FBCCA, superando-a em pouco mais de um ponto percentual. Isso indica que, além de ser superior às demais técnicas que não empregam a ideia de banco de filtros em sua construção, como o CCA tradicional e o CAR, o FBMVDR também é capaz de promover contribuições entre as técnicas que fazem o emprego do banco de filtros, como o FBCCA. Deste modo, concluímos as análises do filtro espaço-temporal MVDR, mostrando sua capacidade de atuação em sistemas BCI-SSVEP.

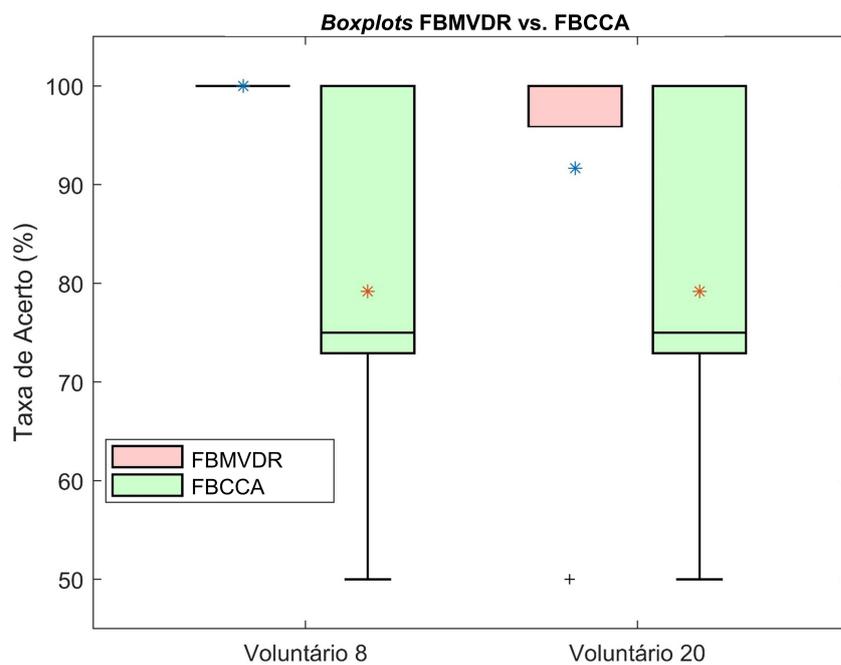


Figura 6.2 – *Boxplots* comparativos entre FBMVDR e FBCCA para os voluntários 8 e 20.

## 7 Conclusões

A etapa de processamento de sinais de EEG pode ser considerada uma das principais de um sistema BCI-SSVEP. Mais especificamente, no pré-processamento, existem diversas técnicas computacionais capazes de atenuar componentes indesejadas no sinal registrado, de modo a promover ganhos de desempenho ao sistema. Devido à possibilidade de combinar informações de diversos eletrodos, juntamente com a restrição de preservação de conteúdo espectral nas frequência de estímulo empregadas pela BCI, o filtro MVDR surge como uma técnica promissora a ser aplicada em sinais de EEG registrados sob o paradigma SSVEP.

Motivados pelas contribuições propostas por [Leite \(2016\)](#), o presente trabalho avaliou o comportamento da técnica de filtragem espaço-temporal MVDR aplicada a sistemas BCI-SSVEP, apresentando uma nova formulação matemática. Ademais, análises mais aprofundadas foram estabelecidas, com o principal intuito de avaliar o potencial do filtro e também suas limitações. Inicialmente, a técnica, em sua definição inicial, foi comparada com duas técnicas de filtragem espacial consideradas clássicas: CAR e CCA, de acordo com cenários que pudessem revelar possíveis vulnerabilidades do método proposto. Esses cenários compreenderam janelas de estimulação de 3, 2 e 1 s, a presença de 4, 6 e 8 frequências de estímulos, bem como a alteração do espaçamento entre os estímulos, correspondendo ao afastamento máximo e mínimo possíveis, de acordo com a base de dados empregada.

No primeiro momento, o MVDR mostrou-se superior ao CCA e CAR, principalmente para janelas de 3 e 2 s, tanto para cenários com 4, 6 e 8 estímulos, quanto para os de afastamentos máximo e mínimo. Em contrapartida, para janelas de 1 s, foi possível perceber uma queda drástica de desempenho do MVDR, apresentando resultados inferiores às demais técnicas. Esse cenário mostrou ser um entrave para o emprego do MVDR em sistemas BCI-SSVEP. Entretanto, a partir disso, os parâmetros do filtro espaço-temporal foram alterados, onde uma busca pelo número de coeficientes do filtro ( $m$ ) e o número de eletrodos a serem combinados ( $k$ ) foi conduzida. Neste ponto do trabalho, apesar de uma melhora notável no desempenho do MVDR, ainda não foi possível superar o CAR, que até então, fornecia o melhor desempenho global.

Como alternativa ao problema encontrado, surgiu a ideia de uma extensão do MVDR na forma de um banco de filtros. Esse banco de filtros, FBMVDR, passou a atuar individualmente em cada frequência de estímulo e também em suas componentes harmônicas e, por isso, permitiu que ordens menores fossem adotadas, o que tornou-se uma clara vantagem em relação ao MVDR original. Apesar de existir um aumento do

custo computacional associado à essa extensão, houve um aumento maior que cinco pontos percentuais, em termos de desempenho, em relação ao MVDR inicialmente proposto, superando também o CAR em cerca de quatro pontos percentuais.

De posse da melhor configuração obtida para o FBMVDR, foi possível apresentar mais uma extensão para o MVDR. Agora, foi possível ao banco de filtros operar de modo adaptativo, tendo como base duas estratégias de adaptação: o LMS com restrições, proposto por [Frost \(1972\)](#) e o CFLS robusto, por [Resende, Romano e Bellanger \(1996\)](#). Nessa nova extensão, as técnicas adaptativas mostraram-se equivalentemente eficientes, apesar de existir certa superioridade do CFLS robusto, principalmente em termos de velocidade de convergência e ajuste de parâmetros.

Como etapa de teste final, em um cenário extra, avaliamos o desempenho do FBMVDR em comparação com outro banco de filtros, o FBCCA, considerado parte do estado da arte em sistemas BCI-SSVEP. Mais uma vez, o FBMVDR superou a técnica em questão, demonstrando ser uma técnica capaz de gerar contribuições relevantes para os sistemas BCI que a empregam.

Por fim, dado todo o levantamento realizado sobre a capacidade do filtro MVDR em sistemas BCI, acreditamos que ainda restam questões a serem investigadas. A primeira delas seria utilizar informações de fase do sinal de EEG, a fim de se obter o desempenho do MVDR, seja na forma de banco de filtros, ou de forma adaptativa. A segunda seria a avaliação do método proposto em bases de dados registradas em ambientes não-laboratoriais. Desta forma, acreditamos que estaremos próximo de gerar mais contribuições, de forma que sistemas BCI-SSVEP sejam formas frequentes de comunicação, principalmente no âmbito de tecnologias assistivas e neuroreabilitação.

# Referências

- ABIRI, R. et al. A comprehensive review of eeg-based brain–computer interface paradigms. *Journal of neural engineering*, IOP Publishing, v. 16, n. 1, p. 011001, 2019. Citado 5 vezes nas páginas 25, 26, 27, 28 e 31.
- AMIRI, S.; FAZEL-REZAI, R.; ASADPOUR, V. A review of hybrid brain-computer interface systems. *Advances in Human-Computer Interaction*, Hindawi, v. 2013, 2013. Citado na página 31.
- ANG, K. K. et al. A clinical study of motor imagery-based brain-computer interface for upper limb robotic rehabilitation. In: IEEE. *2009 annual international conference of the IEEE engineering in medicine and biology society*. [S.l.], 2009. p. 5981–5984. Citado na página 28.
- BELLANGER, M. *Adaptive digital filters*. [S.l.]: CRC Press, 2001. Citado 2 vezes nas páginas 68 e 71.
- BENDA, M.; VOLOSYAK, I. Comparison of different visual feedback methods for ssvep-based bcis. *Brain sciences*, Multidisciplinary Digital Publishing Institute, v. 10, n. 4, p. 240, 2020. Citado na página 32.
- BENESTY, J.; CHEN, J.; HUANG, Y. A generalized mvdr spectrum. *IEEE Signal Processing Letters*, IEEE, v. 12, n. 12, p. 827–830, 2005. Citado 2 vezes nas páginas 33 e 41.
- 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*, Elsevier, v. 62, n. 6, p. 462–464, 1985. Citado 2 vezes nas páginas 33 e 34.
- BIN, G. et al. An online multi-channel ssvep-based brain–computer interface using a canonical correlation analysis method. *Journal of neural engineering*, IOP Publishing, v. 6, n. 4, p. 046002, 2009. Citado 2 vezes nas páginas 21 e 35.
- BISHOP, C. M. *Pattern recognition and machine learning*. [S.l.]: springer, 2006. Citado na página 38.
- BISHOP, C. M. et al. *Neural networks for pattern recognition*. [S.l.]: Oxford university press, 1995. Citado 2 vezes nas páginas 36 e 39.
- BRADBERRY, T. J.; GENTILI, R. J.; CONTRERAS-VIDAL, J. L. Fast attainment of computer cursor control with noninvasively acquired brain signals. *Journal of neural engineering*, IOP Publishing, v. 8, n. 3, p. 036010, 2011. Citado na página 28.
- BRYSON, A. E. *Applied optimal control: optimization, estimation and control*. [S.l.]: CRC Press, 1975. Citado 2 vezes nas páginas 45 e 46.
- CAPON, J. High-resolution frequency-wavenumber spectrum analysis. *Proceedings of the IEEE*, IEEE, v. 57, n. 8, p. 1408–1418, 1969. Citado na página 41.

- CARVALHO, S. N. et al. Comparative analysis of strategies for feature extraction and classification in ssvep bcis. *Biomedical Signal Processing and Control*, Elsevier, v. 21, p. 34–42, 2015. Citado 2 vezes nas páginas 36 e 39.
- CHANG, M. H. et al. An amplitude-modulated visual stimulation for reducing eye fatigue in ssvep-based brain–computer interfaces. *Clinical Neurophysiology*, Elsevier, v. 125, n. 7, p. 1380–1391, 2014. Citado na página 31.
- CHEN, X. et al. Filter bank canonical correlation analysis for implementing a high-speed ssvep-based brain–computer interface. *Journal of neural engineering*, IOP Publishing, v. 12, n. 4, p. 046008, 2015. Citado 3 vezes nas páginas 11, 74 e 75.
- CIPRESSO, P. et al. The use of p300-based bcis in amyotrophic lateral sclerosis: from augmentative and alternative communication to cognitive assessment. *Brain and behavior*, Wiley Online Library, v. 2, n. 4, p. 479–498, 2012. Citado 2 vezes nas páginas 11 e 29.
- CONSTANZO, L. S. *BRS physiology*. [S.l.]: Lippincott publishing, 2006. Citado na página 24.
- COYLE, S. et al. On the suitability of near-infrared (nir) systems for next-generation brain–computer interfaces. *Physiological measurement*, IOP Publishing, v. 25, n. 4, p. 815, 2004. Citado na página 26.
- CURRAN, E. et al. Cognitive tasks for driving a brain-computer interfacing system: a pilot study. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 12, n. 1, p. 48–54, 2004. Citado na página 27.
- DAVIES, D. L.; BOULDIN, D. W. A cluster separation measure. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, n. 2, p. 224–227, 1979. Citado na página 38.
- DEVIJVER, P. A.; KITTLER, J. *Pattern recognition: A statistical approach*. [S.l.]: Prentice hall, 1982. Citado na página 38.
- DONCHIN, E.; SMITH, D. B. The contingent negative variation and the late positive wave of the average evoked potential. *Electroencephalography and clinical Neurophysiology*, Elsevier, v. 29, n. 2, p. 201–203, 1970. Citado na página 28.
- FROST, O. L. An algorithm for linearly constrained adaptive array processing. *Proceedings of the IEEE*, IEEE, v. 60, n. 8, p. 926–935, 1972. Citado 7 vezes nas páginas 11, 66, 67, 68, 71, 73 e 80.
- GARCIA-MOLINA, G.; ZHU, D. Optimal spatial filtering for the steady state visual evoked potential: Bci application. In: IEEE. *2011 5th International IEEE/EMBS Conference on Neural Engineering*. [S.l.], 2011. p. 156–160. Citado 2 vezes nas páginas 26 e 33.
- GIBBONS, J. D.; CHAKRABORTI, S. *Nonparametric statistical inference*. [S.l.]: CRC press, 2020. Citado na página 62.
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain–computer interfaces: A gentle introduction. In: *Brain-computer interfaces*. [S.l.]: Springer, 2009. p. 1–27. Citado 2 vezes nas páginas 21 e 32.

- GU, Y.; DREMSTRUP, K.; FARINA, D. Single-trial discrimination of type and speed of wrist movements from eeg recordings. *Clinical Neurophysiology*, Elsevier, v. 120, n. 8, p. 1596–1600, 2009. Citado na página 28.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of machine learning research*, v. 3, n. Mar, p. 1157–1182, 2003. Citado na página 38.
- GUYON, I. et al. *Feature extraction: foundations and applications*. [S.l.]: Springer, 2008. v. 207. Citado na página 38.
- GUYTON, A. C. *Tratado de fisiologia médica*. [S.l.]: Elsevier Brasil, 2006. Citado 2 vezes nas páginas 24 e 25.
- HARDING, G. F.; JEAUVONS, P. M. *Photosensitive epilepsy*. [S.l.]: Cambridge University Press, 1994. Citado na página 31.
- HAYKIN, S. *Neural Networks and Learning Machines, 3/E*. [S.l.]: Pearson Education India, 2010. Citado na página 39.
- HERRMANN, 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*, Springer, v. 137, n. 3-4, p. 346–353, 2001. Citado na página 29.
- HOCHBERG, L. R. et al. Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, Nature Publishing Group, v. 442, n. 7099, p. 164–171, 2006. Citado na página 28.
- HOTELLING, H. Relations between two sets of variates. In: *Breakthroughs in statistics*. [S.l.]: Springer, 1992. p. 162–190. Citado na página 34.
- JASPER, H. H. The ten-twenty electrode system of the international federation. *Electroencephalogr. Clin. Neurophysiol.*, v. 10, p. 370–375, 1958. Citado na página 26.
- KAY, S. *Intuitive probability and random processes using MATLAB®*. [S.l.]: Springer Science & Business Media, 2006. Citado na página 37.
- KIM, S.-P. et al. Neural control of computer cursor velocity by decoding motor cortical spiking activity in humans with tetraplegia. *Journal of neural engineering*, IOP Publishing, v. 5, n. 4, p. 455, 2008. Citado na página 28.
- KLETT, J. *Applied multivariate analysis*. [S.l.]: New York: McGraw-Hill, 1972. Citado na página 35.
- KOHAVI, R.; JOHN, G. H. et al. Wrappers for feature subset selection. *Artificial intelligence*, Elsevier Science, v. 97, n. 1-2, p. 273–324, 1997. Citado na página 38.
- KURUVILLA, A.; FLINK, R. Intraoperative electrocorticography in epilepsy surgery: useful or not? *Seizure*, Elsevier, v. 12, n. 8, p. 577–584, 2003. Citado na página 25.
- LEITE, S. N. d. C. Contribuições ao desenvolvimento de interfaces cérebro-computador baseadas em potenciais evocados visualmente em regime estacionário. [sn], 2016. Citado 14 vezes nas páginas 22, 25, 26, 27, 28, 33, 34, 37, 38, 41, 50, 54, 55 e 79.

- LIN, F.-C. et al. Snr analysis of high-frequency steady-state visual evoked potentials from the foveal and extrafoveal regions of human retina. In: IEEE. *2012 Annual international conference of the IEEE engineering in medicine and biology society*. [S.l.], 2012. p. 1810–1814. Citado na página 31.
- LUTH, T. et al. Low level control in a semi-autonomous rehabilitation robotic system via a brain-computer interface. In: IEEE. *2007 IEEE 10th International Conference on Rehabilitation Robotics*. [S.l.], 2007. p. 721–728. Citado na página 31.
- MARKAND, O. Artifacts. In: *Annual meeting of American Academy of Neurology*. [S.l.: s.n.], 1996. v. 1, p. 363–396. Citado na página 33.
- MCFARLAND, D. J. et al. Spatial filter selection for eeg-based communication. *Electroencephalography and clinical Neurophysiology*, Elsevier, v. 103, n. 3, p. 386–394, 1997. Citado 2 vezes nas páginas 21 e 34.
- MELLINGER, J. et al. An meg-based brain-computer interface (bci). *Neuroimage*, Elsevier, v. 36, n. 3, p. 581–593, 2007. Citado na página 26.
- MUGLER, E. M. et al. Design and implementation of a p300-based brain-computer interface for controlling an internet browser. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 18, n. 6, p. 599–609, 2010. Citado na página 28.
- MÜLLER, S. M. T.; BASTOS, T. F.; FILHO, M. S. Proposal of a ssvep-bci to command a robotic wheelchair. *Journal of Control, Automation and Electrical Systems*, Springer, v. 24, n. 1-2, p. 97–105, 2013. Citado na página 21.
- NEUPER, C. et al. Imagery of motor actions: Differential effects of kinesthetic and visual-motor mode of imagery in single-trial eeg. *Cognitive brain research*, Elsevier, v. 25, n. 3, p. 668–677, 2005. Citado na página 27.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. *sensors*, Molecular Diversity Preservation International, v. 12, n. 2, p. 1211–1279, 2012. Citado 2 vezes nas páginas 25 e 28.
- OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-time signal processing*. 3rd ed. ed. Upper Saddle River: Pearson, 2010. ISBN 9780131988422. Citado 3 vezes nas páginas 33, 36 e 37.
- ORTNER, R. et al. An ssvep bci to control a hand orthosis for persons with tetraplegia. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 19, n. 1, p. 1–5, 2010. Citado na página 21.
- PFURTSCHELLER, G. et al. The hybrid bci. *Frontiers in neuroscience*, Frontiers, v. 4, p. 3, 2010. Citado na página 31.
- PFURTSCHELLER, G.; NEUPER, C. Motor imagery activates primary sensorimotor area in humans. *Neuroscience letters*, Elsevier, v. 239, n. 2-3, p. 65–68, 1997. Citado na página 27.
- RAMADAN, R. A.; VASILAKOS, A. V. Brain computer interface: control signals review. *Neurocomputing*, Elsevier, v. 223, p. 26–44, 2017. Citado 2 vezes nas páginas 25 e 26.

- RESENDE, L. S.; ROMANO, J. M. T.; BELLANGER, M. G. A fast least-squares algorithm for linearly constrained adaptive filtering. *IEEE Transactions on Signal Processing*, IEEE, v. 44, n. 5, p. 1168–1174, 1996. Citado 7 vezes nas páginas 11, 66, 68, 69, 70, 73 e 80.
- ROBBINS, H.; MONRO, S. A stochastic approximation method. *The annals of mathematical statistics*, JSTOR, p. 400–407, 1951. Citado na página 68.
- SILVERTHORN, D. U. et al. *Human physiology: an integrated approach*. [S.l.]: Pearson/Benjamin Cummings San Francisco, 2010. Citado na página 24.
- SONG, J. et al. Characterizing relationships of dti, fmri, and motor recovery in stroke rehabilitation utilizing brain-computer interface technology. *Frontiers in neuroengineering*, Frontiers, v. 7, p. 31, 2014. Citado na página 26.
- SPÜLER, M. et al. Spatial filtering based on canonical correlation analysis for classification of evoked or event-related potentials in eeg data. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 22, n. 6, p. 1097–1103, 2013. Citado na página 35.
- THEODORIDIS, S.; KOUTROUMBAS, K. et al. Pattern recognition. *IEEE Transactions on Neural Networks*, IEEE INSTITUTE OF ELECTRICAL AND ELECTRONICS, v. 19, n. 2, p. 376, 2008. Citado na página 40.
- VOLOSYAK, I. et al. Bci demographics ii: How many (and what kinds of) people can use a high-frequency ssvep bci? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 19, n. 3, p. 232–239, 2011. Citado na página 31.
- WALDERT, S. et al. A review on directional information in neural signals for brain-machine interfaces. *Journal of Physiology-Paris*, Elsevier, v. 103, n. 3-5, p. 244–254, 2009. Citado na página 25.
- WANG, W. et al. Decoding and cortical source localization for intended movement direction with meg. *Journal of neurophysiology*, American Physiological Society Bethesda, MD, v. 104, n. 5, p. 2451–2461, 2010. Citado na página 26.
- WANG, Y. et al. A benchmark dataset for ssvep-based brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, PP, p. 1–1, 11 2016. Citado 7 vezes nas páginas 46, 47, 53, 56, 74, 75 e 76.
- WEISKOPF, N. et al. Principles of a brain-computer interface (bci) based on real-time functional magnetic resonance imaging (fmri). *IEEE transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 966–970, 2004. Citado na página 26.
- WOLPAW, J. R. et al. Brain-computer interfaces for communication and control. *Clinical neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002. Citado na página 21.
- WOLPAW, J. R. et al. An eeg-based brain-computer interface for cursor control. *Electroencephalography and clinical neurophysiology*, Elsevier, v. 78, n. 3, p. 252–259, 1991. Citado na página 27.
- YUAN, H.; HE, B. Brain-computer interfaces using sensorimotor rhythms: current state and future perspectives. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 61, n. 5, p. 1425–1435, 2014. Citado na página 28.

ZHU, D. et al. A survey of stimulation methods used in ssvep-based bcis. *Computational intelligence and neuroscience*, Hindawi, v. 2010, 2010. Citado na página [30](#).