Extração de características para a classificação de imagética motora em interfaces cérebro-computador

Yule Vaz

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Yule Vaz

Extração de características para a classificação de imagética motora em interfaces cérebro-computador

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre em Ciências – Ciências de Computação e Matemática Computacional. *EXEMPLAR DE DEFESA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. Rodrigo Fernandes de Mello

USP – São Carlos
Abril de 2016

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados fornecidos pelo(a) autor(a)

VVaz, Y.e Vaz, Yule
Extração de Características para a Classificação de
Imagética Motora em Interfaces Cérebro-Computador /
Yule Vaz; orientador Rodrigo Fernandes de Mello. --
São Carlos, 2016.
91 p.

Dissertação (Mestrado - Programa de Pós-Graduação
em Ciências de Computação e Matemática
Computacional) -- Instituto de Ciências Matemáticas
e de Computação, Universidade de São Paulo, 2016.

1. Interfaces Cérebro-Computador. 2. Imagética
Motora. 3. Extração de Características. 4.
Aprendizado de Máquina. I. de Mello, Rodrigo
Fernandes, orient. II. Título.

Yule Vaz

Feature extraction for motor imagery classification in brain-computer interfaces

Master dissertation submitted to the Instituto de
Ciências Matemáticas e de Computação – ICMC-
USP, in partial fulfillment of the requirements for the
degree of the Master Program in Computer Science
and Computational Mathematics. *EXAMINATION
BOARD PRESENTATION COPY*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. Rodrigo Fernandes de Mello

USP – São Carlos
April 2016

Resumo

As Interfaces Cérebro-Computador (do inglês Brain-Computer Interfaces – BCI) são sistemas que visam permitir a interação entre usuários e máquinas por meio do monitoramento das atividades cerebrais. Sistemas de BCI são considerados como uma alternativa para que pessoas com perda severa ou total do controle motor, tais como as que sofrem de Esclerose Lateral Amiotrófica, possam contar com algum controle sobre o ambiente externo. Para mapear intenções individuais em operações de máquina, os sistemas de BCI empregam um conjunto de etapas que envolvem a captura e pré-processamento dos sinais cerebrais, a extração e seleção de suas características mais relevantes e a classificação das intenções. O projeto e a implementação de sistemas de BCI viáveis ainda são questões em aberto devido aos grandes desafios encontrados em cada uma de suas etapas. Esta lacuna motivou este trabalho de mestrado o qual apresenta uma avaliação dos principais extratores de características utilizados para classificar ensaios de imagética motora, cujos dados foram obtidos por meio de eletroencefalografia (EEG) e apresentam influências de artefatos, mais precisamente daqueles produzidos por interferências provenientes de atividades oculares (monitoradas por eletrooculografia – EOG). Foram considerados sinais coletados pela BCI Competition IV-2b, os quais contêm informações sobre três canais de EEG e três outros de EOG. Como primeira etapa, foi realizado o pré-processamento desses canais utilizando a técnica de Análise de Componentes Independentes (ICA) em conjunto com um limiar de correlação para a remoção de componentes associados a artefatos oculares. Posteriormente, foram avaliadas diferentes abordagens para a extração de características, a mencionar: i) Árvore Diádica de Bandas de Frequências (ADBF); ii) Padrões Espaciais Comuns (CSP); iii) Padrões Espectro-Espaciais Comuns (CSSP); iv) Padrões Esparsos Espectro-Espaciais Comuns (CSSSP); v) CSP com banco de filtros (FBCSP); vi) CSSP com banco de filtros (FBCSSP); e, finalmente, vii) CSSSP com banco de filtros (FBCSSSP). Contudo, como essas técnicas podem produzir espaços de exemplos com alta dimensionalidade, considerou-se, também, a técnica de Seleção de Características baseada em Informação Mútua (MIFS) para escolher os atributos mais relevantes para o conjunto de dados adotado na etapa de classificação. Finalmente, as Máquinas de Vetores de Suporte (SVM) foram utilizadas para a classificação das intenções de usuários. Experimentos permitem concluir que os resultados do CSSSP e FBCSSSP são equiparáveis àqueles produzidos pelo estado da arte, considerando o teste de significância estatística de Wilcoxon bilateral com confiança de 0,95. Apesar disso o CSSSP tem sido negligenciado pela área devido ao fato de sua parametrização ser considerada complexa, algo que foi automatizado neste trabalho. Essa automatização reduziu custos computacionais envolvidos na adaptação das abordagens para indivíduos específicos. Ademais, conclui-se que os extratores de características FBCSP, CSSP, CSSSP, FBCSSP e FBCSSSP não necessitam da etapa de remoção de artefatos oculares, pois efetuam filtragens por meio de modelos autoregressivos.

Palavras-chave. Interface Cérebro-Computador; Imagética Motora; Extração de Características; Aprendizado de Máquina.

Abstract

Brain-Computer Interfaces (BCI) employ brain imaging to enable human-machine interaction without physical control. BCIs are an alternative so that people suffering from severe or complete loss of motor control, like those with Amyotrophic Lateral Sclerosis (ALS), may have some interaction with the external environment. To transform individual intentions onto machine operations, BCIs rely on a series of steps that include brain signal acquisition and preprocessing, feature extraction, selection and classification. A viable BCI implementation is still an open question due to the great challenges involved in each one of these steps. This gap motivated this work, which presents an evaluation of the main feature extractors used to classify Motor Imagery trials, whose data were obtained through Electroencephalography (EEG) influenced by ocular activity, monitored by Electrooculography (EOG). In this sense, signals acquired by BCI Competition IV-2b, were considered. As first step the preprocessing was performed through Independent Component Analysis (ICA) together with a correlation threshold to identify components associated with ocular artifacts. Afterwards, different feature extraction approaches were evaluated: i) Frequency Subband Dyadic Tree; ii) Common Spatial Patterns (CSP); iii) Common Spectral-Spatial Patterns (CSSP); iv) Common Sparse Spectral-Spatial Patterns (CSSSP); v) Filter Bank Common Spatial Patterns (FBCSP); vi) Filter Bank Common Spectral-Spatial Patterns (FBCSSP); and, finally, vii) Filter Bank Sparse Spectral-Spatial Patterns (FBCSSSP). These techniques tend to produce high-dimensional spaces, so a Mutual Information-based Feature Selection was considered to select signal attributes. Finally, Support Vector Machines were trained to tackle the Motor Imagery classification. Experimental results allow to conclude that CSSSP and FBCSSSP are statistically equivalent the state of the art, when two-sided Wilcoxon test with 0,95 confidence is considered. Nevertheless, CSSSP has been neglected by this area due to its complex parametrization, which is addressed in this work using an automatic approach. This automation reduced computational costs involved in adapting the BCI system to specific individuals. In addition, the FBCSP, CSSP, CSSSP, FBCSSP and FBCSSSP confirm to be robust to artifacts as they implicitly filter the signals through autoregressive models.

Keywords. Brain-Computer Interfaces; Motor Imagery; Feature Extraction; Machine Learning.

Sumário

Resumo	i
Abstract	iv
Lista de Figuras	viii
Lista de Tabelas	ix
Lista de Abreviaturas	xi
1 Introdução	1
2 BCI Competition	11
2.1 Considerações Iniciais	11
2.2 BCI Competition IV-2b	15
2.3 Trabalhos Relacionados	18
2.4 Considerações Finais	22
3 Classificação de Imagética Motora	25
3.1 Considerações Iniciais	25
3.2 Remoção de Artefatos	26
3.2.1 Análise de Componentes Independentes	29
3.2.2 Remoção Automática de Artefatos	31
3.3 Extração de Características	32
3.3.1 Análise Espectral	34
3.3.2 Filtros Espaciais e Espaço-temporais	38
3.4 Seleção de Características	41

3.5	Classificação	42
3.5.1	Máquina de Vetores de Suporte	44
3.6	Considerações Finais	46
4	Experimentos	51
4.1	Considerações Iniciais	51
4.2	Árvore Diádica de Bandas de Frequências	54
4.3	Padrões Espaciais	55
4.4	Padrões Espaciais com Banco de Filtros	58
4.5	Remoção de Artefatos	62
4.6	Busca Automática por Parâmetros	65
4.7	Considerações Finais	74
5	Conclusões	79
	Referências	82

Lista de Figuras

1.1	Manifestação do potencial P300.	4
1.2	Etapas de uma Interface Cérebro-Computador.	6
1.3	Posicionamento de eletrodos segundo o padrão 10-20.	7
1.4	Esquema de um experimento baseado em ensaios.	8
2.1	Esquema experimental da <i>BCI Competition IV-2b</i>	16
2.2	Disposição dos eletrodos de Eletrooculografia.	17
3.1	Componentes extraídos pela Análise de Componentes Independentes.	30
3.2	Etapas envolvidas na abordagem utilizada neste trabalho e técnicas conside- radas para aquisição e pré-processamento.	32
3.3	Janela de tempo utilizada na extração de características.	33
3.4	Resultado da convolução entre dois sinais.	36
3.5	Árvore Diádica de Bandas de Frequências	37
3.6	Etapas de classificação de imagética motora envolvendo ADBF e seleção de características.	38
3.7	Etapas de classificação de Imagética Motora envolvendo banco de filtros, filtros espaciais e seleção de características.	39
3.8	Etapas de classificação de Imagética Motora envolvendo banco de filtros, CSP, CSSP ou CSSSP e seleção de características.	41
3.9	Ilustração do problema de maximização de margem.	44
3.10	Etapas e métodos envolvidos na abordagem utilizada neste trabalho.	49
4.1	Gráficos dos índices <i>kappa</i> normalizados vs. limiar de correlação para remo- ção de artefatos.	64

4.2	Fluxo de dados para a abordagem de estimação de coordenadas de atraso dos sinais de controle.	66
4.3	Fluxo de dados para a abordagem de estimação do número de dimensões embutidas dos sinais de controle.	68
4.4	Gráfico de convergência de ganho de informação e índice <i>kappa</i>	69
4.5	Gráfico de avaliação de desempenho das abordagens que utilizam filtros espaciais em relação às janelas de tempo.	70
4.6	Gráficos para comparação entre os filtros espaciais.	71
4.7	Gráficos de comparação entre os filtros espaciais com e sem banco de filtros.	72
4.8	Gráficos para comparação das abordagens de parametrização considerando o CSSP e CSSSP.	73
4.9	Gráficos para comparação das abordagens de parametrização considerando o FBCSSP e FBCSSSP.	74
4.10	Gráficos para comparação dos resultados do CSSP e CSSSP utilizando parametrização automática e os de Alvarez-Meza <i>et al.</i> (2015).	76
4.11	Gráficos para comparação dos resultados do FBCSSP e FBCSSSP utilizando parametrização automática e os de Alvarez-Meza <i>et al.</i> (2015).	77

Lista de Tabelas

2.1	Índices <i>kappa</i> de Cohen apresentados pelos trabalhos relacionados.	23
4.1	Índices <i>kappa</i> de Cohen no uso da técnica ADBF em relação ao limiar de correlação utilizado para remoção de artefatos.	55
4.2	Índices <i>kappa</i> de Cohen no uso da técnica CSP em relação ao limiar de correlação utilizado para remoção de artefatos.	56
4.3	Índices <i>kappa</i> de Cohen no uso da técnica CSSP em relação ao limiar de correlação utilizado para remoção de artefatos.	57
4.4	Índices <i>kappa</i> de Cohen no uso da técnica CSSSP em relação ao limiar de correlação utilizado para remoção de artefatos.	58
4.5	Índices <i>kappa</i> de Cohen no uso da técnica FBCSP em relação ao limiar de correlação utilizado para remoção de artefatos.	60
4.6	Índices <i>kappa</i> de Cohen no uso da técnica FBCSSP em relação ao limiar de correlação utilizado para remoção de artefatos.	61
4.7	Índices <i>kappa</i> de Cohen no uso da técnica FBCSSSP em relação ao limiar de correlação utilizado para remoção de artefatos.	62
4.8	Tabela com os índices <i>kappa</i> dos métodos considerados estado da arte e os das abordagens consideradas neste trabalho.	63
4.9	Tabela com os índices <i>kappa</i> dos métodos utilizando a configuração automática de parâmetros e com resultados do estado da arte.	75

Lista de Abreviaturas

ADBF	Árvore Diádica de Sub-bandas de Frequências
ALS	Esclerose Lateral Amiotrófica (do inglês <i>Amyotrophic Lateral Sclerosis</i>)
AMI	Auto-informação Mútua (do inglês <i>Auto-mutual Information</i>)
ANN	Rede Neural Artificial (do inglês <i>Artificial Neural Network</i>)
AR	Modelo Autorregressivo (do inglês <i>Autoregressive Models</i>)
AS	Atenção Seletiva
BCI	Interface Cérebro-Computador (do inglês <i>Brain-Computer Interface</i>)
BSS	Separação Cega de Fontes (do inglês <i>Blind Source Separation</i>)
CLIS	Síndrome de Aprisionamento Total (do inglês <i>Complete Locked-In Syndrome</i>)
CSP	Padrões Espaciais Comuns (do inglês <i>Common Spatial Patterns</i>)
CSSD	Decomposição Subespacial de Espaços Comuns (do inglês <i>Common Spatial Subspace Decomposition</i>)
CSSP	Padrões Espectro-Espaciais Comuns (do inglês <i>Common Spectral Spatial Patterns</i>)
CSSSP	Padrões Espectro-Espaciais Comuns Esparsos (do inglês <i>Common Sparse Spectral Spatial Patterns</i>)
ECG	Eletrocardiografia
ECOG	Eletrocorticografia
EEG	Eletroencefalografia
EMD	Decomposição Empírica de Modos (do inglês <i>Empirical Mode Decomposition</i>)
EMG	Eletromiografia
EOG	Eletrooculografia

ERD	Dessincronização Relacionada a Evento (do inglês <i>Event-Related Desynchronization</i>)
ERS	Sincronização Relacionada a Evento (do inglês <i>Event-Related Synchronization</i>)
FBCSP	Padrões Espaciais Comuns com Banco de Filtros (do inglês <i>Filter Bank Common Spatial Patterns</i>)
FBCSSP	Padrões Espectro-Espaciais Comuns com Banco de Filtros (do inglês <i>Filter Bank Common Spectral Spatial Patterns</i>)
FBCSSSP	Padrões Espectro-Espaciais Comuns Esparsos com Banco de Filtros (do inglês <i>Filter Bank Common Sparse Spectral Spatial Patterns</i>)
FIR	Resposta ao Impulso Finita (do inglês <i>Finite Impulse Response</i>)
FNN	Falsos Vizinhos mais Próximos (do inglês <i>False Nearest Neighbors</i>)
HCRF	Campos Aleatórios Condicionais Escondidos (do inglês <i>Hidden Conditional Random Fields</i>)
ICA	Análise de Componentes Independentes (do inglês <i>Independent Component Analysis</i>)
IC	Componentes Independentes (do inglês <i>Independent Components</i>)
IHC	Interface Humano-Computador
IMF	Funções Modais Intrínsecas (do inglês <i>Intrinsic Mode Function</i>)
IM	Imagética Motora
KDA	Análise de Discriminante com Kernel (do inglês <i>Kernel Discriminant Analysis</i>)
LCR	Combinação e Regressão Linear (do inglês <i>Linear Combination and Regression</i>)
LDA	Análise de Discriminante Linear (do inglês <i>Linear Discriminant Analysis</i>)
LF	Filtragem Linear (do inglês <i>Linear Filtering</i>)
MEG	Magnetoencefalografia
MIFS	Seleção de Características baseada em Informação Mútua (do inglês <i>Mutual Information-based Feature Selection</i>)
MRA	Análise Multirresolução (do inglês <i>Multiresolution Analysis</i>)
MRP	Potenciais Relacionados a Movimento (do inglês <i>Movement Related Potentials</i>)

NIRS	Espectroscopia de Infravermelho Próximo (do inglês <i>Near-Infrared Spectroscopy</i>)
PCA	Análise de Componentes Principais (do inglês <i>Principal Component Analysis</i>)
PMRE	Princípio de Minimização do Risco Empírico
RQNN	Redes Neurais Artificiais Recorrentes Quânticas (do inglês <i>Recurrent Quantum Neural Networks</i>)
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
STFT	Transformada de Fourier de Curta Duração (do inglês <i>Short-Time Fourier Transform</i>)
SVM	Máquinas de Vetores de Suporte (do inglês <i>Support Vector Machines</i>)
TAE	Teoria do Aprendizado Estatístico
TSVM	Máquinas de Vetores de Suporte Gêmeas (do inglês <i>Twin Support Vector Machines</i>)
WPD	Decomposição de Pacotes Wavelet (do inglês <i>Wavelet Packet Decomposition</i>)
WT	Transformada Wavelet (do inglês <i>Wavelet Transform</i>)
fMRI	Imageamento por Ressonância Magnética Funcional (do inglês <i>Functional Magnetic Resonance Imaging</i>)
kNN	k-Vizinhos mais Próximos (do inglês <i>k-Nearest Neighbors</i>)

Introdução

A ergonomia visa estudar a interação entre seres humanos e elementos de um determinado sistema com o intuito de projetá-lo com base nas necessidades, habilidades e limitações humanas (Jastrzebowski, 1857). Neste contexto, a área de Interação Humano-Computador (IHC) visa projetar dispositivos digitais de acordo com características físicas, cognitivas e motivacionais de diferentes indivíduos (Moray, 2005). Desenvolvimentos mais recentes da área de IHC têm buscado projetar dispositivos eletrônicos capazes de responder à solicitação de indivíduos com pouco ou nenhum controle motor, considerando, principalmente, a reabilitação de pessoas que sofreram danos no sistema sensório-motor. Uma das tecnologias estudadas para auxiliar na reabilitação desses indivíduos são as Interfaces Cérebro-Computador (do inglês *Brain-Computer Interface* – BCI).

BCI tem suas raízes nos primeiros estudos realizados pelo cientista alemão Hans Berger, em 1929, quando ele monitorou pela primeira vez a atividade elétrica cerebral a partir do sensoramento do escalpo humano (Graumann *et al.*, 2010). Posteriormente, em 1964, Dr. Grey Walter apresentou a primeira Interface Cérebro-Computador, cujo objetivo era o de mapear a atividade cerebral humana produzida ao se pressionar o botão de um projetor, avançando as páginas de uma apresentação. Dr. Walter percebeu que o avanço ocorria antes que o paciente pressionasse o botão, ou seja, assim que a operação era mentalmente planejada, conseqüentemente não havia a necessidade da movimentação dos membros do indivíduo (Graumann *et al.*, 2010).

Esses primeiros resultados fomentaram o interesse sobre BCI devido à possibilidade de construção de sistemas que pudessem auxiliar pessoas com perda total do controle motor, tal como as que sofrem de Esclerose Lateral Amiotrófica (do inglês *Amyotrophic Lateral Sclerosis* – ALS), a interagir com o ambiente externo de maneira mais autônoma. Nesse contexto, um sistema de BCI seria utilizado para a movimentação de uma cadeira de rodas, por exemplo.

Contudo, diversos desafios ainda são encontrados no que se refere ao projeto de BCIs, dentre eles a coleta de sinais produzidos pelo cérebro e sua correta interpretação para efetuar uma ação sobre o meio externo. Não obstante, há ainda a necessidade da rápida manipulação dos dados coletados para que o indivíduo tenha interações que simulem as naturalmente realizadas por meio de seu corpo. Essa interação natural do ser humano sobre o ambiente ao seu redor é dada por meio da comunicação entre o Sistema Nervoso Central (SNC) e músculos, a partir do Sistema Nervoso Periférico (SNP). Uma saída eferente determina o controle dos órgãos com movimentação voluntária, ou seja, quando há comunicação direcionada do SNC para o SNP. Já uma saída aferente é vinculada à percepção humana, i.e., envolve a comunicação do sistema sensorial humano para o SNC. Danos nesses canais podem causar problemas sensório-motores, produzindo perda parcial ou total do controle motor (Purves *et al.*, 2001).

As Interfaces Cérebro-Computador devem, portanto, por meio do monitoramento da atividade cerebral, criar uma alternativa ao canal de comunicação entre o Sistema Nervoso Central e músculos tal qual o canal eferente natural. Tecnologias como as baseadas em foco ocular (*eye-gaze based*) (Morimoto & Mimica, 2005) e em Eletromiografia (Chowdhury *et al.*, 2013) têm sido utilizadas para a melhoria da qualidade de vida de indivíduos com perda parcial do controle motor, contudo elas não abrangem pessoas que perderam totalmente tal controle, i.e., com Síndrome de Encarceramento Total (do inglês *Complete Locked-In Syndrom* – CLIS), pois a primeira exige que o usuário possua habilidade para movimentar os olhos, enquanto a segunda, para movimentar algum músculo específico. Neste contexto, mesmo que os sistemas de BCI atuais não contem com eficiência similar à oferecida pelos meios físicos de interação, nem mesmo com a confiabilidade necessária para a identificação das intenções humanas, eles podem prover maior autonomia a pessoas com CLIS (Grimann *et al.*, 2010).

A tradução da atividade cerebral de um indivíduo em uma operação de máquina re-

quer conhecimento sobre sinais que caracterizam intenções, os quais são chamados de sinais de controle (Nicolas-Alonso & Gomez-Gil, 2012). Para o monitoramento desses sinais, duas estratégias podem ser adotadas: a de Atenção Seletiva (AS) e a de Imagética Motora (IM). A primeira requer um estímulo exógeno, sendo esse auditivo, visual ou somatosensorial, para que, a partir das informações produzidas por uma saída aferente, possa ser identificada a intenção do usuário (Grazimann *et al.*, 2010). Por exemplo, o potencial P300 corresponde ao aumento na amplitude de um sinal cerebral produzido em torno de 300 milissegundos após um estímulo exógeno, o qual é caracterizado por ser imprevisto pelo indivíduo em questão. Assim, a partir de um conjunto de símbolos apresentados ao usuário, uma modificação repentina em um deles (por exemplo um realce cromático), irá produzir um potencial P300 em seu sinal cerebral tal como ilustrado na Figura 1.1.

Estratégias de Atenção Seletiva são utilizadas no projeto de BCIs síncronas, as quais necessitam esperar pelo término de um estímulo exógeno para proceder com a coleta e interpretação dos sinais de controle. Esses sistemas são caracterizados por não produzirem respostas em tempo real, exigindo, contudo, pouco ou nenhum treinamento por parte do usuário, visto que os sinais de controle abordados por essa estratégia são intrínsecos à atividade autônoma cerebral e se comportam de maneira menos subjetiva (Grazimann *et al.*, 2010; Nicolas-Alonso & Gomez-Gil, 2012). Além disso, a AS possibilita a execução de tarefas complexas, como a comunicação, dado que o usuário irá selecionar uma operação arbitrária (e.g., digitar um determinado caractere, frente a um conjunto de outros símbolos).

Em contrapartida, a estratégia de Imagética Motora não requer estímulo externo, i.e., quaisquer atividades cerebrais produzidas por intenções motoras de um indivíduo devem ser compreendidas e traduzidas em operações de máquina. Pelo simples fato do indivíduo controlar todas as operações e não haver a necessidade de estímulo exógeno, estratégias de IM suportam controle assíncrono, no entanto a identificação dos sinais de controle é muito mais complexa uma vez que varia entre indivíduos tanto em termos de intensidade quanto frequências (Doppelmayr *et al.*, 1998; da Silva & Pfurtscheller, 1999; Neuper & Pfurtscheller, 2001; del R Millan *et al.*, 2002). Portanto, é essencial que haja uma etapa de treinamento do usuário para que opere esse tipo de BCI, além disso o método de tradução dos sinais deve-se adaptar ao comportamento da atividade cerebral do sujeito (Wolpaw *et al.*, 2002; Raza *et al.*, 2015).

Tipicamente, estratégias de IM utilizam sinais cerebrais denominados ritmos sensório-

Figura 1.1: Manifestação do potencial P300 causada por um estímulo exógeno. Note que, o usuário está atento à letra “A”, se essa for realçada, haverá a produção do sinal de controle. (Adaptado de Graimann *et al.* (2010)).

motores (Neuper *et al.*, 2009), os quais são caracterizados pelo aumento ou redução de amplitude em um intervalo de frequência específico. Ao aumento, dá-se o nome de Sincronização Relacionada a Evento (do inglês *Event-related Synchronization* – ERS) enquanto, à redução, Dessincronização Relacionada a Evento (do inglês *Event-related Desynchronization* – ERD). Essas atividades se propagam de diferentes maneiras na região do córtex cerebral de acordo com a intenção de execução de cada movimento (esse aspecto intencional motivou a denominação de IM). Complementarmente, há três intervalos de frequência que sofrem tais alterações dada a intenção de um movimento, os quais dão origem a três ondas cerebrais específicas denominadas μ (8 – 12 Hz), β (12 – 30 Hz) e γ (> 30 Hz) (Graimann *et al.*, 2010).

Uma vez monitorada a atividade cerebral, uma BCI baseada na estratégia de Imagética Motora deve extrair os ritmos sensório-motores. Essa etapa é tipicamente realizada pela filtragem dos sinais cerebrais nas faixas de frequência μ e β , os quais sofrem redução em sua amplitude quando ocorre a intenção ou a execução de uma tarefa motora. Cabe ressaltar que essa variação é ainda mais evidente em regiões contralaterais ao movimento e é denominada de Dessincronização Relacionada a Eventos (ERD). O oposto, ou seja, o aumento da atividade rítmica sensório-motora, ocorre após o movimento ser executado ou

imaginado, i.e., no período de relaxamento (Wolpaw *et al.*, 2002), e é chamada de Sincronização Relacionada a Eventos (ERS). São essas alterações de amplitude em determinadas frequências dos sinais cerebrais que permitem a construção de sistemas baseados em IM.

Cabe ainda ressaltar que movimentos voluntários propagam a ERD, através do córtex motor, sobre as maiores frequências da onda μ e as menores da onda β . Esses sinais de controle iniciam-se proeminentemente sobre regiões contralaterais ao movimento e se tornam bilateralmente simétricos no decorrer da atividade motora (Pfurtscheller & da Silva, 1999). Já a faixa inferior das ondas μ , mais precisamente no intervalo de 8 Hz a 10 Hz, apresenta um comportamento simétrico durante a preparação do movimento, logo pesquisadores a consideram como um preparo motor geral (Pfurtscheller & Neuper, 2010). Em contrapartida, as altas frequências das ondas μ contêm informações relativas à lateralidade dos movimentos (Pfurtscheller & Neuper, 2010), consequentemente, sua correta manipulação deve permitir a identificação da intenção e do lado do corpo a ser movimentado (direito ou esquerdo).

Diversos trabalhos têm considerado os aspectos de Dessincronização Relacionada a Eventos (ERD) e Sincronização Relacionada a Eventos (ERS) a fim de construir sistemas de BCI de alta acurácia na classificação de Imagética Motora. Dentre eles, deve-se destacar Wolpaw *et al.* (2002) e McFarland & Wolpaw (2011), que discutem pontos fundamentais sobre os sinais de controle e como eles podem ser empregados na construção de BCIs, e Ince *et al.* (2007); Ang *et al.* (2012a) e Zhou & Wan (2012), que apresentam diversos métodos para a extração de características de ERD e ERS específicas de um indivíduo.

Esses estudos refletem o crescente interesse pelo projeto e construção de BCIs, os quais motivaram a organização de diversas conferências e competições para a identificação de Imagética Motora, tais como a *BCI Competition*, fomentada pelo projeto *Berlin Brain-Computer Interface* (of Education & Research, 2016), mantido pelo Ministério Federal da Educação e Pesquisa Alemão. Essa competição visa a melhoria na aquisição, extração de características e classificação de sinais de controle.

Com o advento dessas competições, tornou-se possível projetar novas abordagens de BCI e compará-las aos sistemas existentes. Nesse contexto, este trabalho de mestrado avalia diferentes técnicas de extração de características de sinais cerebrais e as utiliza em uma etapa de classificação posterior, a fim de identificar intenções de movimento. Assim, torna-se possível comparar a eficiência de cada um desses extratores que visam produzir carac-

Figura 1.2: Ilustração das etapas envolvidas para a classificação de sinais de controle em Interfaces Cérebro-Computador.

terísticas discriminativas para a Imagética Motora. Posteriormente, essas características são utilizadas como entrada para a técnica de Máquinas de Vetores de Suporte (do inglês *Support Vector Machines* – SVM), sobre a qual há a expectativa de classificar intenções de movimento. Na Figura 1.2 são ilustradas todas as etapas envolvidas neste trabalho bem como as técnicas tipicamente estudadas pela literatura ¹. Cabe ressaltar que essas são as mesmas etapas consideradas por demais trabalhos que visam o projeto de BCIs baseados em Imagética Motora (Bashashati *et al.*, 2007; Ang *et al.*, 2012a). Essas etapas são: aquisição dos sinais, pré-processamento, extração de características, seleção de características e classificação de intenções.

Na etapa de aquisição dos sinais cerebrais, diversas técnicas de imageamento podem ser empregadas para, tais como: Magnetoencefalografia (MEG), Imageamento por Ressonância Magnética Funcional (do inglês *Functional Magnetic Resonance Imaging* – fMRI), Espectroscopia de Infravermelho Próximo (do inglês *Near Infrared Spectroscopy* – NIRS), Eletrocorticografia (ECoG) e, finalmente, Eletroencefalografia (EEG). Dentre essas foi considerada a EEG, devido a não necessitar de procedimentos clínicos invasivos, ter menor custo de aquisição e contar com maior volume de dados disponíveis na literatura. Por outro lado, essa técnica de imageamento apresenta baixa resolução espacial (cobertura do córtex com eletrodos), o que tende a prejudicar a qualidade dos dados coletados.

A técnica de Eletroencefalografia monitora a atividade neuroelétrica por meio de eletrodos posicionados tipicamente segundo padrões tais como o 10-20, 10-10 e 10-5 (Jurcak *et al.*, 2007). Esses padrões servem para definir a disposição dos eletrodos no escalpo, tal como ilustrado na Figura 1.3. Cada um desses componentes capta a atividade neuroelétrica em uma região com uma grande densidade de neurônios e, portanto, apresenta

¹Os próximos capítulos abordarão essas técnicas.

Figura 1.3: Posicionamento de eletrodos segundo o padrão 10-20 para o monitoramento eletroencefalográfico (Adaptada de Nguyen *et al.* (2013)). Cada círculo rotulado corresponde a um eletrodo. Os rótulos indicam: a letra F corresponde à região frontal do escalpo humano; a letra C está associada à região cortical; a letra T indica a região temporal; a letra P corresponde à região parietal; e, finalmente, a letra O indica a região occipital.

baixa resolução espacial.

Ainda na etapa de aquisição dos sinais cerebrais para Imagética Motora, é necessária a estruturação das sessões experimentais para serem produzidas relações entre os dados e suas respectivas classes. Tipicamente, essas sessões empregam uma coleção de ensaios, tal como ilustrado na Figura 1.4, os quais contam com um período de relaxamento em que o indivíduo não efetua qualquer ação, um período em que uma tarefa é apresentada e que, posteriormente, deve ser imaginada (intenção de movimento) pelo voluntário. Em seguida, há um período aleatório entre dois ensaios para que o voluntário não se adapte ao sistema. Cada ensaio é associado a uma tarefa, possibilitando sua análise e classificação.

Cabe ressaltar que os sinais coletados para cada ensaio apresentam alta sensibilidade a ruídos endógenos e exógenos, o que motiva a etapa de pré-processamento (Figura 1.2). Eventuais ruídos exógenos podem ser causados, por exemplo, pelo próprio equipamento, pois a impedância dos eletrodos interfere na aquisição dos sinais (nesse caso, filtros estreitos são tipicamente utilizados para a eliminação das frequências de 50 ou 60 Hz).

Além disso, há atividades que não estão relacionadas à intenção do usuário, tais como as oculares (via monitoramento por Eletrooculografia – EOG), musculares (via Eletromio-

Figura 1.4: Os ensaios são iniciados com um período de espera. Posteriormente, o indivíduo é avisado que haverá uma tarefa a seguir (período de referência). Logo após, a tarefa é apresentada e executada pelo indivíduo o qual, finalmente, é submetido a um período de repouso de tempo aleatório.

grafia – EMG) e cardíacas (via Eletrocardiografia – ECG), e que produzem interferências endógenas. Esses artefatos são tipicamente tratados a partir do emprego de técnicas tais como Regressão Linear, Análise de Componentes Independentes (do inglês *Independent Component Analysis* – ICA), Modelos Autorregressivos (do inglês *Autoregressive Models* – AR) ou Análise de Componentes Principais (do inglês *Principal Component Analysis* – PCA) (Fattourehchi *et al.*, 2006). Com isso, espera-se que os sinais contenham apenas as informações relevantes para a classificação de movimentos.

A etapa de extração de características em sistemas de BCI visa produzir, a partir dos sinais de controle, informações relevantes para a classificação das intenções de um indivíduo. No caso da Imagética Motora os sinais de controle tipicamente utilizados são relativos à sincronização e dessincronização das ondas μ e β , usualmente, nas faixas de frequência entre $[7, 12]$ Hz e $[12, 30]$ Hz. Cabe ressaltar que estudos como o de Ang *et al.* (2012a) ainda utilizam a faixa entre $[4; 40]$ Hz, também adotada neste trabalho. Assim, é bastante comum, após o pré-processamento, aplicar um filtro passa-bandas para se extrair sinais dentro dessas faixas de frequência. Contudo, as características mais relevantes podem estar em sub-bandas, motivando sua decomposição por meio de Transformadas Wavelet (do inglês *Wavelet Transform* – WT) ou banco de filtros (Ince *et al.*, 2007; Yang *et al.*, 2007; Ting *et al.*, 2008; Ang *et al.*, 2012a).

Além disso, dadas as características topográficas (o termo “topográfica” é utilizado como referência ao modelo de organização dos sensores de EEG sobre o escalpo humano) da ERS e ERD, análises e filtros espaciais tais como o Padrão Espacial Comum (do inglês *Common Spatial Patterns* – CSP) (Koles, 1991) e Decomposição Espacial de Sub-espacos

Comum (do inglês *Common Spatial Subspace Decomposition* – CSSD) (Wang *et al.*, 1999). Ainda, outras técnicas apresentadas pela literatura, tais como Padrão Espectro-Espacial Comum (do inglês *Common Spectral-Spatial Patterns* – CSSP) (Lemm *et al.*, 2005), e Padrão Esperso Espectro-Espacial Comum (do inglês *Common Sparse Spectral-Spatial Patterns* – CSSP) (Dornhege *et al.*, 2006), são empregadas para abordar, também, dependências temporais. Complementarmente, os Modelos Autorregressivos (do inglês *Autoregressive Models* – AR) e Redes Neurais Preditivas (RNP) (Burke *et al.*, 2005; Coyle *et al.*, 2005; Coyle, 2009; Hsu, 2013) e suas variações também são utilizadas para a representação de características temporais da ERS e ERD.

No entanto, métodos de extração de características podem produzir espaços de alta dimensionalidade (grande número de atributos) o que pode prejudicar a classificação das intenções de movimento, motivando a inclusão de uma etapa de seleção de características (Figura 1.2). Técnicas como a Análise de Discriminante Linear (do inglês *Linear Discriminant Analysis* – LDA) (Mclachlan, 2004), Análise de Discriminante com Kernel (do inglês *Kernel Discriminant Analysis* – KDA) (Mika *et al.*, 1999), Análise de Componentes Principais (PCA) e Seleção de Características baseada em Informação Mútua (do inglês *Mutual Information-based Feature Selection* – MIFS) (Ang *et al.*, 2012b) são tipicamente empregadas para a redução desses espaços, sendo a última a considerada neste trabalho.

A última etapa, ilustrada na Figura 1.2, é responsável pela classificação do espaço de características. Nessa fase, os algoritmos tradicionais de aprendizado supervisionado de máquina, tais como Redes Neurais Artificiais (do inglês *Artificial Neural Networks* – ANN), k-Vizinhos mais Próximos (do inglês *k-Nearest Neighbors* – kNN) e Máquinas de Vetores de Suporte são comumente utilizados a fim de estimar a distribuição de probabilidades conjunta que melhor define as relações entre atributos de entrada e classes. No contexto deste trabalho, são utilizadas as Máquinas de Vetores de Suporte devido à garantia mais justa de aprendizado, segundo o Princípio de Minimização do Risco Empírico, conforme provado pela Teoria do Aprendizado Estatístico (TAE) (von Luxburg & Scholkopf, 2009).

Em resumo, com base nas etapas apresentadas, este trabalho de mestrado focou na construção e avaliação de um sistema de BCI baseado em Imagética Motora utilizando: i) EEG como técnica de coleta de sinais cerebrais; ii) a técnica de Análise de Componentes Independentes (ICA) para analisar componentes estatisticamente independentes e separá-los a fim de melhor identificar e remover sinais de Eletrooculograma; iii) diversas téc-

nicas de extração de características foram avaliadas, entre elas: Árvore Diádica de Bandas Frequência (ADBF), CSP, CSSP, CSSSP, *Filter Bank* CSP (FBCSP), *Filter Bank* CSSP (FBCSSP) e *Filter Bank* CSSSP (FBCSSSP); iv) seleção de características utilizando a técnica de Seleção de Características baseada em Informação Mútua (do inglês *Mutual Information-based Feature Selection* – MIFS) (Ang *et al.*, 2012a,b); e, finalmente, v) classificação de intenções de movimento, utilizando Máquinas de Vetores de Suporte. Os sinais de EEG utilizados neste trabalho foram disponibilizados pela *BCI Competition* IV-2b (Tangermann *et al.*, 2012), os quais contam com ensaios referentes a dois tipos de Imagética Motora: movimento da mão esquerda e da mão direita. Os resultados obtidos foram comparados aos reportados junto à *BCI Competition*, além de outros produzidos por estudos mais recentes.

Este trabalho está organizado nos seguintes capítulos: no Capítulo 2 são apresentadas a descrição da *BCI Competition*, a especificação da base IV-2b e seus trabalhos relacionados; no Capítulo 3 são introduzidos os métodos e as abordagens utilizadas neste trabalho; no Capítulo 4 são apresentados os resultados e discussões acerca dos experimentos e, finalmente, o Capítulo 5 contém as conclusões e direções futuras para este trabalho.

BCI Competition

2.1 Considerações Iniciais

Apesar do avanço tecnológico na área de imageamento cerebral e o maior acesso a equipamentos de Eletroencefalografia (EEG), a coleta de dados ainda requer uma infraestrutura laboratorial específica. A publicação de dados adquiridos a partir do monitoramento de atividades cerebrais auxilia não só na divulgação de trabalhos relacionados como também no desenvolvimento de pesquisas em sistemas de BCI, já que, nesse sentido, algumas delas podem ser feitas sem o acesso à infraestrutura laboratorial. Além disso, a disponibilização dos ensaios permite a comparação quantitativa de diferentes métodos de análise, processamento, tomada de decisão e a reprodutibilidade experimental. Neste contexto, este trabalho de mestrado utiliza os dados coletados e disponibilizados pela *BCI Competition*.

A *BCI Competition* é uma competição criada a partir do projeto *Berlin Brain-Computer Interface* (Tangermann *et al.*, 2012) que visa a publicação de sessões de BCIs e a avaliação de diferentes técnicas aplicadas a diferentes problemas dentro da área de Interfaces Cérebro-Computador. Essa competição foi realizada por quatro anos e conta com diversas bases destinadas a diferentes problemas como o de Imagética Motora, identificação de caracteres por sinais P300, autorregulação de ondas μ e β , autorregulação de Potenciais Corticais Lentos, classificação de Eletroencefalografia contínua sem estrutura de ensaios,

classificação de sinais de EEG afetados por movimento ocular, entre outros. Os dados coletados a partir dessas sessões têm sido amplamente utilizados na literatura para abordar diferentes desafios associados à área de BCI.

Como os dados da primeira edição não estão disponíveis no *site* da *BCI Competition* (of Education & Interface, 2014), são apresentados, primeiramente, os problemas da segunda edição que contam com: 1-a/1-b) Autorregulação de Potenciais Corticais Lentos; 2-a) Autorregulação de ondas μ e/ou β -central; 2-b) Paradigma P300-speller; 3) Imagética Motora com duas classes; e 4) *Self-Paced* 1s.

A terceira edição da *BCI Competition* disponibilizou dados para abordar desafios relacionados à: 1) Transferência de sessão para sessão de Imagética Motora monitorados por ECoG; 2) Paradigma P300-speller; 3a) Imagética Motora de quatro classes; 3b) Imagética Motora de duas classes com *feedback online*; 4a) Imagética Motora de três classes com conjunto de treinamento pequeno; 4b) Imagética Motora de três classes sem dicas visuais para os ensaios de teste; 4c) Imagética Motora de três classes para o problema da invariância ao tempo; e, finalmente, 5) Mentalização de três classes (Imagética Motora da mão esquerda/direita e mentalização de palavras).

Finalmente, a quarta edição da *BCI Competition* tratou dos seguintes desafios: 1) Imagética Motora de três classes sem dicas visuais para os ensaios de teste; 2a) Imagética Motora de quatro classes; 2b) Imagética Motora de duas classes; 3) Direção do movimento de mão com imageamento por MEG; e 4) Flexão de dedos a partir do imageamento por ECoG.

Dentre tais desafios, o *BCI Competition* II-3, *BCI Competition* III-3a, 3b, 4a, 4b, 4c e *BCI Competition* IV-1, 2a, 2b referem-se a Imagética Motora. Por estarem associados ao objetivo deste trabalho, os conjuntos de dados associados a esses desafios são explicados a seguir:

- *BCI Competition* II-3: visa a classificação da Imagética Motora das mãos esquerda/direita. Demanda que o indivíduo controle, pela Imagética Motora, uma barra disposta na tela de um computador, a qual é utilizada para *feedback*. A sessão experimental foi efetuada em um dia, apenas sobre um indivíduo e em sete etapas. Cada etapa apresenta 40 ensaios e um intervalo de alguns minutos entre eles. Por ter sido aplicado sobre apenas um indivíduo, esse problema não contempla a variação da classifica-

ção sobre diferentes pessoas;

- *BCI Competition III-3a*: este conjunto foi obtido por meio de imageamento por EEG de 64 canais para o problema de classificação de quatro diferentes tipos de movimentos (mão esquerda/direita, pés e língua), sobre três indivíduos e com dicas visuais;
- *BCI Competition III-3b*: foram utilizados os canais C3 e C4 (visualizar posicionamento destes eletrodos na Figura 1.3) para monitorar a atividade cerebral de três indivíduos sob um cenário com *feedback* para a classificação da Imagética Motora da mão esquerda/direita. Seus ensaios apresentam longa duração, pois visam a avaliação de classificadores não-estacionários que se adaptam a mudanças do comportamento cerebral do indivíduo no decorrer do experimento;
- *BCI Competition III-4a*: foram utilizados 118 canais de EEG nas sessões experimentais efetuadas visando a classificação de três Imagética Motora (movimentos da mão esquerda/direita e pé direito). Cinco voluntários participaram desse experimento e a quantidade de ensaios efetuados sobre cada indivíduo para o treinamento do classificador varia de 28 a 224;
- *BCI Competition III-4b*: utilizou-se 118 canais de EEG para o imageamento da atividade cerebral a fim de monitorar três tipos de Imagética Motora (idem ao item anterior). As tarefas a serem executadas nos ensaios de validação desse experimento apresentam períodos aleatórios entre 1,5 e 8 segundos e são dadas por um estímulo acústico. Este conjunto foi criado para a análise da eficiência na classificação em tempo real de sinais cerebrais;
- *BCI Competition III-4c*: utilizou os mesmos ensaios de treinamento do item anterior, contudo os de validação são efetuados algumas horas depois para que sejam avaliadas as variações de resposta dos classificadores em relação às mudanças nas características dos sinais cerebrais após esse período de espera;
- *BCI Competition IV-1*: foram utilizados 59 canais de EEG para o imageamento da atividade cerebral com o intuito de classificar dois tipos de Imagética Motora selecionados entre as classes mão direita/esquerda e pés. Nos ensaios de validação, os períodos em que os indivíduos efetuam a tarefa dada por um estímulo acústico são

aleatórios e variam entre 1, 5 e 8 segundos para se analisar a eficiência na classificação em tempo real;

- *BCI Competition IV-2a*: utilizou-se 20 canais de EEG nas sessões experimentais efetuadas com o objetivo de se classificar quatro tipos de Imagética Motora (mão direita/esquerda, ambos os pés e língua). Nove voluntários se submeteram ao experimento e não houve *feedback*. Além disso, foram utilizados três eletrodos de Eletrooculograma (EOG) para monitorar a atividade ocular e os cinco minutos iniciais das sessões são destinados a estimar a influência do EOG;
- *BCI Competition IV-2b*: utilizou-se três canais de EEG (C3, Cz e C4) nas sessões experimentais efetuadas sobre nove voluntários, visando a classificação dos Imagética Motora da mão esquerda e direita. A mesma configuração do item anterior foi utilizada para a estimação da influência de EOG. Foram feitas três sessões de treinamento sendo que, na terceira, foi apresentado *feedback* para o usuário. Há, também, duas sessões de validação em que houve *feedback*.

Dentro do caráter deste trabalho de mestrado, o conjunto de dados disponibilizado pela *BCI Competition IV-2b* apresenta desafios relevantes e que possibilitam a análise dos sinais extraídos a partir de um equipamento de EEG com apenas três eletrodos (equipamento simples e, portanto, de menor custo monetário). Esse conjunto ainda conta com três eletrodos para coletar dados de Eletrooculografia associados ao ato de piscar do indivíduo. Logo, esses dados correspondem a uma situação próxima de um ambiente real de coleta, pois todos os ruídos estão presentes. Deve-se ressaltar que esse conjunto de dados conta com uma quantidade considerável de voluntários, o que permitiu a melhor condução deste trabalho.

A seguir são descritas, com maiores detalhes, as sessões experimentais de monitoramento cerebral por EEG disponibilizadas pela *BCI Competition IV-2b*, as quais são consideradas neste trabalho. Posteriormente, são apresentados os resultados dos trabalhos reportados pela mesma competição no tratamento do desafio IV-2b. A fim de complementar os trabalhos reportados pela *BCI Competition*, resultados mais recentes também são discutidos.

2.2 BCI Competition IV-2b

O conjunto de dados disponibilizado pela *BCI Competition IV-2b* permite o estudo do problema de Imagética Motora birrotulada (mão direita e esquerda), com uma estrutura de ensaio e com presença de artefatos de Eletrooculografia nos sinais de EEG. Cabe ressaltar que, nesse conjunto de dados, as influências da atividade ocular são monitoradas por meio de eletrodos posicionados na face do indivíduo (dois laterais a cada olho e um frontal entre os olhos – Figura 2.2).

A *BCI Competition IV-2b* contém sessões de mapeamento cerebral efetuadas por EEG sobre nove voluntários destros e com visão saudável. O monitoramento da atividade cerebral dessas pessoas foi realizado da seguinte maneira: os indivíduos ficaram sentados em uma cadeira e unicamente observaram um monitor posicionado a aproximadamente um metro de distância. Para cada indivíduo, foram efetuadas cinco sessões, 1T, 2T, 3T, 4E e 5E, em que 1T e 2T correspondem às sessões de treinamento sem *feedback*, 3T à de treinamento com *feedback* e, finalmente, 4T e 5T às de teste com *feedback*.

O início de cada sessão consistiu no mapeamento da atividade ocular dos voluntários que eram instruídos a ficar dois minutos com os olhos abertos, observando uma cruz de fixação na tela, um minuto com os olhos fechados e um minuto movimentando-os. O mapeamento dos artefatos de EOG foi dividido em quatro ensaios de 15 segundos, com cinco segundos de intervalo entre cada bloco.

As sessões 1T e 2T contam, cada uma, com 120 ensaios referentes a dois tipos de Imagética Motora: o da mão esquerda (classe 1) e o da direita (classe 2). Antes da primeira sessão, cada indivíduo executou e imaginou diferentes movimentos das mãos e selecionou aquele que acreditou ter sido o mais natural. Cada ensaio iniciou com a apresentação da cruz de fixação na tela e um estímulo acústico de aviso, emitido na frequência de 1 kHz durante 70 ms. Três segundos após o início do ensaio, foi apresentada na tela, durante 1,25 segundo, a tarefa a ser executada, a qual, por meio de uma seta, indicava para qual mão deveria-se imaginar o movimento. Neste contexto, o voluntário contava com 4 segundos para completar a tarefa. Após o término do ensaio, houve um período de repouso médio de 1,5 segundo adicionado a um intervalo aleatório de até um segundo, a fim de evitar a adaptação do indivíduo.

As sessões 3T, 4E e 5E, consistiram de ensaios que consideravam a intensidade com que

o indivíduo imaginava o movimento determinado pelo sistema. Ao início de cada ensaio, um *smiley* cinza era apresentado no centro da tela para indicar nenhuma atividade. Após dois segundos do início do ensaio, um curto sinal auditivo era emitido. A tarefa era dada no intervalo de 3 até 7,5 segundos. O usuário era instruído a mover o *smiley* para a esquerda ou para a direita dependendo da Imagética Motora. Se a execução da IM estivesse correta, a cor da imagem tornava-se verde, caso contrário, vermelha. No instante de 7,5 segundos, a tela do monitor tornava-se vazia e o voluntário esperava um período aleatório de um a dois segundos para o início de um novo ensaio. O esquema dos ensaios com e sem *feedback* são ilustrados na Figura 2.1.

a)

b)

Figura 2.1: Esquema de ensaios utilizado pela *BCI Competition IV-2b*: a) ilustra a estrutura de um ensaio efetuado nas sessões sem *feedback*, e b) nas sessões com *feedback*. Ilustração adaptada de (of Education & Interface, 2014).

Cabe ressaltar que essas sessões empregaram um equipamento de EEG com três eletrodos (C3, Cz e C4 – para maiores detalhes veja a Figura 1.3) e com uma taxa de aquisição de 250 Hz. O intervalo de amplitude dos sinais são, respectivamente, de $\pm 100 \mu V$ e $\pm 50 \mu V$

para as sessões sem e com *feedback*. O eletrodo na posição Fz (Figura 1.3) foi utilizado para aterrar o capacete de EEG. O sinal foi filtrado na faixa de frequência de $[0, 5; 100]$ Hz e aplicou-se um filtro fino sobre a frequência de 50 Hz para eliminar a influência da atividade elétrica do equipamento (frequência da corrente elétrica).

Ademais, foram utilizados três eletrodos adicionais na face do indivíduo, como mostra a Figura 2.2, para monitorar artefatos provenientes da movimentação ocular, i.e., resultantes do Eletrooculograma. As mesmas configurações de filtros foram utilizadas sobre os sinais de EOG, os quais variam no intervalo de amplitude de ± 1 mV.

Figura 2.2: Disposição dos eletrodos que efetuaram a Eletrooculografia. Imagem adaptada a partir da descrição da base de dados 2b, encontrada na competição *BCI Competition IV* (of Education & Interface, 2014).

Para permitir a avaliação entre as técnicas empregadas sobre esse conjunto de sinais cerebrais e submetidas na competição, considerou-se o índice *kappa* de Cohen (Cohen, 1960) que apresenta o quão distante o classificador está, em termos de acurácia, de uma decisão aleatoriamente tomada. Assim, dados exemplos, $x_c \in \mathcal{X}_c$, seus respectivos rótulos $y_c \in \mathcal{Y}_c$, Ω uma função de decisão aleatória e α uma função de acurácia para um classificador f_n , a medida κ é definida por:

$$\kappa = \frac{\alpha(f_n(\mathcal{X}_c, \mathcal{Y}_c)) - \alpha(\Omega(\mathcal{X}_c, \mathcal{Y}_c))}{1 - \alpha(\Omega(\mathcal{X}_c, \mathcal{Y}_c))}. \quad (2.1)$$

O índice *kappa* varia no intervalo $[-1; 1]$, a qual indica que o classificador f_n está em total desacordo com os rótulos caso $\kappa = -1$, e que está em total acordo caso $\kappa = 1$, ou que há uma decisão aleatória caso $\kappa = 0$. Por exemplo, dado um problema birrotulado com exemplos x_1 e x_2 e rótulos y_1 e y_2 de forma que as classes estejam distribuídas uniformemente, decisões tomadas aleatoriamente produzem uma acurácia de 0,5. Assim, se $\alpha(f_n(\mathcal{X}_c, \mathcal{Y}_c)) = 0,5$, $\kappa = 0$ e, portanto, o classificador f_n apresenta decisão aleatória. Se $\alpha(f_n(\mathcal{X}_c, \mathcal{Y}_c)) = 1$, então f_n atribui as classes $\mathcal{Y}_c$ corretamente a todos os exemplos.

2.3 Trabalhos Relacionados

Os seis métodos mais eficientes reportados pela *BCI Competition IV-2b* em 2008 foram os de Yang Ping, Jaime F. D. Saa, Shaun Lodder, Damien Coyle, Huang Gan e Zheng Yang Chin e seus índices *kappa* médios para todos os indivíduos foram de 0,25, 0,37, 0,43, 0,46, 0,58 e 0,60, respectivamente (Tangemann *et al.*, 2012).

O trabalho de Yang Ping conta com a remoção de artefatos de EOG por meio de regressão linear, cálculo de potência de 75 bandas de frequência dentro do intervalo [6; 33] Hz para cada canal (i.e., sinal cerebral de um eletrodo), produzindo os descritores de características e selecionando-as por meio de eliminação recursiva, reduzindo o espaço de 225 atributos para seis. Na etapa de classificação, os autores utilizam a Análise de Discriminante Linear Bayesiano (Hamsici & Martinez, 2008). Contudo, segundo Fatourehchi *et al.* (2006), o sinal de EOG subtraído do sinal original é contaminado pelos sinais de EEG e, portanto, informações relevantes podem ser eliminadas nesse processo. Além disso, Yang Ping não faz uso de quaisquer filtros espaciais tais como o CSP ou análises temporais que podem aprimorar os resultados por levarem em consideração a dependência temporal dos sinais e melhorarem a projeção dos dados no espaço de características.

O trabalho de Jaime F. D. Saa também faz uso de regressão linear para a remoção de artefatos de EOG e os sinais são tratados com um filtro passa-altas a partir de 4 Hz. O método utiliza características espectrais das bandas μ e β aplicadas a uma Rede Neural Artificial (do inglês *Artificial Neural Network* – ANN). Pouca informação foi apresentada sobre as características espectrais extraídas e não há uma referência sobre algum trabalho publicado que explique o método com maiores detalhes.

Shaun Lodder utiliza a Decomposição de Pacotes Wavelet (do inglês *Wavelet Packet Decomposition* – WPD) a fim de extrair características espectrais dos sinais de Imagética Motora que foram classificados pela Análise de Discriminante Linear (do inglês *Linear Discriminant Analysis* – LDA). Essa técnica também é reportada na literatura em trabalhos como Ting *et al.* (2008) e Yang *et al.* (2007). Contudo, Lodder não aplica a seleção da melhor base formada pela WPD, nem a redução da dimensionalidade e nem mesmo o pré-processamento dos sinais. Não obstante, essa técnica poderia ser aprimorada com a remoção de artefatos de EOG, já que esses são produzidos na mesma faixa de frequência das ondas μ e β , e também com o uso de informação temporal e de filtragem espacial.

Já a abordagem proposta por Damien Coyle pré-processa os sinais por meio de uma ANN preditiva gerando modelos temporais para cada canal e classe (Coyle *et al.*, 2005, 2008; Coyle, 2009). A partir dos sinais de cada eletrodo, descobre-se as coordenadas de atraso e a dimensão embutida (Takens, 1981), a fim de alimentar uma rede neural fuzzy auto-organizada associada a cada rótulo. Sobre os sinais dos eletrodos são aplicados: i) um filtro espectral, selecionado para cada indivíduo a partir de validação cruzada; e ii) a técnica de Padrões Espaciais Comuns (do inglês *Common Spatial Patterns* – CSP) para a filtragem espacial dos sinais. Note que há a possibilidade do aprimoramento dessa técnica a partir da seleção de múltiplas sub-bandas ao invés de apenas uma tal como observado em (Yang *et al.*, 2007) e (Ince *et al.*, 2007). Além disso, é possível utilizar melhores métodos para a escolha das faixas de frequência, tal como o critério de Fisher (Fisher, 1936; McLachlan, 2004) ou a seleção de características por meio de Informação Mútua, para não exigir uma busca extensiva tal como a empregada.

O segundo colocado da competição, Huang Gan, utilizou a técnica de Decomposição Subespacial de Espaços Comuns (*Common Spatial Subspace Decomposition* – CSSD) sobre os sinais de EEG após a aplicação de um banco de filtros e seleção da janela de tempo que produz o melhor desempenho de classificação. A CSSD é uma variação da técnica CSP que visa não só descobrir o espaço que, simultaneamente, maximiza a variação dos dados relacionados a uma classe minimizando a de outra, bem como eliminar sinais que não são produzidos pela intenção do indivíduo (Wang *et al.*, 1999, 2004). Contudo, CSSD assume que tais sinais se diferem um dos outros por sua covariância, enquanto que a Análise de Componentes Independentes é formalizada sobre uma consideração mais robusta, a de que esses sinais são estatisticamente independentes.

A técnica vencedora (*Filter Bank Common Spatial Patterns* – FBCSP), proposta por Zheng Yang Chin, remove os artefatos de EOG por meio de um modelo autorregressivo e utiliza um banco de filtros para pré-processar os sinais cerebrais. A partir disso, o CSP é aplicado sobre cada uma das sub-bandas produzidas e a dimensionalidade reduzida por meio do método de *Mutual Information-based Rough Set reduction* (Ang *et al.*, 2012a), o qual visa encontrar dimensões mais significativas a partir da informação mútua entre os exemplos e os rótulos. Contudo, a dependência temporal dos sinais não é considerada nessa técnica. Por outro lado, uma das técnicas que leva em consideração esse fator é o Padrão Espectro-Espacial Comum Esperso (do inglês *Common Sparse Spectral Spatial Patterns* – CSSSP), a

qual o autor da abordagem vencedora considera desnecessária, uma vez que a FBCSP já caracteriza as dependências temporais (algo que não fica evidente pela técnica) e, além disso, ele afirma que CSSSP apresenta sensibilidade aos parâmetros temporais, dificultando a escolha de uma boa configuração inicial. Contudo, o CSSSP pode ser interpretado como um método que realiza uma imersão (Takens, 1981) em espaço de alta dimensionalidade a fim de representar dependências temporais, as quais podem melhorar os resultados de separação entre as duas classes consideradas no problema proposto no *BCI Competition IV-2b*.

Além desses trabalhos reportados junto à *BCI Competition*, há outros mais recentes que reportam resultados relevantes para comparação com este trabalho de mestrado. Gandhi *et al.* (2015) utilizam a técnica de Redes Neurais Artificiais Recorrentes Quânticas (do inglês *Recurrent Quantum Neural Networks* – RQNN) que emprega uma função de ativação baseada na função de onda, determinada pela Equação de Schrödinger. Assim, a partir da perspectiva clássica de Redes Neurais Artificiais, a Equação de Schrödinger é utilizada como uma função de transferência neuronal estocástica aplicada a um conjunto de sinapses que, nesse trabalho, são adaptadas pela regra de aprendizado Hebbiana baseada em distância radial. Os autores extraem características dos sinais cerebrais por meio das métricas de Hjorth (Hjorth, 1970), as quais estimam as potências, larguras de banda e médias de frequências dos sinais. Os melhores índices *kappa* médios obtidos pelos autores foram de 0,64 para o conjunto de treinamento com *feedback*, 0,54 utilizando o primeiro conjunto de validação e 0,51 para o segundo. De acordo os autores, essas redes neurais têm como fundamento a bioplausibilidade discutida por Hameroff (1998).

Em Raza *et al.* (2015), os autores utilizam uma abordagem adaptativa que aplica o CSP sobre as ondas μ e β . Em seguida, a técnica de k-Vizinhos mais Próximos (do inglês *k-Nearest Neighbors* – kNN) é utilizada para produzir um classificador. Na etapa de classificação, a técnica de Análise de Componentes Principais (do inglês *Principal Components Analysis* – PCA) é utilizada para detectar alterações no comportamento dos sinais de EEG. Essa detecção é efetuada comparando-se a média móvel exponencial dos dados antigos com a dos novos. Caso exista alteração significativa, essa nova instância é incluída na base de conhecimento que, por sua vez, é reconfigurada. Esse cenário adaptativo considera que a relação entre exemplos antigos e novos é linear o que pode não se aplicar ao conjunto de dados. Os autores também desconsideram a etapa de pré-processamento para a re-

moção de artefatos de EOG. Cabe ressaltar que a técnica poderia ser aprimorada com maior resolução na análise espectral e com a inclusão de informações temporais na extração de características. O trabalho, apesar de não superar o estado da arte, apresenta índice *kappa* igual a 0,42.

Em Soman & Jayadeva (2015), os autores abordam a seleção de sub-bandas de frequência por meio de uma medida de classificabilidade que considera ϵ -vizinhanças dos dados para a avaliação de separabilidade, analogamente a medidas de entropia. A partir da intuição de que podem ser obtidos melhores resultados por meio do emprego de mais que um hiperplano (dois, mais precisamente), os quais podem não ser paralelos, os autores consideraram as Máquinas de Vetores de Suporte Gêmeas (do inglês *Twin Support Vectors Machines* – TSVM) para a classificação dos dados da *BCI Competition IV-2b*. O método é iniciado pela aplicação do CSP sobre cada sub-banda extraída dentro do intervalo de frequências [4; 40] Hz e, posteriormente, há a seleção das características produzidas pelo CSP de forma que é considerada apenas a sub-banda de maior classificabilidade. Logo após, aplica-se a TSVM para treinamento e teste do classificador. Esse trabalho alcançou um índice *kappa* de Cohen de 0,52 e apresenta menor tempo de execução se comparada ao FBCSP, contudo os autores consideram apenas uma sub-banda candidata enquanto que um conjunto maior de sub-bandas e padrões espaciais poderiam ser considerados na seleção de características para aprimorar os resultados.

Gaur *et al.* (2015) propõem uma abordagem que emprega a Decomposição Empírica de Modos (do inglês *Empirical Mode Decomposition* – EMD) e a reconstrução dos sinais a partir das Funções de Modos Intrínsecas (do inglês *Intrinsic Mode Functions* – IMF) cujo valor médio de frequência está contido no intervalo [6; 24] Hz. As características empregadas foram as energias das bandas nos intervalos de [6; 12] e [16; 24] Hz e as medidas de Hjorth (Hjorth, 1970). A partir da produção do espaço de características, a técnica LDA foi utilizada para sua classificação. Adotou-se para a configuração experimental a sessão com *feedback* para o treinamento do modelo e a primeira e a segunda sessões de validação para os testes, produzindo, respectivamente, índices *kappa* médios iguais a 0,65 e 0,61. Apesar do bom desempenho da abordagem, a EMD ainda apresenta adversidades para execução em tempo real, pois requer o armazenamento de uma quantidade significativa de dados (em *buffer*). Além disso, o método poderia ser aprimorado, em termos de acurácia, por meio do uso de filtros espaciais e temporais tais como o CSP, CSSP, CSSSP e bem

como por uma análise multirresolução dos sinais reconstruídos pelas IMFs.

Em Saa & Cetin (2012) é utilizada, para a classificação, a técnica de Campos Aleatórios Condicionais Escondidos (do inglês *Hidden Conditional Random Fields* – HCRF) que emprega modelos probabilísticos escondidos (*hidden models*) sem pressupor a independência estatística entre estados. Essa abordagem é iniciada com uma etapa de pré-processamento baseada em regressão linear para a remoção de artefatos EOG. Para se extrair as características, é aplicado o CSP sobre os sinais de EEG de forma a estimar, por meio de modelos AR, a potência de espectro dos componentes resultantes. O trabalho apresenta índice *kappa* médio de 0,66, o qual é superior aos do *BCI Competition IV 2-b*. Contudo, os próprios autores concluem que a HCRF tem alto custo computacional, o que dificulta a construção de um sistema BCI de tempo real.

Os autores de Alvarez-Meza *et al.* (2015) utilizam, primeiramente, o CSP sobre os canais de EEG de forma que, sobre os componentes produzidos, são estimadas bandas de frequência por meio das IMFs extraídas pelo método EMD (Huang *et al.*, 1998) e selecionadas aquelas de interesse para comporem um novo sinal, sobre os quais são calculados três tipos de descritores: a densidade de potência espectral, os coeficientes Wavelet e os coeficientes de Hjorth. Como o conjunto de características tem alta dimensionalidade, os autores aplicam PCA para a redução do espaço de exemplos. Apesar dos resultados serem satisfatórios ($\kappa = 0.446$), há técnicas que produzem melhores resultados.

2.4 Considerações Finais

A área de Interfaces Cérebro-Computador exige uma infra-estrutura laboratorial específica cuja falta de acesso dificulta suas pesquisas. Contudo, projetos como o *BCI Competition* são essenciais para a publicação de ensaios experimentais que possibilitem o desenvolvimento e comparação de métodos de análise e classificação de sinais cerebrais de interesse. Como apresentado na Seção 2.1, há uma vasta gama de sessões de monitoramento cerebral publicadas que abrangem diversos problemas dentro da área de BCI. Apesar disso, apenas o experimento *BCI Competition I-2b* foi efetuado sobre um voluntário com Esclerose Lateral Amiotrófica e, contudo, há a necessidade de se validar os métodos de classificação de Imagética Motora sobre indivíduos que sofrem de perda total do controle motor.

Dentro do contexto de IM, nota-se uma vasta quantidade de modelos matemático-computacionais que buscam superar as acurácias do estado da arte. A revisão da literatura, discutida na seção anterior, buscou atualizar os conhecimentos sobre novas técnicas voltadas para o desafio *BCI Competition IV-2b*. Percebeu-se uma pequena melhora nos resultados dos métodos mais atuais, conforme apresentado na Tabela 2.1, em que se destacam os trabalhos de Gaur *et al.* (2015) e Saa & Cetin (2012). O trabalho realizado no contexto deste mestrado é comparado a esses estudos, conforme detalhado no Capítulo 4. Cabe ressaltar que, são apresentados no rodapé da Tabela 2.1, tanto as referências dos trabalhos considerados quanto a manipulação efetuada sobre os resultados, a qual viabilizou comparações entre as técnicas visto que alguns autores não reportaram os resultados no formato utilizado pela *BCI Competition IV-2b*.

Tabela 2.1: Índices *kappa* de Cohen apresentados pelos trabalhos relacionados.

Autores	Voluntários									Média
	1	2	3	4	5	6	7	8	9	
Yang Ping	0,02	0,09	0,07	0,43	0,25	0,00	0,14	0,76	0,47	0,25
Jaime F. D. Saa	0,20	0,16	0,16	0,73	0,21	0,19	0,39	0,86	0,44	0,37
Shaun Lodder	0,23	0,31	0,07	0,91	0,24	0,42	0,41	0,74	0,53	0,43
Damien Coyle	0,19	0,12	0,12	0,77	0,57	0,49	0,38	0,85	0,61	0,46
Huang Gan	0,42	0,21	0,14	0,94	0,71	0,62	0,61	0,84	0,78	0,58
Zeng Yang Chin	0,40	0,21	0,22	0,95	0,86	0,61	0,56	0,85	0,74	0,60
Gandhi ¹	0,28	0,23	0,67	0,88	0,40	0,52	0,28	0,84	0,66	0,52
Gaur ²	0,26	0,36	0,96	0,76	0,94	0,52	0,46	0,76	0,70	0,62
Alvarez ³	0,44	0,36	0,31	0,60	0,33	0,32	0,51	0,60	0,37	0,45
Raza ⁴	0,5	0,03	0,04	0,93	0,54	0,48	0,40	0,77	0,50	0,47
Soman ⁵	0,49	0,42	0,32	0,90	0,72	0,40	0,47	0,47	0,50	0,53
Saa ⁶	0,60	0,32	0,06	0,97	0,87	0,78	0,63	0,88	0,81	0,66

¹Gandhi *et al.* (2015): Estimou-se a média ponderada (pelo número de ensaios associados às duas classes de Imagética Motora) dos índices *kappa* produzidos pelo teste da técnica sobre cada sessão de validação; ²Gaur *et al.* (2015): estimou-se a acurácia média pelo mesmo cálculo de ¹ a qual foi utilizada para se obter o índice *kappa*; ³Alvarez-Meza *et al.* (2015): Foram consideradas as acurácias médias do trabalho para o cálculo dos índices *kappa*; ⁴Raza *et al.* (2015); ⁵Soman & Jayadeva (2015); ⁶Saa & Cetin (2012).

Classificação de Imagética Motora

3.1 Considerações Iniciais

Diversas técnicas tais como Magnetoencefalografia (MEG), Imageamento por Ressonância Magnética Funcional (do inglês *Functional Magnetic Resonance Imaging* – fMRI), Espectroscopia do Infravermelho Próximo (do inglês *Near Infrared Spectroscopy* – NIRS), Eletrocorticografia (ECOG) e Eletroencefalografia (EEG) são empregadas para o estudo e análise do comportamento cerebral do ser humano (Nicolas-Alonso & Gomez-Gil, 2012).

No que se refere a aspectos práticos, buscam-se por Interfaces Cérebro-Computador (do inglês *Brain-Computer Interfaces* – BCI) que sejam econômica e ergonomicamente viáveis. Isso motiva a pesquisa de BCIs baseadas em monitoramento cerebral por meio de EEG já que provê boa mobilidade, baixo custo e alta resolução temporal se comparada às demais técnicas. Em complemento, sessões de aquisição de sinais cerebrais para BCI que empregam EEG encontram-se disponíveis publicamente e em maior volume. Em contrapartida, o imageamento por EEG é sensível a ruídos oriundos de diversas fontes tais como a rede elétrica e a variação da impedância dos eletrodos.

Além disso, a própria atividade cerebral de um indivíduo produz interferências em seus sinais de controle, os quais são essenciais para discriminar suas intenções. Conforme apresentado no Capítulo 1, atividades cerebrais envolvendo os aspectos ocular, muscular e cardíaco interferem, diretamente, nos sinais de controle, dificultando a identificação das

intenções do indivíduo. Neste contexto, faz-se necessária a remoção de quaisquer artefatos que prejudiquem a fase de extração de características.

A próxima seção apresenta as formas de tratamento de artefatos em sinais de EEG consideradas neste trabalho de mestrado, bem como as técnicas utilizadas para sua remoção. Em seguida, são discutidos os extratores e a abordagem de seleção de características, e, finalmente, o método de classificação de imagética motora utilizado.

3.2 Remoção de Artefatos

O imageamento cerebral por meio de Eletroencefalografia é bastante suscetível a interferências denominadas artefatos, as quais podem ser produzidas tanto por influências geradas pelo próprio equipamento de captura (e.g. erros de medição) quanto por outros sinais produzidos pelo cérebro (e.g. aqueles oriundos de atividades oculares). Em relação ao primeiro tipo, o monitoramento da atividade cerebral efetuado pela técnica de EEG contém ruídos específicos produzidos pela rede elétrica (utilizada para alimentar o equipamento) e pela variação da impedância dos eletrodos (Teplan, 2002). Essas interferências são bem conhecidas e estão localizadas nas frequências de 50 ou 60 Hz, logo é possível removê-las a partir da filtragem dos sinais capturados pelo EEG ou mesmo pela blindagem do equipamento, tal como descrito em Fatourechi *et al.* (2006).

Em relação ao segundo tipo, ou seja, influências cerebrais, há artefatos gerados por fenômenos neurais e por atividades involuntárias do usuário. Para a remoção desses artefatos, pode-se utilizar técnicas capazes de mapeá-los para, em seguida, filtrá-los. Eletrooculografia (EOG), Eletromiografia (EMG) e Eletrocardiografia (ECG) mapeiam, respectivamente, as atividades oculares, musculares e cardíacas do indivíduo, para remover os artefatos produzidos nas atividades eletroencefálicas. Além disso, sinais de controle também podem contaminar os dados de interesse, tais como o P300 realiza sobre Imagética Motora (e.g., o piscar de uma luz pode influenciar na percepção do indivíduo).

Segundo Fatourechi *et al.* (2006), há três abordagens comumente empregadas para evitar as influências sobre os sinais de controle: a prevenção, a rejeição de ensaios e a remoção de artefatos. A prevenção de artefatos consiste em instruir o usuário sobre como evitar ações que produzam resultados indesejados no imageamento cerebral. Por exemplo, pode-se comunicar ao indivíduo que evite piscar ou movimentar alguma parte de

seu corpo. Apesar desse método não demandar qualquer atividade computacional, alguns movimentos oculares e musculares podem ser involuntários sendo, portanto, inevitáveis (e.g. batimentos cardíacos). Ochoa & Polich (2000) e Verleger (1991) mostram que inibir a atividade ocular tende a produzir variações indesejadas na amplitude dos sinais de controle (Fatourehchi *et al.*, 2006).

A segunda abordagem consiste em eliminar ou rejeitar todo o período em que os dados foram contaminados, i.e., uma ou mais janelas de dados são descartadas. Neste caso, todos os ensaios realizados dentro de uma sessão experimental de BCI devem ser avaliados por um especialista a fim de remover aqueles que sofreram influências indesejadas. Esse procedimento é conhecido como rejeição manual de artefatos (Fatourehchi *et al.*, 2006). Sua vantagem é que nenhum esforço computacional é necessário para sua execução, contudo, há a necessidade da ação de um especialista e, inevitavelmente, há a perda de informações relevantes. Ambos fatores são desvantajosos em relação à ergonomia da BCI, pois exigem uma sessão com maior tempo e a intervenção humana especializada sobre o sistema. Em contrapartida, é possível automatizar a rejeição de ensaios, para que seja eliminada a intervenção humana, a partir dos dados adquiridos por Eletrooculografia ou pela própria EEG (Fatourehchi *et al.*, 2006). Nesse caso são removidos os ensaios cuja amplitude dos sinais de EEG ultrapassam um determinado limiar, utilizado para definir as atividades não desejadas.

Apesar da rejeição automática de ensaios não precisar de intervenção de um especialista, há ainda a perda de informação relevante para a classificação dos sinais de controle. Motiva-se, assim, uma terceira abordagem que visa a remoção dos dados que representam os artefatos. Para isso, há técnicas como Filtragem Linear (do inglês *Linear Filtering* – LF), Combinação e Regressão Linear (do inglês *Linear Combination and Regression* – LCR), Separação Cega de Fontes (do inglês *Blind Source Separation* – BSS) e Análise de Componentes Principais (do inglês *Principal Component Analysis* – PCA) que permitem remover artefatos sem a necessidade da eliminação completa de um ensaio.

A Filtragem Linear visa remover os artefatos pela sua frequência característica. As atividades oculares (EOG) e musculares (EMG) consistem geral e respectivamente em sinais de baixas e altas frequências podendo, então, ser removidos por meio de filtros de frequência (Gotman *et al.*, 1973; Zhou & Gotman, 2005). Porém, há sinais de controle que compartilham o mesmo intervalo de frequências dos sinais de EOG e EMG. Por exemplo, os Potenciais Re-

lacionados a Movimentos (do inglês *Movement Related Potential* – MRP) são caracterizados por sua baixa frequência, portanto não é possível usar filtros passa-altas sem que esse sinal de interesse seja eliminado. Dessa maneira, não há como utilizar essa abordagem para eliminar artefatos referentes à atividade ocular sem interferir no MRP. Por outro lado, caso a BCI seja baseada nas ondas μ e β (que têm maiores frequências relativas), é possível empregar um filtro passa-altas eliminando a influência da atividade ocular no sinal, a qual apresenta menor frequência. Porém, para eliminar os sinais referentes à atividade muscular por meio da Filtragem Linear, é necessário um filtro passa-baixas. Adotando-o, os dados das ondas μ e β seriam afetados, causando, portanto, a perda de informações relevantes (de Beer *et al.*, 1995; Fatourehchi *et al.*, 2006).

A técnica de Combinação e Regressão Linear visa, a partir do mapeamento por EOG, produzir dados livres de artefatos por meio da remoção dos sinais de atividade ocular escalados por uma constante k . Assim, um sinal de Eletroencefalograma não contaminado, estimado a partir do eletrodo i , i.e., $EEG_{nc}^i(t)$, é produzido pela Equação 3.1 em que EEG_c^i e $EOG(t)$ são, respectivamente, a série original obtida a partir do eletrodo i e a produzida pela atividade ocular.

$$EEG_{nc}^i(t) = EEG_c^i(t) - k EOG(t) \quad (3.1)$$

Tipicamente, utiliza-se o método de regressão linear por mínimos quadrados para estimar o valor de k (Croft *et al.*, 2005). Contudo, o sinal de EOG, que deve ser subtraído do original, também está contaminado pelos de EEG. Portanto, a remoção dos artefatos de EOG também implica na eliminação de dados significativos para o sistema de BCI. Além disso, há a necessidade de eletrodos de referência para o monitoramento das atividades oculares, aumentando o custo monetário do desenvolvimento da BCI.

A Análise de Componentes Principais visa encontrar uma transformação linear que projete um conjunto de dados multivariado em um espaço cujas bases apresentem a maior variância possível. Estudos como (Lagerlund *et al.*, 1997; Lins *et al.*, 1993a,b) mostram que a PCA é uma forma eficiente para tratar artefatos de EOG. Contudo, é necessário que esses sejam descorrelacionados dos sinais de EEG, o que é uma forte suposição. Lagerlund *et al.* (1997) mostram que, principalmente quando sinais de controle e artefatos têm amplitudes similares, não é possível separar completamente os dados produzidos pelo movimento

ocular. Além disso, a PCA não necessariamente produz os mesmos componentes principais em diferentes ensaios, o que torna complexa a identificação dos artefatos versus sinais de interesse.

Técnicas de Separação Cega de Fonte permitem decompor um sinal original para identificar e remover seus artefatos. A técnica mais comumente utilizada de BSS é a Análise de Componentes Independentes (do inglês *Independent Component Analysis* – ICA) a qual supõe a independência estatística dos componentes como critério suficiente para a separação de sinais provenientes de diferentes fontes. Como é possível observar na Figura 3.1, os artefatos de EOG têm características morfológicas bem definidas e conhecidas na literatura (Vigário, 1997). Em contrapartida, poucos estudos foram realizados sobre o uso de BSS para a remoção de artefatos de EMG (Fatourehchi *et al.*, 2006). Além disso, técnicas de BSS necessitam de inspeção visual sobre os componentes, para identificar essas influências indesejadas.

Após apresentar, brevemente, as técnicas para remoção de artefatos, a seção seguinte detalha a técnica ICA escolhida no contexto deste trabalho para realizar tal tarefa, visto seus bons resultados reportados na literatura (Flexer *et al.*, 2005).

3.2.1 Análise de Componentes Independentes

A Análise de Componentes Independentes é uma técnica motivada pelo problema *Cocktail Party* em que se deseja separar a fala de diversos indivíduos a partir dos sons produzidos por suas conversas. Assim, supõe-se que existe uma combinação linear entre falas (ou fontes) e que essas são estatisticamente independentes. Portanto, seja $\mathbf{X}$ uma matriz com os sinais produzidos e $\mathbf{S}$ suas respectivas fontes, tal que cada linha represente um sinal e cada coluna uma respectiva amostra, a ICA calcula, por meio da Equação 3.2, uma matriz de transformação $\mathbf{P} = \mathbf{A}^{-1}$, em que $\mathbf{A}$ define a combinação linear dos sinais fonte $\mathbf{S}$, i.e., Componentes Independentes (do inglês *Independent Components* – IC).

$$\mathbf{X} = \mathbf{AS} \quad (3.2)$$

A partir do Teorema do Limite Central, supõe-se que a soma de variáveis aleatórias independentes tende, sob certas condições, a uma distribuição Normal (Stone, 2004). Ao assegurar que a transformação linear adquirida a partir de $\mathbf{PX}$ produz sinais com distribui-

Figura 3.1: Componentes extraídos pela Análise de Componentes Independentes a partir de um sinal real de EEG capturado por três eletrodos (C3,Cz e C4 – para maiores detalhes veja a Figura 1.3). Foram também utilizados três eletrodos para a captura do EOG, com o intuito de remover artefatos produzidos pelas atividades oculares. Os componentes independentes 1 e 5 podem ser caracterizados como artefatos. Esse comportamento é bem definido e encontrado na literatura (Vigário, 1997).

ções não-Normais, $\mathbf{P}$ produzirá componentes estatisticamente independentes. Assim, a hipótese de que as variáveis aleatórias de $\mathbf{S}$ devem apresentar distribuições não-Normais é necessária para que haja uma solução para o problema.

Isso ocorre pois, dada a i -ésima linha da matriz $\mathbf{S}$, i.e., o sinal fonte de índice i , como $\hat{s}_i$, se, para n variáveis aleatórias, $\hat{s}_i$ tem distribuição Normal com média zero e covariância $\mathbf{I}$ para $i = 1, 2, \dots, n$, então $\mathbf{AS}$ também terá distribuição Normal com média zero e covariância $\mathbf{AA}^T$. Supondo que $\tilde{\mathbf{A}} = \mathbf{AR}$, em que $\mathbf{R}$ é uma transformação ortogonal, então $\tilde{\mathbf{X}} = \tilde{\mathbf{A}}\mathbf{S}$. Assim, $\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T = \mathbf{ARSS}^T\mathbf{R}^T\mathbf{A}^T = \mathbf{AA}^T$. Portanto, ambos $\mathbf{X}$ e $\tilde{\mathbf{X}}$ apresentam distribuições Normais com média zero e covariância $\mathbf{AA}^T$, logo não é possível saber se foram produzidos por $\mathbf{A}$ ou $\tilde{\mathbf{A}}$.

Visto que é necessário supor que os sinais fonte sejam estatisticamente independentes, a ICA calcula componentes cujas distribuições sejam as mais distantes possíveis de uma Normal. Assim, é necessário calcular $\mathbf{P}$ de forma que alguma medida de não-normalidade das distribuições das variáveis aleatórias, tal como Curtose e Negentropia, seja ótima (Stone, 2004). Tipicamente utiliza-se técnicas de gradiente descendente/ascendente sobre as medidas de não-normalidade para o cálculo de $\mathbf{P}$.

Mesmo que a Análise de Componentes Independentes decomponha um conjunto de misturas de dados em suas possíveis fontes, a identificação dos sinais de EOG contidos nos ICs necessita de inspeção visual. Isso motivou trabalhos como o de Flexer *et al.* (2005) para automatizar a identificação de ICs relacionados à EOG. Na seção a seguir é apresentada essa abordagem.

3.2.2 Remoção Automática de Artefatos

A Análise de Componentes Independentes tem um papel na remoção de artefatos de EOG (Makeig *et al.*, 1996; Jung *et al.*, 2000; Radüntz *et al.*, 2015), contudo ela exige uma quantidade significativa de dados de forma que a distribuição de probabilidades de cada mistura de sinais seja devidamente caracterizada. Além disso, os componentes independentes extraídos não seguem uma ordem, sendo necessária, tipicamente, a inspeção visual para a identificação dos artefatos. Essas limitações dificultam o tratamento da influência da EOG em tempo real.

Contudo, em alguns cenários, tal como o apresentado no problema *BCI Competition IV-2b*, os sinais de Eletrooculografia são acessíveis pela BCI. Assim, durante a etapa de coleta,

Figura 3.2: Ilustração das etapas envolvidas para a classificação de sinais de controle em Interfaces Cérebro-Computador e os métodos considerados para aquisição (pela *BCI Competition IV-2b*) e pré-processamento dos dados.

pode-se utilizar τ amostras anteriores para a extração dos ICs e compará-los à EOG. Assim como em Flexer *et al.* (2005), a correlação de Pearson é empregada neste trabalho de mestrado para efetuar a comparação entre ICs e canais de EOG. Seja $\sigma(\text{EOG}_i, \text{IC}_j)$ essa correlação e θ um limiar pré-definido tal que $0 \leq \theta \leq 1$, se para qualquer i , $|\sigma(\text{EOG}_i, \text{IC}_j)| > \theta$ então o Componente Independente IC_j não é incluído na reconstrução dos sinais.

Mais especificamente, o pré-processamento é efetuado sobre uma janela de tempo de cinco segundos anterior ao início de um ensaio e até seu término, extraída de cada um dos canais c_X dentre os três de EEG e os três de EOG disponíveis, gerando $\mathbf{X} = (x_{c_X}(t))_{\forall c_X \in C_X}$. A técnica ICA é aplicada sobre $\mathbf{X}$ e, posteriormente, compara-se os ICs com a Eletrooculografia para compor seis novos sinais a partir dos ICs que apresentaram correlação menor que θ em relação a um dos canais de EOG. Produz-se então, novos dados $\tilde{\mathbf{X}}$ constituídos de seis novos canais $c \in C$. Assim, como ilustrado na Figura 3.2, após essa etapa de pré-processamento, são extraídas características dos dados resultantes de forma a produzir informação relevante para a classificação da Imagética Motora (IM). Cabe ressaltar que, neste trabalho, são considerados os índices *kappa* produzidos pela execução de cada extrator de características sobre os sinais cerebrais pré-processados por meio da técnica ICA, empregando diferentes valores $\theta \in \Theta$ (mais precisamente para $\Theta = \{0, 1; 0, 2; \dots; 1\}$).

3.3 Extração de Características

Após a remoção de artefatos, é possível extrair sinais de interesse mais representativos e estudá-los. No entanto, há ainda outros aspectos que interferem no comportamento desses sinais. Para exemplificar, considere a estratégia mental de Imagética Motora (IM) utilizada para a construção de BCI. Ela é comumente baseada na identificação e classificação da sincronização e dessincronização das ondas μ e β , produzidas pela Imagética Motora de algum membro do indivíduo (maiores detalhes no Capítulo 1). Portanto, neste

trabalho, tal como em Ang *et al.* (2012a), os sinais são filtrados nas faixa de frequência entre [4; 40] Hz após a remoção dos artefatos para caracterizar os ritmos sensório-motores (ondas μ e β).

Em contrapartida, a energia desses sinais varia em relação a condições subjetivas tais como a emoção, a concentração e o estado de saúde, e apresentam diferenças entre indivíduos (Doppelmayr *et al.*, 1998; da Silva & Pfurtscheller, 1999; Neuper & Pfurtscheller, 2001; del R Millan *et al.*, 2002), o que dificulta ainda mais a tarefa de projeto e construção de um sistema de BCI de propósito geral. É neste complexo cenário que surgem diferentes estudos voltados tanto para a remoção de artefatos, quanto para a extração de características relevantes de sinais de controle, a fim de identificar as intenções de usuários. Neste contexto, uma das técnicas consideradas estado da arte é o FBCSP (Ang *et al.*, 2012a) que visa encontrar uma projeção espacial para cada banda de frequência (i.e., considerando apenas os eletrodos como as dimensões do problema).

Contudo, essa técnica não inclui informações sobre quaisquer relações temporais dos canais de EEG, o que pode ser alcançado a partir do CSSP e do CSSSP. Em Ang *et al.* (2012a), é afirmado que o CSSSP consiste na produção de filtros de Resposta a Impulso Finita (do inglês *Finite Impulse Response* – FIR) de forma que haja otimização simultânea das variâncias dos sinais associados às diferentes classes de movimento. Mesmo que o FBCSP já empregue o uso de banco de filtros é esperado que o CSSSP resulte em melhores acurácias por ser relacionado ao Teorema de Imersão de Takens (Takens, 1981), o que faz com que produza um espaço capaz de representar as recorrências temporais não lineares.

Neste trabalho, sete abordagens de extração de características foram avaliadas. A primeira utilizando apenas a análise multirresolução por meio de filtros FIR, decompondo o sinal a partir de uma árvore diádica de frequências, as três seguintes empregando apenas CSP, CSSP e CSSSP e as restantes considerando banco de filtros FIR em conjunto com os filtros espaciais e espaço-temporais: CSP, CSSP e CSSSP. Para todas as abordagens, tal como ilustrado na Figura 3.3, a partir de $\tilde{\mathbf{X}}$ extrai-se uma janela de tempo de tamanho pré-definido, de um ou dois segundos mais precisamente, 0,5 segundo após o início da Imagética Motora, gerando um conjunto de sinais $\mathbf{Z} \ni z_c(t)$, utilizados para a produção de características (maiores detalhes são apresentados no Capítulo 4).

Posteriormente, os métodos de extração de características foram empregados para o processamento dos sinais, na tentativa de se produzir informações relevantes para a clas-

Figura 3.3: Janela de tempo utilizada na extração de características.

sificação da Imagética Motora. A seguir são apresentadas as técnicas de extração de características utilizadas neste trabalho.

3.3.1 Análise Espectral

Como apresentado no Capítulo 1, a dessincronização de ondas μ e β têm, respectivamente, características espectrais nas faixas [7; 12] Hz e [12; 30] Hz que podem ser utilizadas para a classificação de Imagética Motora. A etapa de análise espectral tem como objetivo encontrar essas características para que, em seguida, um algoritmo de aprendizado de máquina supervisionado produza um modelo que identifique diferentes comportamentos nos sinais de controle. Posteriormente, esse modelo é utilizado para definir as operações sobre o ambiente externo (e.g. cadeira de rodas).

Contudo, as ondas μ e β apresentam grande variabilidade entre indivíduos, mesmo quanto aos aspectos temporais, espectrais e espaciais, o que dificulta a construção de BCIs de propósito geral (Doppelmayr *et al.*, 1998; da Silva & Pfurtscheller, 1999; Neuper & Pfurtscheller, 2001; del R Millan *et al.*, 2002). Isso motivou Yang *et al.* (2007) e Ince *et al.* (2007) a empregarem métodos de análise espectral que permitissem adaptar a resposta da BCI à atividade cerebral individual. Para isso, eles utilizaram a análise multirresolução (respectivamente a Decomposição de Pacotes Wavelet e a Transformada do Cosseno) com o intuito de selecionar bandas de frequência que produzam características mais discriminativas para um determinado sujeito.

Os trabalhos de Yang *et al.* (2007) e Ince *et al.* (2007) são considerados no contexto deste mestrado, pois auxiliam no projeto de BCIs capazes de se adaptar às características de cada indivíduo. Mais precisamente, este trabalho utilizou a seleção de bandas por meio da análise multirresolução baseada em filtros FIR e a dimensionalidade do con-

junto de características foi reduzida por um critério baseado em ganho de informação denominado Seleção de Características baseadas em Informação Mútua (do inglês *Mutual Information-based Feature Selection* – MIFS) (Ang & Quek, 2006). Além disso, tal como em Ang *et al.* (2012a), um banco de filtros FIR foi utilizado para extrair sub-bandas dos sinais de EEG as quais, posteriormente, foram transformadas por meio de filtros espaciais e espaço-temporais tais como o CSP, CSSP, e CSSSP.

Banco de Filtros FIR e Análise Multirresolução

A Análise Multirresolução (do inglês *Multiresolution Analysis* – MRA) visa, a partir de transformações ortogonais, encontrar subespaços que contenham informações adicionais sobre os sinais de controle analisados (Akansu & Haddad, 1992). Assim, por meio dessas diferentes funções, pode-se analisar um sinal em diferentes faixas de frequência, denominadas sub-bandas. A MRA pode ser realizada por meio de diferentes técnicas, tais como por meio de um banco de filtros FIR, Transformada de Fourier de Curta Duração (do inglês *Short Time Fourier Transform* – STFT) e Transformadas Wavelet (Akansu & Haddad, 2001).

As ondas μ e β têm, respectivamente, intervalos de frequência de $[7; 12]$ Hz e de $[12; 30]$ Hz. O comportamento desses sinais pode variar ao longo de uma sessão experimental e entre indivíduos. Ademais, as informações mais discriminativas dos dados podem estar contidas em um menor intervalo dentro das ondas μ ou β . Portanto, a análise multirresolução desses sinais é uma ferramenta útil para a seleção de sub-bandas relevantes para um determinado indivíduo.

A análise multirresolução foi conduzida, no contexto deste mestrado, utilizando filtros FIR. Os filtros FIR empregam transformações sobre séries temporais, considerando observações atuais e passadas com o propósito de eliminar o impacto de componentes espectrais indesejados (Lyons, 1996). Um filtro FIR h pode ser projetado para extrair componentes de baixas ou altas frequências. Por exemplo, no caso da Figura 3.4, utiliza-se uma série periódica composta por n observações $x = (10, 10, 2, 2)_{i=1, \dots, n}^{i=1, \dots, n}$ cujo comprimento de onda é de três unidades. Dado um período τ , assumindo que $x(t) = x(t + \tau)$ para qualquer t , se um filtro FIR, $h_1 = (1, -1, 1, -1)$, construído para responder em comprimento de onda de duas unidades for aplicado sobre x , nenhuma resposta será apresentada já que o sinal não contém componentes com a mesma frequência de h_1 . Em contrapartida, ao se considerar o filtro $h_2 = (1, 1, -1, -1)$, obtém-se resposta significativa uma vez que os sinais têm o mesmo

período.

Figura 3.4: Sinais y_1 e y_2 produzidos, respectivamente, pela convolução dos filtros h_1 e h_2 sobre o sinal x .

Dado que x pode ser representado por uma série de Fourier, ele pode ser escrito na forma de uma combinação linear de bases trigonométricas que formam um espaço $\mathcal{F}$. Sobretudo, x está contido em um subespaço $V \subset \mathcal{F}$. Assim, dado o subespaço V complemento ortogonal de V^c , qualquer vetor ou função contido em V é linearmente independente aos contidos em V^c , portanto, o produto escalar entre qualquer componente de V^c e x resulta em um elemento nulo. No exemplo anterior, x e h_2 pertencem ao mesmo subespaço V e, portanto, ambos são produzidos pela mesma base de forma que a convolução entre x e h_2 não seja nula. Em contrapartida, h_1 está contido no subespaço V^c sendo, portanto, complemento ortogonal de V de forma que a convolução entre x e h_1 produza um componente nulo. Assim, é possível definir funções trigonométricas que, quando operadas sobre uma série, produzam componentes de intervalos de frequência pré-definidos.

Neste contexto, sejam $f_{min} < f < f_{max}$, f_1 e f_2 frequências pré-estipuladas e f_{min} e f_{max}

a mínima e máxima frequência possível de um sinal (dado pelo Teorema de Amostragem de Nyquist-Shannon (Shannon, 1998)), denomina-se um filtro passa-baixas aquele que extrai componentes com intervalos de $\hat{f} = [f_{min}; f]$, passa-altas aquele que extrai intervalos caracterizados por $\hat{f} = [f; f_{max}]$ e, finalmente, passa-bandas aquele que permite recuperar os intervalos $\hat{f} = [f_1; f_2]$. Os bancos de filtros produzem um conjunto de transformações que segmentam um sinal em n intervalos de frequência. Por exemplo, pode-se construir um banco de filtros que segmente uma série temporal com intervalo de frequência de 4 a 40 Hz em nove intervalos de frequência de 4 Hz.

Além disso, por meio dos filtros FIR, os sinais do imageamento por EEG podem ser decompostos para a obtenção de seus componentes ou ondas μ e β , i.e., um sinal com intervalo de frequências $\hat{f}_1^1 = [f_{min}, f_{max}] = [7; 30]$ Hz ou, no caso deste trabalho, $[4; 40]$ Hz. A partir desses componentes, pode-se aplicar um banco de filtros FIR de forma a se obter dois subcomponentes com intervalos de frequência $\hat{f}_1^2 = [f_{min}; (f_{max} - f_{min})/2]$ e $\hat{f}_2^2 = [(f_{max} - f_{min})/2; f_{max}]$. Aplica-se, repetidamente, esse processo sobre cada subcomponente produzido, gerando uma árvore diádica de sub-bandas como ilustrada na Figura 3.5. Esse processo aumenta a resolução, no domínio de frequências, para cada sinal estudado, conforme o nível da árvore diádica.

Figura 3.5: Estrutura de uma Árvore Diádica de Bandas de Frequência.

Essa técnica, denominada de Árvore Diádica de Bandas de Frequência, é avaliada neste trabalho de mestrado considerando sinais filtrados entre 4 e 40 Hz (intervalo que engloba as ondas μ e β) e produzindo os descritores de características por meio da energia dessas bandas. Assim, para cada ensaio e e canal c , é produzida a ADBF com altura igual a cinco, para a análise multirresolução de um intervalo de tempo $t = [t_0 = 0, 5; t_n]$ (mais

precisamente, pode ser atribuído um ou dois segundos a t_n) dentro do período de Imagética Motora. Neste trabalho, a produção dos nós da ADBF termina se os próximos intervalos de frequência apresentam variação menor que 1 Hz. Posteriormente, as energias de cada banda $b \in B$ e canal $c \in C$, definidas pela Equação 3.3, são concatenadas em um vetor de características o qual é associado ao rótulo $y \in \mathcal{Y}$ do respectivo ensaio (mais especificamente Imagética Motora da mão esquerda e da mão direita).

$$\mathcal{E}_{c,b} = \sum_{t=t_0}^{t_n} \frac{z_{c,b}^2}{t_n - t_0} \quad (3.3)$$

Esse espaço de características dado por $\mathcal{V} = \mathbb{R}^{|B||C|} \times \mathcal{Y}$, é reduzido posteriormente para um subespaço $\mathcal{V}_r = \mathbb{R}^k \times \mathcal{Y}$, com $k < |B||C|$, por meio da Seleção de Características baseada em Informação Mútua (MIFS). Como neste trabalho a ADBF têm altura igual a cinco, a dimensão do espaço S é de 64 sub-bandas vezes 6 canais, o que resulta em $\dim(S) = 64 \times 6 + 1 = 385$. Além disso esse subespaço S_r é o utilizado para a classificação como apresentado na Figura 3.6.

Figura 3.6: Etapas de classificação de imagética motora envolvendo a ADBF e seleção de características por meio do algoritmo MIFS.

Além disso, como ilustrado na Figura 3.7, avaliou-se também o uso da combinação entre um banco de filtros FIR de nove componentes com intervalo de frequência de 4 Hz, contidos entre 4 e 40 Hz, e filtros espaciais e espaço-temporais, apresentados no capítulo seguinte, para a extração de características. Posteriormente, também emprega-se o algoritmo MIFS para a redução da dimensionalidade (ou atributos) do espaço de características.

Figura 3.7: Etapas de classificação de imagética motora envolvendo banco de filtros, filtros espaciais e seleção de características.

3.3.2 Filtros Espaciais e Espaço-temporais

Como apresentado no Capítulo 1, a Imagética Motora produz sincronização e dessincronização das ondas μ e β as quais têm características espaciais bem definidas. Particularmente, no caso de IM das mãos, esses ritmos tendem a dessincronizar mais proeminentemente em regiões contralaterais ao membro (Pfurtscheller & Neuper, 2010). Isso motivou o desenvolvimento de técnicas que visam realçar tais relações espaciais em termos de discriminabilidade. Uma das técnicas mais empregadas no contexto de BCI é a de Padrões Espaciais Comuns (do inglês *Common Spatial Patterns* – CSP) que, em problemas birrotulados, maximiza a variância de sinais associados a uma classe enquanto minimiza a de associados à outra classe.

Contudo, o CSP não abrange características temporais dos dados que, como apresentado no Capítulo 1, são bem definidos nas ondas μ e β . Isso motivou o desenvolvimento da técnica de Padrão Espectro-Espacial Comum (do inglês *Common Spectral-Spatial Patterns* – CSSP), a qual visa otimizar as variâncias de ambas as classes, simultaneamente, de forma que sejam avaliados os sinais originais e seu deslocamento em um tempo de atraso τ pré-definido. Há, também, o Padrão Espectro-Espacial Comum Esperso (do inglês *Common Sparse Spectral-Spatial Patterns* – CSSSP) que generaliza o CSSP para um espaço fase

(espaço obtido após o emprego do Teorema de Imersão de Takens) com coordenada de atraso τ e dimensão embutida m pré-definidos (Takens, 1981).

Padrões Espaciais Comuns

Dentro do contexto de BCI, o CSP visa salientar a relação espacial entre a sincronização e dessincronização dos ritmos sensório-motores. Para isso, é calculada a matriz de covariância média dos ensaios $e^{(y_1)} \in E^{(y_1)}$ associados à uma classe y_1 e a dos ensaios $e^{(y_2)} \in E^{(y_2)}$ associados à uma classe y_2 , sendo $E^{(y)}$ o conjunto dos ensaios associados a uma classe y . Assim, seja $\mathbf{Z}_e = (\mathbf{z}_c(t))_{c \in C}$ a janela de tempo extraída de um ensaio e , x_{c_i} os sinais de cada canal de EEG c_i com N amostras e C a quantidade de canais, a matriz de covariância média é dada por:

$$\Sigma^{(y)} = \frac{1}{N|E^{(y)}|} \sum_{e \in E^{(y)}} (\mathbf{z}_e - \bar{\mathbf{z}}_e)^T (\mathbf{z}_e - \bar{\mathbf{z}}_e). \quad (3.4)$$

Deseja-se, então, encontrar uma transformação $\mathbf{W}$ que maximiza a variância dos sinais associados à classe y_1 enquanto minimiza a dos associados à classe y_2 . Para isso, considera-se o problema de minimização definido pela Equação 3.5, cuja solução corresponde à mesma do problema de autovetor generalizado, $\Sigma^{(y_1)} \mathbf{w}_i = \lambda_i \Sigma^{(y_2)} \mathbf{w}_i$. Note que, quão maior é a variância da projeção dos sinais associados à classe y_1 sobre $\mathbf{w}_i$, menor deve ser a variância na projeção dos associados à classe y_2 e vice-versa.

$$\mathbf{W}^* = \arg \min_{\mathbf{W}} \frac{\mathbf{W}^T \Sigma^{(y_2)} \mathbf{W}}{\mathbf{W}^T \Sigma^{(y_1)} \mathbf{W}} \quad (3.5)$$

Posteriormente, emprega-se a variância da projeção $\tilde{\mathbf{Z}}_e = \mathbf{W}^{*T} \mathbf{Z}_e$ dos sinais extraídos de um ensaio para a construção dos descritores de características, os quais serão utilizados na classificação. Cabe ressaltar que, apesar do CSP ser aplicável apenas em problemas birrotulados, ele se enquadra justamente no escopo deste trabalho de mestrado.

Em contrapartida, o CSP não abrange a dependência temporal dos sinais cerebrais capturados por EEG, o que motivou o desenvolvimento do CSSP (Lemm *et al.*, 2005). Sendo os sinais de EEG definidos por $\mathbf{Z}_e(t) = (\mathbf{z}_{c_i}(t))_{i=1,2,\dots,C}$, o CSSP reconstrói o conjunto de dados a partir da união do sinal original e o seu deslocamento em um atraso τ , de forma que $\mathbf{Z}_{\tau,e}(t) = (\mathbf{z}_{c_i}(t), \mathbf{z}_{c_i}(t - \tau))_{i=1,2,\dots,C}$. Posteriormente, essa reconstrução é utilizada na resolução do problema definido pela Equação 3.5 para a produção do autoespaço $\mathbf{W}^*$.

A partir da perspectiva da área de sistemas dinâmicos o CSSP produz um espaço fase com dimensão embutida $m = 2$ e coordenada de atraso τ pré-definida, por meio do emprego do Teorema de Imersão de Takens (Takens, 1981). O CSSSP busca generalizar o CSSP considerando maiores dimensões embutidas, i.e., procura reconstruir o atrator completo da série temporal a fim de desdobrar suas recorrências (Allgood *et al.*, 1997). Assim, seja m a cardinalidade da dimensão embutida, a matriz de covariância a ser empregada na Equação 3.5 é calculada por meio da imersão dos sinais, i.e., $\mathbf{Z}_{m,\tau,k}(t) = (\mathbf{z}_{c_i}(t), \mathbf{z}_{c_i}(t - \tau), \dots, \mathbf{z}_{c_i}(t - (m - 1)\tau))_{i=1,2,\dots,C}$.

Neste trabalho de mestrado, as três técnicas de Padrões Espaciais Comuns são avaliadas no que diz respeito ao índice *kappa* (adotado pela *BCI Competition*) e são, também, empregadas em conjunto com banco de filtros como ilustrado na Figura 3.8.

Figura 3.8: Etapas de classificação de imagética motora envolvendo banco de filtros, CSP, CSSP ou CSSSP e seleção de características.

Para se aplicar os filtros espaciais e espaço-temporais, foram, primeiramente, utilizados todos os autovetores do autoespaço $\mathbf{W}^*$ produzidos a partir do conjunto de dados de treinamento para se projetar os dados $\mathbf{Z}_e$. Para cada canal c contido em um ensaio e , é calculado o logaritmo da variância das projeções $\tilde{\mathbf{Z}}_e^c$ (ou $\tilde{\mathbf{Z}}_e^{c,b}$ no caso do FBCSP, FBCSSP e FBCSSSP), tal como apresentado na Equação 3.6, compondo um vetor $\mathbf{v}_e$ de características associados ao ensaio e . Então, produz-se um conjunto de exemplos para a classificação a

partir dos vetores $\mathbf{v}_e \forall e \in E$. Posteriormente, a dimensionalidade do espaço de características é reduzida pelo emprego MIFS, a fim de aprimorar os resultados de classificação (Ang & Quek, 2006).

$$\mathbf{v}_e = \left(\log \left(\text{var} \left(\tilde{\mathbf{z}}_e^c \right) \right) \right)_{c \in C} \quad (3.6)$$

3.4 Seleção de Características

As técnicas de extração de características apresentadas anteriormente produzem alta dimensionalidade no espaço de exemplos ou informações irrelevantes. O problema da Maldição da Dimensionalidade ocorre em casos em que a proporção entre a dimensão do conjunto de dados e a quantidade de exemplos é grande o suficiente para torná-los pouco representativos, reduzindo, portanto, a acurácia na etapa de classificação (Hughes, 1968). Para complementar, segundo Hopcroft & Kannan (2014), o aumento das dimensões de um espaço pode ocasionar a compactação dos dados, visto que o volume de uma hipersfera tende a um ponto quando sua dimensão tende ao infinito. Isso motiva o emprego de uma abordagem para a seleção de características com o intuito de produzir um espaço de dados menor e mais relevante. A Seleção de Características baseada em Informação Mútua (MIFS) faz uma busca gulosa no espaço de exemplos de forma a procurar pelas dimensões que melhor representam os rótulos em termos de ganho de informação (Ang & Quek, 2006).

Seja $\tilde{\mathbf{x}}$ um vetor coluna do espaço de características $\mathcal{X}$ e $\tilde{\mathbf{y}}$ seus respectivos rótulos, essa técnica de seleção de características segue o Algoritmo 1.

Algoritmo 1: Algoritmo da técnica MIFS.

Entrada: $\mathcal{X} \times \mathcal{Y}, k$
 $\mathcal{F} \leftarrow \mathcal{X} \times \mathcal{Y};$
 $S \leftarrow \emptyset;$
enquanto $\dim(S) < k$ **faça**
 $\tilde{\mathbf{x}}^* \leftarrow \arg \max_{\tilde{\mathbf{x}} \in \mathcal{F}} I(S \cup \tilde{\mathbf{x}}, \tilde{\mathbf{y}});$
 $S \leftarrow S \cup \tilde{\mathbf{x}}^*;$
 $\mathcal{F} \leftarrow \mathcal{F} / \tilde{\mathbf{x}}^*;$
fim
retorna $S.$

Neste trabalho de mestrado, após a extração de características, é aplicado o algoritmo

MIFS para a redução de dimensionalidade e, posteriormente, esse novo espaço de exemplos é utilizado para treinamento e classificação da Imagética Motora (maiores detalhes na próxima seção). Note que essa técnica é utilizada apenas sobre o conjunto de dados de treinamento para não superestimar os resultados obtidos.

3.5 Classificação

Aprendizado de máquina é uma subárea da inteligência computacional que visa estudar e propor abordagens para a aquisição e emprego de conhecimento em problemas práticos (Marsland, 2009). Essa subárea tradicionalmente realiza o processo de indução de um modelo a partir de exemplos ou instâncias (Mitchell, 1997; Marsland, 2009). Suas técnicas têm sido utilizadas em diversas áreas, tais como mineração de dados, processamento de sinais, robótica e processamento de linguagem natural (Mitchell, 1997; Marsland, 2009).

Os paradigmas do aprendizado de máquina podem ser divididos essencialmente em: i) aprendizado de máquina supervisionado, em que os exemplos de treinamento são previamente rotulados e, portanto, contam com uma classe; e ii) aprendizado não-supervisionado de máquina, em que não há rótulos para as instâncias, caso em que são utilizadas medidas de similaridade entre exemplos. Este trabalho está somente relacionado ao primeiro paradigma, o que se justifica devido ao fato dos ensaios de sessões experimentais de Eletroencefalografia serem rotulados.

As Interfaces Cérebro-Computador visam traduzir sinais de controle em uma determinada operação, possibilitando que um indivíduo consiga interagir com o ambiente externo sem a necessidade de controle muscular. Para atingir tal objetivo, são necessárias diversas técnicas como a remoção de artefatos e a extração de características dos sinais da atividade cerebral do usuário. Espera-se, assim, produzir dados que permitam a classificação das intenções de usuários com bom índice *kappa*. Para isso, recorre-se a técnicas de aprendizado de máquina supervisionado que, baseadas nas classes que definem os sinais de controle, induzem classificadores que representem a distribuição de probabilidade conjunta P , a qual determina, a partir dos atributos obtidos, as probabilidades de ocorrência entre atributos de entrada e classes (Vapnik, 1995).

Neste trabalho, foram empregadas as Máquinas de Vetores de Suporte (do inglês *Support Vector Machines* – SVM) para classificar as intenções dos usuários, pois, conforme des-

tacado e formalizado em (von Luxburg & Scholkopf, 2009), elas asseguram o Princípio de Minimização do Risco Empírico (PMRE), provado segundo a Teoria do Aprendizado Estatístico (TAE) (Vapnik, 1995). Além disso, as Máquinas de Vetores de Suporte têm convergência mais justa de generalização quando comparadas a outras técnicas de aprendizado de máquina supervisionado.

A partir do conceito de generalização apresentado na TAE, Vapnik elucida o problema de *overfitting* e *underfitting* e conclui que o aumento na complexidade de um classificador f acarreta em perda de generalização, i.e., se f for mais complexo do que é exigido pelo problema em questão, tende-se a obter bons resultados para exemplos já vistos, porém resultados ruins para exemplos nunca vistos, o que corresponde ao *overfitting*. Contudo, a redução da complexidade dos classificadores pode produzir rotuladores incapazes de caracterizar o problema e, portanto, eles não produzem bons resultados ao categorizar exemplos já vistos e nunca vistos.

Essa questão é conhecida como Dilema Viés-Variância (Vapnik, 1995), a partir do qual Vapnik formalizou o Princípio de Minimização do Risco Empírico e criou medidas de capacidade que avaliam se um algoritmo de aprendizado de máquina produz bons classificadores. Dentre essas medidas de capacidade é importante citar o Limite para Máxima Margem (do inglês *Large Margin Bounds*), utilizado como base para o projeto da SVM e que lhe confere garantias de aprendizado mais justas. Uma vez que a técnica SVM é provada ter limites mais justos de aprendizado, seu uso é de interesse deste mestrado. A seção a seguir apresenta maiores detalhes sobre as Máquinas de Vetores de Suporte.

3.5.1 Máquina de Vetores de Suporte

O Limite de Máxima Margem formulado por Vapnik define que, quanto maior a largura de uma margem definida a partir de um hiperplano separador e os exemplos de classes distintas, mais justas são as garantias de aprendizado de um determinado classificador (von Luxburg & Scholkopf, 2009). Isso motivou Cortes & Vapnik (1995) a proporem as SVMs.

Define-se como hiperplano canônico o hiperplano de suporte que contém o ponto p mais próximo ao separador linear. Por exemplo, considerando x^- e x^+ instâncias de rótulos -1 e $+1$ respectivamente, a SVM busca, a partir dos hiperplanos canônicos $h^+ \stackrel{\text{def}}{=} \langle \mathbf{w}, \mathbf{x}_0^+ \rangle + b = +1$ e $h^- \stackrel{\text{def}}{=} \langle \mathbf{w}, \mathbf{x}_0^- \rangle + b = -1$, ilustrados na Figura 3.9, maximizar a distância $1/\|\mathbf{w}\|$ entre h^+ e h^- .

Figura 3.9: Hiperplanos canônicos h^+ e h^- e demonstração da função objetivo do problema de maximização de margem (Adaptado de (Schölkopf & Smola, 2001)).

A partir da função de decisão $f_{\mathbf{w},b}(\mathbf{x}) = \text{sign}(\langle \mathbf{w}, \mathbf{x} \rangle + b)$ que satisfaça $f_{\mathbf{w},b}(\mathbf{x}_i) = y_i$, define-se o problema primal de maximização de margem da SVM na forma:

$$\begin{aligned} & \underset{\mathbf{w} \in H, b \in \mathbb{R}}{\text{minimizar}} \quad \tau(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{sujeito a} \quad y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 \geq 0 \text{ para todo } i = 1, 2, \dots, m \end{aligned}$$

O problema primal apresenta função objetivo convexa e restrições lineares e, portanto, tem solução factível. Para encontrar essa solução é necessário minimizar a Lagrangiana do problema primal dada pela Equação 3.7.

$$L(\mathbf{w}, b, \lambda) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^m \lambda_i [y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1]. \quad (3.7)$$

Dessa forma, é possível encontrar um ponto estável para $L(\mathbf{w}, b, \lambda)$ em $\frac{\partial L}{\partial b} = 0$ e $\frac{\partial L}{\partial \mathbf{w}} = 0$. Portanto,

$$\frac{\partial L}{\partial b} = \sum_{i=1}^m \lambda_i y_i b = 0$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^m \lambda_i y_i \mathbf{x}_i = 0 \rightarrow \mathbf{w} = \sum_{i=1}^m \lambda_i y_i \mathbf{x}_i$$

Define-se assim, o Problema Dual de Lagrange na forma:

$$\begin{aligned}
& \underset{\mathbf{w} \in H, b \in \mathbb{R}}{\text{maximizar}} & g(\lambda) &= \sum_{i=1}^m \lambda_i - \frac{1}{2} \sum_{i=1, j=1}^m \lambda_i \lambda_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \\
& \text{sujeito a} & & \lambda_i \geq 0, \text{ para todo } i = 1, 2, \dots, m \text{ e} \\
& & & \sum_{i=1}^m \lambda_i y_i = 0.
\end{aligned}$$

e a sua respectiva função de decisão é determinada pela Equação 3.8.

$$f(\mathbf{x}) = \text{sin} \left(\sum_{i=1}^m \lambda_i y_i \langle \mathbf{x}, \mathbf{x}_i \rangle + b \right). \quad (3.8)$$

Ambos problemas respeitam as condições de Karush-Kuhn-Tucker (KKT) (Schölkopf & Smola, 2001), logo há um conjunto viável de soluções. Dessa maneira, a forma dual apresenta o que se chama de dualidade forte, ou seja, sua solução ótima é equivalente à solução ótima para o problema primal.

Apesar de ter garantias de aprendizado mais justas, a SVM é apenas capaz de classificar espaços linearmente separáveis. Contudo, é possível aplicar o conceito de *Kernel Trick* de forma que, ao invés do hiperplano ser produzido no espaço de exemplos $\mathcal{X}$, ele é construído sobre um espaço de Hilbert $\mathcal{H}$ que se supõe ser linearmente separável (uma matriz de Gram deve ser produzida). Assim, dado um mapeamento $\phi : \mathcal{X} \rightarrow \mathcal{H}$, o produto escalar entre os exemplos é dado por $\phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) = \mathbb{K}(\mathbf{x}_i, \mathbf{x}_j)$. Portanto, o problema de otimização da SVM com *kernel* é definido por:

$$\begin{aligned}
& \underset{\mathbf{w} \in H, b \in \mathbb{R}}{\text{maximizar}} & g(\lambda) &= \sum_{i=1}^m \lambda_i - \frac{1}{2} \sum_{i=1, j=1}^m \lambda_i \lambda_j y_i y_j \mathbb{K}(\mathbf{x}_i, \mathbf{x}_j) \\
& \text{sujeito a} & & \lambda_i \geq 0, \text{ para todo } i = 1, 2, \dots, m \text{ e} \\
& & & \sum_{i=1}^m \lambda_i y_i = 0 \\
& & & f(\mathbf{x}) = \text{sin} \left(\sum_{i=1}^m \lambda_i y_i \mathbb{K}(\mathbf{x}, \mathbf{x}_i) + b \right).
\end{aligned}$$

Assim, com conhecimento prévio sobre o comportamento do espaço de exemplos, é possível selecionar um *kernel* $\mathbb{K}(\cdot, \cdot)$ que discrimine um conjunto de dados não-linearmente separável. No contexto desse trabalho de mestrado o *kernel* utilizado foi o radial e o algoritmo de classificação é utilizado após a seleção de características por meio da MIFS.

3.6 Considerações Finais

Uma série de procedimentos é utilizada para classificar sinais de controle por uma BCI. Um desses visa o tratamento dos sinais de EEG que são bastante sensíveis a ruídos externos e a artefatos produzidos pela própria atividade cerebral do indivíduo em questão. Atividades oculares, musculares e cardíacas podem prejudicar o desempenho da BCI, o que motivou o emprego da Análise de Componentes Independentes na etapa de pré-processamento. Contudo, como a ICA não aborda a identificação automática de sinais fonte que representam artefatos, foi considerado o trabalho de Flexer *et al.* (2005) que emprega uma medida de correlação para esse fim.

A subjetividade do comportamento das ondas referentes à atividade sensório-motora (ondas μ e β) torna a extração de características uma tarefa complexa. Trabalhos como Kang *et al.* (2009) estudaram maneiras de utilizar os sinais de controle de um indivíduo para auxiliar na classificação da Imagética Motora de outro (*subject-to-subject transfer*). Contudo, as técnicas que envolvem produzir características específicas de um sujeito se mostraram mais eficientes e, além disso, há na literatura pesquisas afirmando que ondas μ variam entre indivíduos (Doppelmayr *et al.*, 1998; da Silva & Pfurtscheller, 1999; Neuper & Pfurtscheller, 2001; del R Millan *et al.*, 2002).

A primeira abordagem deste projeto baseou-se em Árvore Diádica de Bandas de Frequência (ADBF), apresentada no exame de qualificação, a qual produziu resultados razoáveis na classificação de conjuntos de treinamento e teste definidos para cada sessão. Cabe ressaltar que, além dessa abordagem e das outras discutidas na seção anterior, diversas outras foram implementadas sem sucesso. Buscando aprimorar a técnica de ADBF, foram também extraídas características por meio de seções temporais nas ADBFs de forma que, cada um de seus componentes foi subdividido em diversas janelas temporais formando, também, uma estrutura multirresolução no domínio do tempo. Sobre cada uma dessas janelas foi calculada a energia do sinal que, posteriormente, compôs um vetor de características. Logo após, a Análise de Discriminante Linear ou a Análise de Discriminante com *Kernel* foi utilizada a fim de reduzir a dimensionalidade do conjunto de características. Porém, verificou-se que essa abordagem produzia *overfitting* sobre os dados de treinamento apresentando, portanto, baixa acurácia para exemplos nunca vistos.

De maneira complementar, a técnica Decomposição de Modos Empírica (do inglês *Em-*

pirical Mode Decomposition – EMD) (Huang *et al.*, 1998) foi utilizada para a separação dos sinais de controle em componentes estocástico e determinístico (Rios & de Mello, 2013). Dado o comportamento bem definido, contudo variável, das ondas μ e β , havia a expectativa de que a informação relevante de um sinal de controle estivesse contida na parte determinística. Porém, observou-se que os atratores, produzidos a partir das coordenadas de atraso e dimensões embutidas (Takens, 1981) do componente determinístico, não proviam boa separabilidade e, portanto, descartou-se a tal decomposição para a extração de características dos sinais de controle.

Outra abordagem experimentada neste trabalho foram as Redes Neurais Convolucionais (do inglês *Convolutional Neural Networks* – CNN) sobre a Transformada Wavelet dos ensaios a fim de realizar a extração de características dos sinais de controle. Três arquiteturas foram testadas, uma contendo três camadas com máscaras de dimensões iguais a, respectivamente, 5×5 , 7×7 e 11×11 , outra contendo dimensões iguais a 3×3 , 5×5 e 7×7 e a última seguindo a arquitetura proposta em Krizhevsky *et al.* (2012). As duas primeiras arquiteturas contavam com o treinamento por meio da maximização da entropia das máscaras e a última por meio do gradiente estocástico, ambas resultaram em acurácia abaixo de 0,7 (com índice *kappa* abaixo de 0,4).

Por conta das características topológicas dos sinais de EEG, diversos trabalhos utilizam filtros espaciais tais como os produzidos pelo CSP, CSSP e CSSSP (Koles, 1991; Lemm *et al.*, 2005; Dornhege *et al.*, 2006) e são considerados neste trabalho de mestrado já que fazem parte do estado da arte. Além disso, o vencedor da competição *BCI Competition IV-2b* utilizou a técnica CSP para, sobre diversas faixas de frequências produzidas por um banco de filtros, transformar os dados adquiridos a partir do imageamento cerebral, otimizando simultaneamente a variação dos sinais de EEG. Contudo, não é considerada, neste contexto, a dependência temporal da ERD e da ERS. Técnicas como o CSSP e o CSSSP visam encontrar filtros que considerem tais dependências temporais já que representam os atratores desses sinais de controle. Porém, essas duas abordagens exigem a parametrização das coordenadas de atraso e da quantidade de dimensões embutidas.

Os métodos de extração de características considerados neste trabalho produzem espaços de exemplos de alta dimensionalidade. Diversas abordagens discutidas na literatura utilizam critérios, tal como o de Fisher (Fisher, 1936), para encontrar sub-espacos de características com maior discriminabilidade linear, reduzindo, assim, a dimensionalidade

Figura 3.10: Ilustração das etapas envolvidas para a classificação de sinais de controle em Interfaces Cérebro-Computador e os métodos considerados neste trabalho. Os fluxos 1, 2 e 3 consideram as abordagens que utilizam banco de filtros e filtros espaciais (CSP, CSSP, CSSSP). Os fluxos 4, 5 e 6 apontam o uso apenas dos filtros espaciais e o fluxo 7 o uso da ADBF. Todas as avaliações dessas abordagens são apresentadas no Capítulo 4.

do problema. No contexto deste trabalho de mestrado, utiliza-se a técnica MIFS a fim de selecionar os atributos que melhor representam, em questão de entropia, a diferença entre sinais de diversos tipos de Imagética Motora. Após a seleção de características, as Máquinas de Vetores de Suporte são utilizadas para a classificação da IM. O fluxograma completo da abordagem utilizada neste trabalho é apresentado na Figura 3.10.

Neste capítulo foram discutidas as abordagens e a fundamentação teórica utilizadas neste trabalho de mestrado para a remoção de artefatos de EOG, extração de características, seleção de características e, finalmente, classificação de sinais de ERD e ERS de dois tipos de Imagética Motora (mão esquerda/direita). Essas etapas e seus respectivos métodos são considerados no capítulo seguinte que discute os resultados experimentais.

Experimentos

4.1 Considerações Iniciais

Sistemas de Interfaces Cérebro-Computador (do inglês *Brain-Computer Interfaces* – BCI) baseados em EEG exigem uma série de etapas que visam produzir informações relevantes para a classificação de Imagética Motora (IM). Devido às interferências produzidas na coleta de dados cerebrais, são utilizadas, tipicamente, técnicas de filtragem na etapa de pré-processamento, a fim de melhorar a qualidade dos sinais cerebrais. Essas interferências podem ser produzidas por atividades não correlatas à Imagética Motora tais como os componentes associados à Eletrooculografia (EOG). Para atenuar as influências dos sinais de EOG, a abordagem utilizada neste trabalho conta com a Análise de Componentes Independentes (do inglês *Independent Component Analysis* – ICA) que permite a análise e seleção de elementos estatisticamente independentes (ou Componentes Independentes, do inglês *Independent Components* – ICs) contidos nos sinais para então proceder com a reconstrução de novos dados que desconsiderem as atividades oculares (maiores detalhes na Seção 3.2).

No entanto, a ICA não conta com nenhuma maneira automatizada para identificar as ICs que representam os sinais de EOG, logo se faz necessária a análise dos componentes independentes por meio de inspeção visual ou outro método acoplado ao processo. Flexer *et al.* (2005) abotam um meio de efetuar tal identificação removendo ICs que são mais

correlacionadas à atividade ocular, i.e., a reconstrução conta apenas com os sinais que apresentam menor similaridade para com os canais de EOG. Para isso, eles empregam um limiar θ de correlação para a rejeição de ICs. Cabe ressaltar que a escolha desse limiar é arbitrária e pode não representar os dados relativos ao problema em questão.

Posteriormente, a etapa de extração de características é efetuada a fim de se produzir informações significativas para a classificação. Neste trabalho, sete métodos de extração de características foram avaliados segundo seus índices *kappa* (Cohen, 1960): i) Árvore Diádica de Bandas de Frequências (ADBF); ii) Padrões Espaciais Comuns (do inglês *Common Spatial Patterns* – CSP); iii) Padrões Espectro-Espaciais Comuns (do inglês *Common Spatio-Spectral Patterns* – CSSP); iv) Padrões Espectro-Espaciais Comuns Esparsos (do inglês *Common Sparse Spatio-Spectral Patterns* – CSSSP); v) CSP com banco de filtros (do inglês *Filter Bank Common Spatial Patterns* – FBCSP); vi) CSSP com banco de filtros (do inglês *Filter Bank Common Spatio-Spectral Patterns* – FBCSSP); e, finalmente, vii) CSSSP com banco de filtros (*Filter Bank Common Sparse Spatio-Spectral Patterns* – FBCSSSP).

Técnicas como CSSP, CSSSP, FBCSP e FBCSSSP empregam o Teorema de Imersão de Takens (Takens, 1981) para reconstruir trajetórias temporais dos sinais de EEG e para, em seguida, otimizar as variâncias dos espaços fase de sinais de controle associados a duas classes (movimento da mão esquerda e da direita). Cabe ressaltar que há a necessidade da definição das coordenadas de atraso τ e número de dimensões embutidas m para cada uma dessas técnicas (Lemm *et al.*, 2005; Dornhege *et al.*, 2006; Ang *et al.*, 2012a).

A extração de características de sinais de controle pode produzir um conjunto de dados com grande número de atributos, o que, devido à maldição da dimensionalidade (Hughes, 1968; Hopcroft & Kannan, 2014), acarreta em menor desempenho de classificação. Diversas técnicas tais como Análise de Componentes Principais (do inglês *Principal Component Analysis* – PCA), Análise de Discriminante Linear (do inglês *Linear Discriminant Analysis* – LDA) e Seleção de Características baseadas em Informação Mútua (do inglês *Mutual Information-based Feature Selection* – MIFS) são tipicamente utilizadas para a redução de atributos do espaço de exemplos.

Neste trabalho foi utilizada a técnica MIFS, a qual efetua uma busca gulosa das dimensões considerando o ganho de informação. Dessa maneira, MIFS permite a análise de correlações não lineares. Por outro lado, essa técnica exige a pré-definição da quantidade k de atributos que devem compor o novo conjunto de exemplos, de forma que

esse parâmetro pode não ser representativo para o problema. Em uma próxima etapa, aplica-se uma Máquina de Vetores de Suporte (do inglês *Support Vector Machines* – SVM), em conjunto com um *kernel* radial, para a classificação do espaço de exemplos produzido após a execução da MIFS. Calcula-se, então, os índices *kappa* para a avaliação de desempenho das abordagens de extração de características. Para o conjunto de dados de EEG considerado neste trabalho (*BCI Competition IV-2b* – maiores detalhes na Seção 2.2), tipicamente encontra-se na literatura avaliações de técnicas propostas com base no treinamento de um modelo a partir de uma composição dos três primeiros ensaios, 1T, 2T e 3T, (abordagem denominada de calibração) e teste conduzido sobre os dois últimos, 4E e 5E. Portanto, os primeiros experimentos deste trabalho utilizam esse modelo experimental para possibilitar uma comparação justa com o estado da arte.

Ademais, visto que as abordagens de extração e seleção de características empregadas contam diversos parâmetros, esses primeiros experimentos calculam os índices *kappa* para diferentes composições paramétricas, definidas pelo espaço $\Theta \times \mathcal{K}$ no caso da ADBF, CSP e FBCSP, pelo espaço $\Theta \times \mathcal{K} \times T$ no caso do CSSP e FBCSSP e, finalmente, pelo espaço $\Theta \times \mathcal{K} \times T \times M$ no caso do CSSSP e FBCSSSP. Esses parâmetros assumem os seguintes valores: i) $\Theta = \{\theta | \theta = 0, 1; 0, 2; \dots; 1\}$; ii) $\mathcal{K} = \{k | k = 1; 2; \dots; 30\}$; iii) $T = \{\tau | \tau = 1; 2; \dots; 10\}$; e, finalmente, iv) $M = \{m | m = 1; 2; \dots; 10\}$. São apresentados, também, resultados para dois comprimentos de janela de tempo, um e dois segundos, extraídas no período de Imagética Motora (essas janelas foram extraídas meio segundo após a dica visual, algo muito comum na literatura (Tangemann *et al.*, 2012; Ang *et al.*, 2012a)). Esses primeiros resultados referem-se aos parâmetros que produziram melhores índices *kappa*, mostrando o potencial de cada abordagem. Observe que todo esse processo de análise paramétrica poderia ser aplicado para adaptar cada uma dessas abordagens a um indivíduo específico.

Cabe ressaltar que a varredura do espaço paramétrico tem alto custo computacional e, além disso, não se enquadra em cenários práticos de BCI uma vez que ocorrem variações no comportamento dos sinais de controle ao longo do tempo (e.g. devido à adaptação do indivíduo ao sistema de BCI). A fim de automatizar esse processo em etapa futura, avaliou-se a sensibilidade dos métodos de extração de características em relação aos limiares de correlação Θ utilizados pela ICA. Em seguida foram utilizadas as abordagens de Kennel *et al.* (1992) e Fraser & Swinney (1986) para a estimação automática dos parâmetros m e τ utilizados pelo Teorema de Imersão de Takens (Takens, 1981), exigidos por

CSSP, FBCSSP, CSSSP e FBCSSSP. A partir dessa automatização, torna-se viável, dada a redução do custo computacional, o emprego da validação cruzada de 10 *folds* para avaliar variações nos índices *kappa* e, portanto, permitir uma melhor análise sobre a capacidade de generalização desses extratores.

Este capítulo é dividido nas seguintes seções: i, ii e iii) resultados para a primeira abordagem experimental a fim de avaliar os métodos de extração de características; iv) análise da sensibilidade das técnicas de extração de características em relação aos limiares de correlação Θ utilizados para a remoção de artefatos na aplicação de ICA; e, finalmente, v) abordagem para a seleção automática de parâmetros e os resultados da validação cruzada de 10 *folds*.

4.2 Árvore Diádica de Bandas de Frequências

A técnica de Árvore Diádica de Bandas de Frequências (ADBF) visa encontrar sub-bandas de frequências que produzam informações mais significativas para as ondas μ e β (maiores detalhes sobre esses sinais de controle cerebrais na Capítulo 1) para a classificação de Imagética Motora. São apresentados na Tabela 4.1, os resultados obtidos a partir de experimentos efetuados por meio da abordagem descrita na Seção 3.3.1, em que foi utilizada uma árvore com altura igual a cinco, produzida a partir dos sinais filtrados no intervalo de [4; 40] Hz (que abrangem as ondas μ e β). Note que, na Tabela 4.1, são apresentados índices *kappa* calculados utilizando as três primeiras sessões de EEG, 1T, 2T e 3T, para treinamento e as duas últimas, 4E e 5E, para teste, tal como realizado na avaliação conduzida pela *BCI Competition IV-2b*. Além disso é considerado os índices *kappa* referentes ao uso de janelas de um e dois segundos, respectivamente.

Como não são verificadas as distribuições dos índices *kappa* para cada indivíduo, mas apenas valores singulares, o teste estatístico de avaliação de hipóteses de Wilcoxon (Wilcoxon, 1945) foi escolhido para efetuar a comparação entre as diferentes técnicas de maneira mais justa, evitando a influência das altas variações dos resultados entre voluntários. Aplicando-se esse teste de forma bilateral com confiança estatística de 0,95 sobre os maiores índices *kappa* apresentados (p-valor igual a 0,83), é possível concluir que não há diferença significativa entre utilizar uma janela temporal de um ou dois segundos. Contudo, em casos isolados, tal como o do indivíduo 8, a diferença entre os índices *kappa* é bas-

Tabela 4.1: Índices *kappa* de Cohen no uso da técnica ADBF em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,12	0,20	0,22	0,14	0,16	0,16	0,20	0,42	0,21	0,20	0,09
0,2	0,07	0,16	0,22	0,26	0,06	0,16	0,25	0,45	0,37	0,22	0,13
0,3	0,31	0,17	0,30	0,34	0,24	0,20	0,31	0,45	0,31	0,29	0,08
0,4	0,25	0,25	0,32	0,39	0,13	0,31	0,39	0,52	0,41	0,33	0,11
0,5	0,36	0,27	0,38	0,50	0,13	0,38	0,44	0,53	0,42	0,38	0,12
0,6	0,43	0,25	0,42	0,55	0,24	0,39	0,44	0,53	0,50	0,42	0,11
0,7	0,26	0,22	0,43	0,48	0,22	0,32	0,50	0,52	0,45	0,38	0,12
0,8	0,24	0,13	0,28	0,49	0,24	0,31	0,21	0,55	0,51	0,33	0,15
0,9	0,05	0,13	0,32	0,50	0,11	0,25	0,19	0,58	0,36	0,28	0,18
1	0,11	0,03	0,47	0,55	0,23	0,22	0,12	0,70	0,50	0,33	0,23
Max	0,43	0,27	0,47	0,55	0,24	0,39	0,50	0,70	0,51	0,45	0,14

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,09	0,08	0,11	0,25	0,19	0,12	0,12	0,35	0,16	0,16	0,09
0,2	0,04	0,17	0,19	0,42	0,13	0,22	0,24	0,46	0,33	0,24	0,14
0,3	0,17	0,23	0,26	0,45	0,21	0,29	0,37	0,46	0,26	0,30	0,10
0,4	0,35	0,22	0,34	0,43	0,17	0,17	0,30	0,53	0,42	0,33	0,12
0,5	0,30	0,24	0,27	0,49	0,29	0,34	0,39	0,61	0,51	0,38	0,13
0,6	0,45	0,35	0,42	0,50	0,31	0,26	0,44	0,66	0,50	0,43	0,12
0,7	0,31	0,33	0,34	0,38	0,29	0,33	0,39	0,60	0,41	0,38	0,09
0,8	0,10	0,17	0,39	0,34	0,19	0,25	0,30	0,64	0,47	0,32	0,17
0,9	0,10	0,17	0,30	0,47	0,15	0,28	0,11	0,70	0,48	0,31	0,21
1	0,14	0,03	0,50	0,51	0,10	0,39	0,09	0,83	0,59	0,35	0,28
Max	0,45	0,35	0,50	0,51	0,31	0,39	0,44	0,83	0,59	0,49	0,15

tante significativa. Outro aspecto a ser salientado é que a remoção de artefatos melhora a qualidade dos dados apenas para determinados indivíduos.

A ADBF não considera a melhoria na qualidade das informações espaciais e nem das temporais, produzindo, portanto, menores índices *kappa* quando comparada às técnicas do estado da arte. Na próxima seção são apresentados os resultados experimentais para a técnica CSP, que visa otimizar características espaciais.

4.3 Padrões Espaciais

A técnica de Padrões Espaciais Comuns (CSP) visa otimizar simultaneamente variâncias dos sinais de diferentes classes produzidos pelos canais de EEG, produzindo, assim, melhores informações topográficas dos sinais de controle. Experimentos foram realizados para avaliar o desempenho da CSP, em termos de classificação, a fim de compará-la ao estado da arte e às demais abordagens empregadas neste trabalho. Os resultados dos índices *kappa* calculados a partir do uso de janelas de um e dois segundos são apresentados na Tabela 4.2.

Tabela 4.2: Índices *kappa* de Cohen no uso da técnica CSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,11	0,08	0,12	0,20	0,12	0,07	0,28	0,21	0,16	0,15	0,07
0,2	0,14	0,09	0,33	0,32	0,27	0,10	0,25	0,24	0,08	0,20	0,10
0,3	0,05	0,09	0,31	0,32	0,27	0,24	0,22	0,17	0,15	0,20	0,09
0,4	0,18	0,12	0,22	0,30	0,32	0,22	0,27	0,37	0,22	0,25	0,08
0,5	0,20	0,18	0,30	0,34	0,24	0,26	0,37	0,20	0,31	0,27	0,07
0,6	0,28	0,27	0,41	0,39	0,21	0,28	0,39	0,31	0,32	0,32	0,07
0,7	0,31	0,26	0,39	0,41	0,41	0,30	0,40	0,28	0,40	0,35	0,06
0,8	0,01	0,13	0,24	0,30	0,31	0,21	0,45	0,42	0,28	0,26	0,14
0,9	-0,02	0,13	0,27	0,36	0,41	0,22	0,72	0,32	0,19	0,29	0,21
1	0,05	0,12	0,38	0,28	0,50	-0,09	0,60	0,42	0,24	0,28	0,22
Max	0,31	0,27	0,41	0,41	0,50	0,30	0,72	0,42	0,40	0,42	0,14

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,12	0,04	0,29	0,14	0,19	0,09	0,15	0,27	0,09	0,15	0,07
0,2	0,09	0,15	0,21	0,21	0,25	0,18	0,29	0,26	0,22	0,21	0,10
0,3	0,12	0,14	0,17	0,26	0,14	0,07	0,35	0,24	0,17	0,18	0,09
0,4	0,29	0,17	0,26	0,16	0,35	0,19	0,28	0,40	0,23	0,26	0,08
0,5	0,26	0,23	0,34	0,36	0,25	0,29	0,22	0,33	0,31	0,29	0,07
0,6	0,28	0,23	0,33	0,42	0,31	0,25	0,49	0,38	0,41	0,34	0,07
0,7	0,30	0,17	0,48	0,27	0,38	0,26	0,47	0,39	0,26	0,33	0,06
0,8	0,05	0,14	0,37	0,38	0,38	0,18	0,45	0,40	0,30	0,29	0,14
0,9	0,17	0,17	0,27	0,28	0,28	0,20	0,52	0,50	0,36	0,31	0,21
1	0,08	0,10	0,34	0,26	0,37	-0,01	0,43	0,76	0,41	0,30	0,22
Max	0,30	0,23	0,48	0,42	0,38	0,29	0,52	0,76	0,41	0,42	0,14

Aplicando-se o teste Wilcoxon bilateral com confiança estatística de 0,95 sobre os dois

tamanhos de janela, conclui-se que não há diferença significativa entre os resultados apresentados (p-valor igual a 0,94). Além disso, rejeita-se a hipótese de que os resultados produzidos pela técnica CSP e pela ADBF sejam diferentes (p-valor igual a 0,57).

No caso da técnica de Padrões Espectro-Espaciais Comuns (CSSP), uma extensão da CSP, os experimentos foram executados variando-se as coordenadas de atraso τ empregadas pelo Teorema de Imersão de Takens (Takens, 1981), variando esse parâmetro de uma a dez unidades de tempo e selecionando a que produziu melhores resultados. Essa técnica, cujos resultados são apresentados na Tabela 4.3, produz melhores índices κ do que a CSP e a ADBF já que, por meio do teste de Wilcoxon unilateral, foram obtidos p-valores iguais a 0,007 e 0,015 respectivamente, destacando significância estatística. Ademais, não há melhorias relevantes quando utilizada a janela de dois segundos para o CSSP (p-valor de 0,66 por meio do teste de Wilcoxon bilateral).

No caso da técnica de Padrões Esparsos Espectro-Espaciais Comuns (CSSSP), os resultados apresentados na Tabela 4.4 são os melhores produzidos dentro do conjunto de parâmetros $\tau = [1; 10]$ e $m = [3; 10]$, aplicados no Teorema de Imersão (Takens, 1981). CSSSP é significativamente melhor que a CSSP, CSP e ADBF (p-valores de, respectivamente, 0,03, 0,01 e 0,007), contudo não há melhoria significativa quando utilizada a janela de dois segundos.

Na próxima seção são apresentados os resultados experimentais para as técnicas de padrões espaciais (CSP, CSSP e CSSSP) aplicadas em conjunto com banco de filtros (maiores detalhes no Capítulo 3).

4.4 Padrões Espaciais com Banco de Filtros

A técnica de CSP com banco de filtros (FBCSP) visa, a partir da segmentação dos sinais produzidos por EEG em diferentes bandas de frequência, encontrar relações lineares espectro-espaciais que otimizem, simultaneamente, a variação dos sinais de controle associados às duas classes de Imagética Motora (mão esquerda e direita). Dessa forma, o FBCSP visa encontrar projeções relevantes dentro de um espaço determinado por relações entre os canais de EEG e frequências dos sinais.

Os resultados dos experimentos, apresentados pela Tabela 4.5, apontam uma melhoria significativa em relação à técnica CSP (p-valor igual a 0,04) se aplicados ao teste de Wilcoxon unilateral com confiança igual a 0,95. Porém, para as demais técnicas, ADBF, CSSP

Tabela 4.3: Índices *kappa* de Cohen no uso da técnica CSSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,18	0,14	0,23	0,28	0,22	0,20	0,38	0,28	0,25	0,24	0,07
0,2	0,13	0,19	0,30	0,36	0,29	0,26	0,34	0,31	0,21	0,27	0,10
0,3	0,28	0,18	0,34	0,37	0,23	0,30	0,37	0,35	0,30	0,30	0,09
0,4	0,23	0,37	0,43	0,39	0,38	0,37	0,43	0,56	0,43	0,40	0,08
0,5	0,36	0,26	0,42	0,41	0,29	0,35	0,47	0,42	0,47	0,38	0,07
0,6	0,46	0,30	0,43	0,51	0,44	0,38	0,47	0,43	0,45	0,43	0,07
0,7	0,34	0,27	0,45	0,50	0,46	0,50	0,59	0,46	0,49	0,45	0,06
0,8	0,23	0,32	0,33	0,60	0,36	0,39	0,62	0,40	0,44	0,41	0,14
0,9	0,27	0,29	0,34	0,66	0,37	0,38	0,78	0,58	0,41	0,45	0,21
1	0,43	0,39	0,48	0,81	0,37	0,46	0,77	0,60	0,56	0,54	0,22
Max	0,46	0,39	0,48	0,81	0,46	0,50	0,78	0,60	0,56	0,56	0,14

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,26	0,19	0,33	0,23	0,20	0,23	0,30	0,36	0,19	0,25	0,06
0,2	0,22	0,15	0,32	0,29	0,23	0,32	0,34	0,49	0,31	0,3	0,10
0,3	0,25	0,18	0,35	0,31	0,22	0,18	0,45	0,31	0,38	0,29	0,09
0,4	0,42	0,30	0,41	0,30	0,36	0,35	0,48	0,46	0,41	0,39	0,06
0,5	0,37	0,29	0,49	0,45	0,38	0,45	0,43	0,63	0,41	0,43	0,09
0,6	0,41	0,26	0,46	0,56	0,50	0,40	0,64	0,57	0,53	0,48	0,11
0,7	0,40	0,19	0,48	0,49	0,45	0,42	0,53	0,47	0,45	0,43	0,10
0,8	0,25	0,19	0,48	0,62	0,47	0,32	0,62	0,51	0,53	0,44	0,16
0,9	0,19	0,26	0,38	0,72	0,36	0,31	0,70	0,61	0,49	0,45	0,19
1	0,36	0,27	0,44	0,88	0,47	0,53	0,67	0,83	0,60	0,56	0,21
Max	0,42	0,30	0,49	0,88	0,50	0,53	0,70	0,83	0,60	0,58	0,19

e CSSSP, o teste de Wilcoxon bilateral resulta nos respectivos p-valores, 0,07, 0,14 e 0,004 os quais indicam que FBCSP tem desempenho estatisticamente similar em relação à ADBF e CSSP e produzem índices *kappa* inferiores aos do CSSSP (p-valor 0,002 no teste de Wilcoxon unilateral). Cabe ainda ressaltar que o teste de Wilcoxon bilateral não aponta diferença significativa no uso de janelas de um ou dois segundos.

A técnica FBCSP não considera dependência temporal entre sinais de diferentes canais e bandas de frequências, o que motiva o uso da técnica de CSSP com banco de filtros (FBCSSP) para melhorar a discriminação dos sinais de controle. A Tabela 4.6 apresenta os melhores índices *kappa* produzidos pelo FBCSSP, que constrói apenas espaços imersos (Takens, 1981) de dimensão $m = 2$, dentro de um intervalo paramétrico $\tau = [1; 10]$ (maiores

Tabela 4.4: Índices *kappa* de Cohen no uso da técnica CSSSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,20	0,21	0,32	0,41	0,21	0,27	0,40	0,47	0,23	0,30	0,10
0,2	0,16	0,22	0,35	0,43	0,29	0,28	0,48	0,46	0,29	0,33	0,11
0,3	0,30	0,26	0,40	0,44	0,29	0,39	0,40	0,51	0,34	0,37	0,08
0,4	0,32	0,31	0,49	0,48	0,37	0,43	0,51	0,56	0,46	0,44	0,09
0,5	0,36	0,36	0,43	0,52	0,39	0,39	0,54	0,55	0,47	0,45	0,08
0,6	0,51	0,37	0,47	0,59	0,50	0,42	0,64	0,58	0,52	0,51	0,08
0,7	0,42	0,27	0,53	0,62	0,50	0,52	0,65	0,56	0,51	0,51	0,11
0,8	0,36	0,35	0,44	0,67	0,39	0,46	0,64	0,49	0,53	0,48	0,11
0,9	0,44	0,36	0,51	0,77	0,41	0,47	0,72	0,72	0,45	0,54	0,15
1	0,61	0,39	0,59	0,90	0,41	0,54	0,83	0,82	0,61	0,63	0,18
Max	0,61	0,39	0,59	0,90	0,50	0,54	0,83	0,82	0,61	0,64	0,17

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,26	0,17	0,41	0,39	0,26	0,22	0,35	0,52	0,28	0,32	0,11
0,2	0,27	0,25	0,44	0,43	0,28	0,35	0,40	0,54	0,36	0,37	0,09
0,3	0,30	0,25	0,44	0,44	0,26	0,26	0,48	0,43	0,34	0,36	0,09
0,4	0,41	0,29	0,61	0,45	0,42	0,43	0,49	0,54	0,45	0,45	0,09
0,5	0,46	0,38	0,55	0,57	0,43	0,48	0,58	0,63	0,44	0,50	0,08
0,6	0,48	0,38	0,51	0,63	0,54	0,42	0,70	0,63	0,52	0,53	0,11
0,7	0,44	0,27	0,55	0,67	0,51	0,55	0,63	0,63	0,55	0,53	0,12
0,8	0,36	0,28	0,58	0,76	0,50	0,55	0,69	0,55	0,57	0,54	0,15
0,9	0,34	0,34	0,44	0,80	0,44	0,54	0,70	0,69	0,65	0,55	0,17
1	0,47	0,41	0,68	0,97	0,54	0,74	0,81	0,88	0,71	0,69	0,19
Max	0,48	0,41	0,68	0,97	0,54	0,74	0,81	0,88	0,71	0,69	0,19

detalhes na Seção 3.3.2).

A partir do teste de Wilcoxon unilateral, com confiança de 0,95, infere-se que o FBCSSP apresenta melhor desempenho para o índice *kappa* em relação às técnicas ADBF (p-valor = 0,002), CSP (p-valor = 0,004), e FBCSP (p-valor = 0,007), além disso, pode-se afirmar que seus resultados são piores que os produzidos pelo CSSSP (p-valor = 0,01) e equiparáveis aos produzidos pelo CSSP (p-valor = 0,14 para o teste bilateral), segundo um teste unilateral de Wilcoxon. Deve-se ressaltar que não há mudanças significativas para os índices *kappa* quando avaliados sobre as janelas temporais distintas (p-valor = 0,69 para o teste bilateral).

Os resultados sobre o melhor cenário possível são apresentados na Tabela 4.7, i.e., os maiores índices *kappa* produzidos pela técnica FBCSSSP dentro de um intervalo paramé-

Tabela 4.5: Índices *kappa* de Cohen no uso da técnica FBCSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,13	0,06	0,17	0,13	0,10	0,07	0,27	0,25	0,20	0,15	0,08
0,2	0,21	0,17	0,28	0,24	0,16	0,13	0,33	0,40	0,26	0,24	0,09
0,3	0,11	0,14	0,33	0,39	0,29	0,18	0,30	0,18	0,43	0,26	0,11
0,4	0,27	0,17	0,42	0,48	0,25	0,35	0,49	0,35	0,32	0,34	0,11
0,5	0,37	0,27	0,40	0,44	0,31	0,25	0,37	0,38	0,26	0,34	0,07
0,6	0,52	0,31	0,34	0,47	0,36	0,34	0,53	0,52	0,45	0,43	0,09
0,7	0,42	0,20	0,27	0,49	0,40	0,40	0,59	0,46	0,37	0,40	0,12
0,8	0,25	0,18	0,38	0,41	0,38	0,35	0,48	0,45	0,32	0,36	0,09
0,9	0,10	0,30	0,43	0,41	0,42	0,20	0,68	0,39	0,28	0,36	0,16
1	0,22	0,35	0,53	0,50	0,26	0,23	0,65	0,45	0,36	0,39	0,15
Max	0,52	0,35	0,53	0,50	0,42	0,40	0,68	0,52	0,45	0,49	0,10

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,15	0,05	0,29	0,15	0,10	0,11	0,28	0,26	0,09	0,16	0,09
0,2	0,22	0,11	0,35	0,31	0,18	0,10	0,37	0,27	0,26	0,24	0,10
0,3	0,23	0,13	0,35	0,39	0,17	0,23	0,32	0,23	0,39	0,27	0,09
0,4	0,37	-0,01	0,44	0,35	0,25	0,27	0,28	0,35	0,26	0,28	0,13
0,5	0,35	0,23	0,38	0,52	0,17	0,29	0,36	0,34	0,32	0,33	0,10
0,6	0,53	0,25	0,40	0,41	0,42	0,33	0,50	0,52	0,47	0,43	0,09
0,7	0,42	0,18	0,45	0,45	0,45	0,32	0,43	0,44	0,37	0,39	0,09
0,8	0,18	0,18	0,39	0,52	0,31	0,29	0,37	0,32	0,33	0,32	0,10
0,9	0,10	0,27	0,41	0,46	0,37	0,21	0,62	0,61	0,41	0,38	0,17
1	0,11	0,28	0,40	0,67	0,30	0,56	0,66	0,70	0,54	0,47	0,21
Max	0,53	0,28	0,45	0,67	0,45	0,56	0,66	0,70	0,54	0,54	0,13

trico para o emprego do Teorema de Imersão (Takens, 1981) em que $m = [3; 10]$ e $\tau = [1; 10]$. Essa técnica consiste na generalização do FBCSSP considerando, não um espaço fase de dimensão embutida $m = 2$, mas um que permita o desdobramento dos dados temporais em número maior de dimensões a fim de encontrar recorrências nos sinais cerebrais (de Mello & Yang, 2009).

A partir do teste de Wilcoxon unilateral, nota-se que há melhoria significativa nos resultados quando o FBCSSSP é comparado às demais técnicas, exceto em relação à CSSSP. Esses p-valores associados aos testes entre o FBCSSSP e a ADBF, o CSP, o CSSP, o FBCSP e o FBCSSP são, respectivamente, 0,002, 0,006, 0,004, 0,005 e 0,007, já o associado ao teste bilateral entre FBCSSSP e o CSSSP é igual a 0,879. Avaliando-se o desempenho do método

Tabela 4.6: Índices *kappa* de Cohen no uso da técnica FBCSSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,19	0,12	0,28	0,26	0,22	0,10	0,37	0,36	0,24	0,24	0,09
0,2	0,23	0,25	0,35	0,33	0,31	0,18	0,45	0,37	0,30	0,31	0,08
0,3	0,20	0,21	0,33	0,46	0,30	0,27	0,43	0,28	0,42	0,32	0,10
0,4	0,33	0,15	0,47	0,43	0,31	0,39	0,52	0,41	0,39	0,38	0,11
0,5	0,46	0,33	0,53	0,55	0,39	0,36	0,58	0,53	0,33	0,45	0,10
0,6	0,60	0,32	0,39	0,54	0,43	0,38	0,59	0,62	0,57	0,49	0,11
0,7	0,50	0,27	0,34	0,56	0,43	0,46	0,62	0,59	0,45	0,47	0,11
0,8	0,36	0,32	0,46	0,62	0,43	0,40	0,66	0,56	0,46	0,47	0,12
0,9	0,34	0,38	0,47	0,61	0,41	0,33	0,62	0,56	0,46	0,46	0,11
1	0,52	0,35	0,62	0,81	0,42	0,52	0,78	0,57	0,46	0,56	0,15
Max	0,60	0,38	0,62	0,81	0,43	0,52	0,78	0,62	0,57	0,59	0,14

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,23	0,16	0,32	0,22	0,18	0,20	0,35	0,32	0,22	0,24	0,07
0,2	0,25	0,21	0,36	0,35	0,25	0,17	0,46	0,46	0,34	0,32	0,10
0,3	0,26	0,18	0,38	0,48	0,27	0,20	0,36	0,36	0,44	0,33	0,10
0,4	0,35	0,14	0,54	0,45	0,35	0,39	0,45	0,44	0,37	0,39	0,11
0,5	0,44	0,23	0,60	0,55	0,38	0,43	0,55	0,46	0,38	0,45	0,11
0,6	0,56	0,28	0,47	0,57	0,44	0,40	0,66	0,63	0,58	0,51	0,12
0,7	0,49	0,28	0,50	0,61	0,45	0,48	0,63	0,59	0,44	0,50	0,11
0,8	0,28	0,27	0,47	0,71	0,39	0,44	0,56	0,55	0,42	0,45	0,14
0,9	0,33	0,32	0,49	0,69	0,42	0,32	0,67	0,70	0,57	0,50	0,16
1	0,31	0,34	0,53	0,90	0,42	0,58	0,74	0,85	0,64	0,59	0,21
Max	0,56	0,34	0,60	0,90	0,45	0,58	0,74	0,85	0,64	0,63	0,18

em relação às duas janelas utilizadas, têm-se que não há mudança significativa já que o p-valor é igual a 0,54 para o teste de Wilcoxon bilateral com confiança de 0,95.

Para complementar, tal como apresentado na Tabela 4.8, ao se considerar os melhores parâmetros utilizados nas técnicas discutidas anteriormente, o CSSSP e o FBCSSSP atingem resultados equiparáveis aos obtidos por Gaur *et al.* (2015); Saa & Cetin (2012) e Tangermann *et al.* (2012), sendo que este último se refere às abordagens avaliadas na *BCI Competition IV*. Consequentemente, os resultados obtidos são comparáveis aos do estado da arte para o conjunto de dados em questão.

Apesar do CSSSP não ter sido adotado na literatura, há a possibilidade de que ele produza resultados equiparáveis às abordagens do estado da arte. Para complementar, o

Tabela 4.7: Índices *kappa* de Cohen no uso da técnica FBCSSSP em relação ao limiar de correlação utilizado para remoção de artefatos.

Janela de um segundo											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,27	0,20	0,36	0,38	0,25	0,19	0,36	0,44	0,28	0,30	0,09
0,2	0,25	0,23	0,42	0,47	0,28	0,25	0,47	0,44	0,35	0,35	0,10
0,3	0,32	0,23	0,36	0,51	0,33	0,27	0,44	0,35	0,43	0,36	0,09
0,4	0,37	0,19	0,44	0,49	0,34	0,45	0,55	0,44	0,43	0,41	0,10
0,5	0,48	0,36	0,58	0,60	0,43	0,41	0,60	0,54	0,33	0,48	0,10
0,6	0,58	0,36	0,44	0,64	0,44	0,47	0,65	0,63	0,56	0,53	0,11
0,7	0,53	0,36	0,44	0,64	0,48	0,50	0,59	0,62	0,53	0,52	0,09
0,8	0,36	0,35	0,46	0,71	0,43	0,42	0,63	0,66	0,44	0,50	0,13
0,9	0,45	0,45	0,51	0,71	0,47	0,47	0,73	0,66	0,54	0,55	0,11
1	0,65	0,43	0,69	0,90	0,40	0,58	0,80	0,76	0,58	0,64	0,17
Max	0,65	0,45	0,69	0,90	0,48	0,58	0,80	0,76	0,58	0,65	0,15

Janela de dois segundos											
	Voluntários										
θ	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
0,1	0,23	0,19	0,35	0,39	0,24	0,21	0,35	0,42	0,26	0,29	0,08
0,2	0,28	0,22	0,43	0,48	0,27	0,27	0,49	0,44	0,36	0,36	0,10
0,3	0,31	0,21	0,44	0,56	0,30	0,27	0,49	0,41	0,48	0,39	0,12
0,4	0,36	0,22	0,51	0,53	0,39	0,43	0,47	0,55	0,45	0,43	0,10
0,5	0,45	0,30	0,61	0,62	0,42	0,42	0,61	0,54	0,37	0,48	0,12
0,6	0,60	0,30	0,54	0,66	0,46	0,44	0,70	0,68	0,58	0,55	0,13
0,7	0,51	0,34	0,55	0,65	0,45	0,47	0,66	0,60	0,59	0,54	0,10
0,8	0,38	0,40	0,57	0,79	0,39	0,51	0,64	0,67	0,55	0,54	0,14
0,9	0,46	0,42	0,49	0,82	0,39	0,51	0,71	0,75	0,60	0,57	0,16
1	0,51	0,40	0,55	0,97	0,43	0,74	0,84	0,86	0,71	0,67	0,20
Max	0,60	0,42	0,61	0,97	0,46	0,74	0,84	0,86	0,71	0,69	0,18

FBCSSSP e CSSSP apresentam bons índices *kappa* o que se deve ao fato de buscarem representar as dependências temporais do sistema dinâmico gerador do sinal de controle. Essas dependências são desdobradas em um espaço multidimensional denominado espaço fase, por meio do Teorema da Imersão proposto por Takens (1981). Contudo, vale ressaltar que os resultados aqui discutidos consideram o melhor cenário de configuração para os parâmetros de coordenadas de atraso τ e quantidade de dimensões embutidas m para o Teorema de Imersão, características selecionadas e o limiar θ utilizado para a remoção de artefatos de EOG, dada a inspeção de intervalos de valores. Na seção seguinte é abordada uma análise de sensibilidade dada a remoção de Componentes Independentes (IC), de acordo com o valor selecionado para o limiar θ .

Tabela 4.8: Tabela com os índices *kappa* dos métodos considerados estado da arte e os das abordagens consideradas neste trabalho.

Janela de um segundo											
Método Autor	Voluntários									Média	Desvio Padrão
	1	2	3	4	5	6	7	8	9		
ADBF	0,45	0,35	0,50	0,55	0,31	0,39	0,50	0,83	0,59	0,50	0,16
CSP	0,37	0,26	0,40	0,41	0,43	0,34	0,63	0,77	0,42	0,45	0,16
FBCSP	0,53	0,35	0,53	0,67	0,45	0,56	0,68	0,70	0,54	0,56	0,11
CSSP	0,46	0,32	0,58	0,88	0,48	0,51	0,77	0,82	0,58	0,60	0,19
FBCSSP	0,60	0,38	0,62	0,90	0,45	0,58	0,78	0,85	0,64	0,64	0,17
CSSSP	0,59	0,42	0,59	0,97	0,50	0,74	0,83	0,89	0,73	0,70	0,18
FBCSSSP	0,65	0,45	0,69	0,97	0,48	0,74	0,84	0,86	0,71	0,71	0,17
Chin ¹	0,40	0,21	0,22	0,95	0,86	0,61	0,56	0,85	0,74	0,60	0,28
Gaur ²	0,26	0,36	0,96	0,76	0,94	0,52	0,46	0,76	0,70	0,62	0,25
Saa ³	0,60	0,32	0,06	0,97	0,87	0,78	0,63	0,88	0,81	0,66	0,30

¹ Zheng Yang Chin, ² Gaur *et al.* (2015) e ³ Saa & Cetin (2012).

4.5 Remoção de Artefatos

O limiar de correlação θ , utilizado para definir quais Componentes Independentes (ICs) são desconsiderados na etapa de composição dos novos sinais pela técnica ICA (Seção 3.2.2), produz grandes influências nos índices *kappa* dos indivíduos. Esta seção avalia a sensibilidade dos resultados anteriores em função de θ , considerando a busca por um valor ideal para este parâmetro independentemente do indivíduo alvo. Isso se faz interessante e necessário para casos em que o sistema de BCI não possa contar com uma etapa prévia de reconfiguração específica para atender um indivíduo.

Uma vez escolhido o limiar θ globalmente mais adequado para os nove indivíduos em estudo, decidiu-se por normalizar os índices *kappa* de cada indivíduo em função de seu maior valor, o que permite avaliar as variações que cada extrator de características produz. A Equação 4.1 é utilizada na etapa de normalização dos índices *kappa* de um indivíduo, em que i é o índice do indivíduo, κ_i corresponde ao vetor de índices *kappa* para cada valor de correlação θ e $\mathbf{v}_i$ representa os resultados normalizados.

$$\mathbf{v}_i = \frac{\kappa_i}{\max(\kappa_i)} \quad (4.1)$$

Posteriormente, calculou-se a média dos valores $\mathbf{v}_i$ para todos os indivíduos dado um parâmetro θ fixo, o que permitiu medir a influência da remoção de artefatos proveniente

da escolha de θ (resultados apresentados na Figura 4.1).

Figura 4.1: Gráficos dos índices *kappa* Normalizados Médios vs. limiar de correlação para remoção de artefatos. Esses dados foram produzidos a partir da aplicação dos métodos das abordagens avaliadas sobre janelas de a) um segundo e b) dois segundos extraídos dos períodos de Imagética Motora.

Nota-se que a remoção de ICs relacionados aos canais de EOG melhora o desempenho geral apenas para as técnicas ADBF e CSP, enquanto que as demais produzem melhores resultados quando nenhum IC é eliminado. Logo, o pré-processamento aparenta excluir componentes relevantes para a classificação. Deve-se ressaltar que as técnicas baseadas no CSSP e CSSSP (incluindo FBCSSP e FBCSSSP) operam sobre os canais de EOG para, automaticamente, remover suas influências indesejadas por meio de um modelo autorregressivo. Logo, não se faz necessário o emprego de ICA como etapa de pré-processamento.

Esta seção apresentou uma análise de sensibilidade para o parâmetro θ , cabe, em seguida, uma análise sobre a estimação automática dos parâmetros de imersão (m e τ) para que se possa, também, pré-configurar o sistema de BCI para qualquer indivíduo. Uma vez que os melhores resultados são os provenientes das técnicas baseadas em CSSP e CSSSP, as quais não necessitam de pré-processamento para remoção de artefatos, decidiu-se por não utilizar a técnica ICA na etapa em questão. Posteriormente, a seção seguinte também

aborda uma análise de convergência para o parâmetro k , o qual define o número de atributos a ser adotado pela técnica de Seleção de Características baseadas em Informação Mútua (MIFS).

4.6 Busca Automática por Parâmetros

Os experimentos anteriores empregaram a varredura completa de parâmetros a qual exige processamento intensivo de dados ao configurar as técnicas de extração e seleção de características. Mais precisamente, o cálculo de autovetores generalizados implementado pela função `DGGEV` do pacote `LAPACK` (Blackford, 1999), utilizado neste trabalho para produzir os filtros espaciais e espaço-temporais (CSP, CSSP e CSSSP), apresenta complexidade computacional de $\mathcal{O}(D^3)$ em que D é a dimensionalidade do conjunto de dados explorado $\mathbf{Z}_e$ (maiores detalhes na Seção 3.3.2). Cabe ressaltar que $\mathbf{Z}_e$ é composto pelos sinais dos canais de EEG e EOG, $c \in C$, imersos em $m = 2$ dimensões no caso do CSSP e $m > 2$ no caso do CSSSP e, portanto, $D = |C|m$ (como o CSP não emprega o Teorema de Imersão (Takens, 1981), é considerado $m = 1$ nesse caso). Assim, o cálculo dos autovetores generalizados para todo um espaço paramétrico composto por $M = \{m|m = 1; 2; \dots; 10\}$ e $T = \{\tau|\tau = 1; 2; \dots; 10\}$ apresenta complexidade de $\mathcal{O}(|C|^3|T|\sigma(M, 3))$ em que $\sigma(\mathcal{U}, a) = \sum_{u \in \mathcal{U}} u^a$. Em complemento, ao se decompor os sinais produzidos pelos canais de EEG e EOG em sub-bandas de frequência B por meio de banco de filtros, a complexidade assintótica da otimização efetuada pelo CSP, CSSP e CSSSP é de $\mathcal{O}(|C_b|^3|T|\sigma(M, 3))$ em que C_b são as sub-bandas extraídas a partir de todos os canais de EEG e EOG, e tem cardinalidade de $|C_b| = |C||B|$.

Contudo, os trabalhos de Fraser & Swinney (1986) e Kennel *et al.* (1992) definem meios de se estimar as coordenadas de atraso τ e m que melhor representam a imersão temporal de uma série. Neste contexto, é possível evitar a varredura completa do espaço paramétrico para CSSP, CSSSP, FBCSSP e FBCSSSP, atenuando, conseqüentemente, a complexidade assintótica do algoritmo (que será de $\mathcal{O}(|C|^3m^3)$).

Então, é empregada neste trabalho, a estimação de coordenadas de atraso τ_{c_j} para os sinais de cada canal c_j por meio da técnica de Auto-Informação Mútua (Fraser & Swinney, 1986), definida pela Equação 4.2, em que $z(t)$ representa uma série temporal e $z_\tau(t)$, a mesma série temporal com atraso τ . Essa técnica permite encontrar um valor adequado

para a coordenada de atraso τ , segundo um critério de recorrência temporal dos dados. Mais precisamente, essa equação calcula o ganho de informação que a série $z(t)$, quando dada como entrada, provê em relação a um tempo futuro τ . Seleciona-se, tipicamente, o instante de tempo τ referente ao primeiro mínimo de $\{AMI(z(t), z_\tau(t)) : \tau = [1, \tau_f]\}$ como coordenada de atraso. Isso se deve ao fato de que esse mínimo oferece o primeiro menor ganho de informação, o qual auxilia a desdobrar de maneira mais adequada os dados no espaço fase (Fraser & Swinney, 1986), segundo o Teorema de Imersão proposto por Takens (1981). Caso não haja um primeiro mínimo bem destacado, a literatura sugere o uso do atraso $\tau = 1$ (de Mello, 2009).

$$AMI(z, z_\tau) = \int_z \int_{z_\tau} p(z, z_\tau) \log_2 \frac{p(z, z_\tau)}{p(z, z_\tau)} dz dz_\tau \quad (4.2)$$

Neste trabalho, estima-se um valor para a coordenada de atraso τ_{c_j} mais adequado para a representação dos sinais cerebrais extraídos, i.e., para cada canal $c_j \in C$ no período da Imagética Motora. Cabe ressaltar que as séries temporais (i.e., sinais de controle) contidas nos diferentes ensaios $e \in E$ tem comportamentos distintos e, portanto, produzem diferentes imersões temporais (Takens, 1981). Logo, obtém-se τ_{c_j} por meio de uma função mediana ϕ aplicada aos valores de coordenadas de atraso de forma que $\tau_{c_j} = \phi(\{\tau_{c_j}^e \mid \forall e \in E\})$, i.e., para cada canal c_j ao longo de todos os ensaios e . Essa abordagem, ilustrada na Figura 4.2, é utilizada para que uma mesma coordenada de atraso seja empregada para um canal ao longo do tempo. A justificativa para isso é que ao alterar esse parâmetro novas imersões seriam produzidas, tornando o espaço fase obtido em um instante t inconsistente com seu passado.

Em complemento, é necessário saber quantos estados passados são necessários para se produzir uma boa representação para um estado futuro de cada canal c , ou seja, quantas são as dimensões do espaço fase obtido após o emprego do Teorema de Imersão (Takens, 1981). Este parâmetro define a dimensão embutida m necessária para desdobrar relações temporais entre observações de um sistema dinâmico (observe que cada canal c é visto como um conjunto de observações produzido por um sistema dinâmico). Para isso, utiliza-se, tipicamente, a técnica de Falsos Vizinhos mais Próximos (do inglês *False Nearest Neighbors* – FNN), a qual permite estimar a estabilidade dos pontos em um espaço fase dado o aumento de sua dimensionalidade (Kennel *et al.*, 1992). Assim, após a estimação

Figura 4.2: Fluxo de dados para estimar as coordenadas de atraso dos sinais de controle produzidos em cada canal c_j .

das coordenadas de atraso $\tau_c \forall c \in C$, a FNN é utilizada para encontrar o número de dimensões embutidas m_c mais adequado para desdobrar os sinais de cada canal c . Esse desdobramento busca evidenciar relações de recorrência existentes nos sinais de controle (ondas μ e β) contidos nesses canais considerando suas coordenadas de atraso τ_c .

Como os canais $c_1^e, \dots, c_r^e$ contidos em cada ensaio $e \in E$, i.e., $e = \{c_1^e, \dots, c_r^e\}$, podem produzir espaços fase com diferentes números de dimensões embutidas m , i.e., $m_{c_j}^e = \mathcal{FNN}(c_j^e, \tau_{c_j}) \neq m_{c_j}^{e'} = \mathcal{FNN}(c_j^{e'}, \tau_{c_j})$, após o emprego da técnica FNN, um valor único m_{c_j} ao longo de todos os ensaios e deve ser encontrado a fim de manter, assim como para as coordenadas de atraso, a consistência das imersões obtidas. Caso contrário, ao variar o número de dimensões embutidas (ou eixos do espaço fase), o número de características (representadas em cada dimensão) pode variar ao longo do tempo. Esse parâmetro m_{c_j} é definido como a mediana do número de dimensões embutidas ao fixar um canal c_j e variar para todo ensaio e na forma $m_{c_j} = \phi(\{m_{c_j}^e \forall e \in E\})$ (todo esse processo é ilustrado na Figura 4.3).

Posteriormente, cada novo ensaio recebido pelo sistema de BCI deve ser imerso, utilizando o conjunto de parâmetros $\mathcal{T} = \{\tau_{c_j} \forall j\}$ e $\mathcal{M} = \{m_{c_j} \forall j\}$. Cabe ressaltar que, quando utilizadas as técnicas CSSP e CSSSP, estima-se τ_{c_j} e m_{c_j} para cada canal físico c_j de EEG e EOG (cada canal físico se refere às observações produzidas para cada eletrodo), porém, ao se utilizar um banco de filtros em conjunto com tais técnicas, cada sub-banda

de frequência é considerada como um novo canal resultante c_j de forma que τ_{c_j} e m_{c_j} são então calculados para cada uma dessas sub-bandas.

Figura 4.3: Fluxo de dados para estimar o número de dimensões embutidas dos sinais de controle produzidos em cada canal c_j .

Por meio dessa abordagem de estimação automática das coordenadas de atraso e dimensões embutidas, reduz-se o custo computacional despendido na etapa de configuração desses parâmetros para um indivíduo específico. Essa redução permitiu a realização de experimentos adicionais utilizando a técnica de validação cruzada de 10 *folds* (Kohavi, 1995), levando em consideração o ganho de informação que cada dimensão selecionada pelo MIFS (a partir do espaço fase obtido) produz, bem como a capacidade de generalização do algoritmo de classificação SVM ao operar sobre os dados produzidos pelos extratores de características.

Como exemplificado na Figura 4.4, os resultados dos índices *kappa* indicam a possibilidade de definir um critério de parada para o algoritmo MIFS em função da convergência do ganho de informação. Neste trabalho, essa convergência é detectada quando a diferença absoluta entre o ganho de informação produzido após a adição de uma nova dimensão atinge um limiar menor que 1×10^{-5} . Cabe ressaltar que os experimentos apresentados a seguir foram efetuados a partir das abordagens de estimação de parâmetros: i) m_{c_j} para a dimensão embutida para cada canal c_j ; ii) τ_{c_j} para a coordenada de atraso de cada canal c_j ; e, finalmente, iii) k para definir o número de dimensões do espaço fase selecionadas pelo algoritmo MIFS.

Figura 4.4: Gráfico ilustrando a convergência do ganho de informação, produzido a partir da validação cruzada 10 *fold* executada sobre os sinais de EEG do indivíduo nº 4, utilizando o CSSSP para extração de características e parametrização automática.

Neste contexto, os resultados da validação cruzada de 10 *fold*s são apresentados na Figura 4.5 para cada um dos filtros espaciais e espaço-temporais (CSP, CSSP e CSSSP) e suas respectivas combinações com bancos de filtros FIR. A figura indica que a janela de tempo mais apropriada para o uso de cada método varia entre indivíduos, ressaltando-se que as variações mais significativas nos índices *kappa* são produzidas para o voluntário de número 7, ao se utilizar CSP, para os de número 2, 7 e 9 no caso do CSSP e para os de número 2 e 4 no CSSSP. Para complementar, o uso da janela de dois segundos para o FBCSP e para o FBCSSP produz resultados melhores ou estatisticamente similares quando comparados

ao uso da janela de um segundo, exceto para o indivíduo 7. Já o uso da janela de dois segundos para o FBCSSSP produz melhores índices *kappa* ou equiparáveis ao uso da janela de um segundo, a depender do indivíduo.

Figura 4.5: Gráficos dos índices *kappa* médios / intervalo de confiança vs. indivíduo utilizando Fraser & Swinney (1986) e Kennel *et al.* (1992) para a encontrar coordenadas de atraso e dimensões embutidas para o CSSP, CSSSP, FBCSSP e FBCSSSP. Esses resultados foram produzidos sobre janelas de um segundo e dois segundos extraídos dos períodos de Imagética Motora.

Comparando os extratores de características abordados, cujos resultados são ilustrados na Figura 4.6, aponta-se que o CSSP e o CSSSP produzem melhores resultados que CSP, já que incorporam dependências temporais lineares e, além disso, produzem filtros autorregressivos capazes de mitigar a influência de certos artefatos. Em complemento, FBCSSP

e FBCSSSP produzem resultados melhores ou similares ao FBCSP, exceto para o indivíduo 7 quando utilizada a janela de um segundo e, como apresentado na Figura 4.7, os bancos de filtros incorporados aos padrões espaciais podem melhorar significativamente os resultados para diversos voluntários tendo, portanto, um importante papel na extração de características espectrais de sinais de controle.

Figura 4.6: Gráficos dos índices *kappa* médios / intervalo de confiança vs. indivíduo, utilizando Fraser & Swinney (1986) e Kennel *et al.* (1992) para a estimar coordenadas de atraso e dimensões embutidas para o CSSP, CSSSP, FBCSSP e FBCSSSP. Esses resultados foram produzidos sobre janelas de a) um segundo e b) dois segundos extraídos dos períodos de Imagem Motora.

Considerando a validação cruzada de 10 *folds*, cujos resultados são apresentados nas Figuras 4.8 e 4.9, a parametrização automática produz melhores índices *kappa* apenas

Figura 4.7: Gráficos dos índices *kappa* médios / intervalo de confiança vs. indivíduo utilizando Fraser & Swinney (1986) e Kennel *et al.* (1992) para a estimar as coordenadas de atraso e dimensões embutidas. Esses resultados foram produzidos sobre janelas de a) um segundo e b) dois segundos extraídos dos períodos de Imagética Motora e servem para se verificar que bancos de filtros podem aprimorar as acurácias dos filtros espaciais.

para determinados indivíduos quando comparados à varredura de todo o espaço paramétrico, tal como abordado nas Seções 4.2, 4.3 e 4.4. Sob uma perspectiva estatística, o uso da abordagem automática para a estimação das coordenadas de atraso, dimensões embutidas e dimensões selecionadas pelo algoritmo MIFS é justificável uma vez que reduz o custo computacional da configuração dos extratores e da seleção de características.

Contudo, utilizando a mesma abordagem experimental da literatura, a Tabela 4.9 indica que essa parametrização automática produz resultados inferiores ao estado da arte

Figura 4.8: Gráficos dos índices *kappa* Médios Intervalo de Confiança vs. Indivíduo considerando as abordagens de Fraser & Swinney (1986) e Kennel *et al.* (1992) para a encontrar coordenadas de atraso e dimensões embutidas para o a) CSSP e b) CSSSP e os parâmetros que resultaram em melhores acurácia nos experimentos da Seções 4.2.4.3 e 4.4. Esses resultados foram produzidos sobre janelas de c) um segundo e d) dois segundos extraídos dos períodos de Imagética Motora.

e distantes da configuração ótima (avaliando todo o espaço paramétrico) pode gerar tal como visto na Seções 4.2, 4.3 e 4.4. Em contrapartida, cabe ressaltar que, exceto no caso de Alvarez-Meza *et al.* (2015), esses trabalhos relacionados não contam com avaliação sobre a capacidade de generalização dos classificadores construídos, uma vez que nem o método de validação cruzada ou qualquer outra técnica para a averiguação de estabilidade é utilizada. Portanto, não é possível aplicar uma comparação estatística justa entre

Figura 4.9: Gráficos dos índices *kappa* Médios Intervalo de Confiança vs. Indivíduo considerando as abordagens de Fraser & Swinney (1986) e Kennel *et al.* (1992) para a encontrar coordenadas de atraso e dimensões embutidas para o a) FBCSSP e b) FBCSSSP e os parâmetros que resultaram em melhores acurácia nos experimentos da Seções 4.2, 4.3 e 4.4. Esses resultados foram produzidos sobre janelas de c) um segundo e d) dois segundos extraídos dos períodos de Imagética Motora.

os resultados produzidos por meio da parametrização automática em conjunto com a validação cruzada em relação aos tais trabalhos reportados na literatura. Em complemento, as Figuras 4.10 e 4.11 permitem apontar que os resultados do CSSP, CSSSP, FBCSSP e FBCSSSP empregando a parametrização automática superam em diversos casos os apresentados por Alvarez-Meza *et al.* (2015).

Tabela 4.9: Tabela com os índices *kappa* dos métodos utilizando a configuração automática de parâmetros e com resultados do estado da arte.

	Voluntários										
Janela	1	2	3	4	5	6	7	8	9	Média	Desvio Padrão
CSSP											
1 seg.	0,41	0,17	0,29	0,43	0,00	0,09	0,65	0,36	0,41	0,31	0,20
2 seg.	0,09	0,07	0,34	0,43	0,14	0,16	0,48	0,61	0,27	0,29	0,19
Max	0,41	0,17	0,34	0,43	0,14	0,16	0,65	0,61	0,41	0,37	0,19
CSSSP											
1 seg.	0,35	0,21	0,18	0,86	0,12	0,32	0,78	0,48	0,21	0,39	0,27
2 seg.	0,18	0,13	0,18	0,93	0,09	0,27	0,38	0,43	0,41	0,33	0,26
Max	0,35	0,21	0,18	0,93	0,12	0,32	0,78	0,48	0,41	0,42	0,27
FBCSSP											
1 seg.	0,17	0,17	0,28	0,56	0,25	0,17	0,32	0,44	0,26	0,29	0,13
2 seg.	0,19	0,18	0,34	0,61	0,17	0,42	0,51	0,64	0,52	0,40	0,19
Max	0,19	0,18	0,34	0,61	0,25	0,42	0,51	0,64	0,52	0,41	0,18
FBCSSSP											
1 seg.	0,43	0,15	0,34	0,84	0,05	0,13	0,79	0,43	0,45	0,40	0,28
2 seg.	0,27	0,27	0,15	0,95	0,10	0,48	0,59	0,69	0,47	0,44	0,28
Max	0,43	0,27	0,34	0,95	0,10	0,48	0,79	0,69	0,47	0,50	0,27
Estado da arte											
Chin ¹	0,40	0,21	0,22	0,95	0,86	0,61	0,56	0,85	0,74	0,60	0,28
Gaur ²	0,26	0,36	0,96	0,76	0,94	0,52	0,46	0,76	0,70	0,62	0,25
Saa ³	0,60	0,32	0,06	0,97	0,87	0,78	0,63	0,88	0,81	0,66	0,30

¹ Zheng Yang Chin, ² Gaur *et al.* (2015) e ³ Saa & Cetin (2012).

4.7 Considerações Finais

A literatura sobre extração de características em Imagética Motora conta com estudos que analisam o uso de diversas técnicas tais como o CSP, CSSP, CSSSP e FBCSP (Koles, 1991; Lemm *et al.*, 2005; Dornhege *et al.*, 2006; Ang *et al.*, 2012a). Em complemento aos resultados dessas abordagens, esta seção analisou, também, os índices *kappa* produzidos pelo extrator ADBF e pelas extensões dos filtros espaço-temporais FBCSSP e FBCSSSP. Neste contexto, efetuou-se, posteriormente, uma comparação entre tais técnicas e aquelas que compõem o estado da arte, utilizando a mesma abordagem experimental adotada na literatura. Nesse cenário, algumas das abordagens consideradas neste trabalho produziram resultados superiores ou equiparáveis ao estado da arte.

Ademais, foi verificado que os índices *kappa* produzidos apresentam variações para diferentes valores de limiares de correlação θ , que são utilizados pela técnica de Análise de Componentes Independentes (ICA) para a escolha de quais Componentes Independentes

Figura 4.10: Gráficos dos índices *kappa* Médios Intervalo de Confiança vs. Indivíduo considerando as abordagens de Fraser & Swinney (1986) e Kennel *et al.* (1992) para a encontrar coordenadas de atraso e dimensões embutidas para o a) CSSP e b) CSSSP, e o trabalho de Alvarez-Meza *et al.* (2015). Esses resultados foram produzidos sobre janelas de c) um segundo e d) dois segundos extraídos dos períodos de Imagética Motora.

(ICs) devem compor os supostos sinais livres de artefatos. Devido a essa variabilidade dos índices *kappa*, avaliou-se θ a fim de encontrar um limiar adequado para a obtenção de bons resultados. Verificou-se, então, que CSSP, CSSSP, FBCSP, FBCSSP e FBCSSSP são robustos em cenários que não adotam a remoção de artefatos, por meio de ICA, na etapa de pré-processamento. Nesses casos, foram utilizados os sinais contendo artefatos, bem como nos experimentos seguintes, uma vez que essas técnicas mais robustas haviam produzido melhores índices *kappa*.

Figura 4.11: Gráficos dos índices *kappa* Médios Intervalo de Confiança vs. Indivíduo considerando as abordagens de Fraser & Swinney (1986) e Kennel *et al.* (1992) para a encontrar coordenadas de atraso e dimensões embutidas para o a) FBCSSP e b) FBCSSSP, e o trabalho de Alvarez-Meza *et al.* (2015). Esses resultados foram produzidos sobre janelas de c) um segundo e d) dois segundos extraídos dos períodos de Imagética Motora.

Visto que a varredura do espaço paramétrico tem alto custo computacional, foi considerada uma abordagem para a estimação automática das coordenadas de atraso, dimensões embutidas e o número de atributos selecionados pelo algoritmo MIFS. Em seguida, foram conduzidos experimentos para avaliar as abordagens consideradas neste trabalho, ainda empregando o mesmo método experimental adotado na literatura. Neste caso, os resultados foram inferiores e, conclui-se que a automatização não produziu parâmetros tão bons quanto aqueles obtidos após varredura do espaço paramétrico. Em contrapartida,

a redução de custo computacional por meio dessa automatização permitiu a execução de experimentos adicionais a fim de analisar os índices *kappa* obtidos a partir do uso da validação cruzada de 10 *folds* para cada extrator de características e para cada janela de tempo.

Os resultados provenientes desse último conjunto de experimentos permitiram avaliar a capacidade de generalização dos classificadores obtidos para o conjunto de dados produzido para cada um dos extratores e seleção de características. Apesar da impossibilidade de comparar esses resultados aos obtidos pelas abordagens do estado da arte, uma vez que a literatura adota um modelo experimental mais simples (Seções 4.2, 4.3 e 4.4), eles ainda assim são próximos aos resultados obtidos pela varredura paramétrica quando comparados a partir do emprego da validação cruzada de 10 *folds*. A vantagem em se utilizar a validação cruzada como modelo experimental é que ela permite obter conclusões mais robustas sobre a capacidade de generalização (ou aprendizado) dos classificadores obtidos, dado o fato que estima, com maior precisão, o risco (ou erro) esperado quando novos exemplos (ou sinais) nunca vistos são classificados. Para complementar as informações deste capítulo, no próximo é apresentado as conclusões e trabalhos futuros.

Conclusões

A classificação de Imagética Motora em sistemas de Interfaces Cérebro-Computador é uma tarefa complexa que exige uma série de etapas para a produção de informações discriminativas sobre sinais adquiridos por meio de imageamento cerebral que, tipicamente, considera a técnica de Eletroencefalografia (EEG). A EEG é atrativa devido ao seu baixo custo e sua mobilidade e, portanto, seu uso apresenta forte presença na construção das bases de dados públicas tal como a *BCI Competition IV* (Tangermann *et al.*, 2012). Neste trabalho foram consideradas as sessões de imageamento cerebral encontradas em *BCI Competition IV-2b*, a qual utilizou o imageamento por EEG para a aquisição de sinais cerebrais referentes à Imagética Motora dos movimentos da mão esquerda e direita.

Por apresentar alta sensibilidade, sinais extraídos por EEG são, tipicamente, pré-processados a fim de remover eventuais artefatos tais como os associados à movimentação dos olhos (monitorados por meio de Eletrooculografia – EOG). Uma das principais técnicas utilizadas na literatura para a remoção de artefatos é a Análise de Componentes Independentes (do inglês *Independent Component Analysis* – ICA), que visa produzir sinais estatisticamente independentes os quais são posteriormente analisados. Aqueles sinais com maior correlação aos canais de EOG são removidos, supondo-se que não há qualquer relação com a Imagética Motora. Neste trabalho, utilizou-se a correlação de Pearson (Pearson, 1895) como medida indicadora de quais Componentes Independentes (do inglês *Independent Components* – ICs) devem compor os novos sinais, supostamente livres de artefatos.

Desconsiderou-se, assim, todo IC cuja correlação com algum dos canais de EOG é maior que um limiar θ .

Os primeiros experimentos efetuados avaliaram a relação entre os índices *kappa* produzidos pelos extratores de características empregados e diferentes limiares θ . Além disso, como os filtros espaço-temporais (CSSP, CSSSP, FBCSSP e FBCSSSP) e a seleção de características por meio do algoritmo MIFS também exigem a escolha prévia de parâmetros tais como coordenadas de atraso τ , dimensões embutidas m e quantidade de atributos selecionados k , optou-se por escolher aqueles que produziram melhores índices *kappa* em uma primeira análise feita nos mesmos moldes da *BCI Competition IV-2b*. Neste contexto, as abordagens ADBF, CSP, CSSP, FBCSP e FBCSSP não produziram resultados equiparáveis ao estado da arte (ver Seções 4.2, 4.3 e 4.4). Contudo, sob a melhor configuração paramétrica possível, o CSSSP e o FBCSSSP atingiram índices *kappa* estatisticamente similares aos obtidos por Saa & Cetin (2012), Gaur *et al.* (2015) e Zheng Yang (Tangermann *et al.*, 2012). Cabe ressaltar que apesar desses resultados, o CSSSP não tem sido utilizado em trabalhos mais recentes pois, como aponta Ang *et al.* (2012a), ele requer a difícil definição de parâmetros temporais (m e τ).

De acordo com esses primeiros resultados experimentais (apresentados no Capítulo 4), conclui-se que, por meio da análise completa dos índices *kappa*, os filtros espaço-temporais (CSSP, CSSSP, FBCSSP e FBCSSSP) e o FBCSP são robustos em relação a influências de artefatos, uma vez que: i) pela formulação desses filtros, há a produção de um modelo autorregressivo capaz de mitigar as influências de Eletrooculografia, quando os canais de EOG são considerados; e ii) a decomposição em sub-bandas de frequência por meio de um banco de filtros permite a eliminação de artefatos na etapa de seleção de características, pois esses supostamente não garantem ganho de informação (calculado pelo algoritmo MIFS).

Sobretudo, a Análise de Componentes Independentes (ICA) prejudicou o desempenho de algumas dessas abordagens, uma vez que os ICs mais correlacionados aos canais de EOG podem ainda conter informações relevantes para a classificação das intenções de movimento. Em suma, os canais de EOG produzem interferências nos canais de EEG, mas também sofrem interferências desses, as quais, eventualmente, levam a informações úteis e que deveriam ser consideradas. Neste contexto, decidiu-se por não empregar a técnica ICA na etapa de remoção de artefatos, o que reduziu o custo computacional dos

experimentos subsequentes e, ao mesmo tempo, permitiu obter melhores resultados.

Em complemento, a varredura de todo o espaço paramétrico para a seleção das coordenadas de atraso, dimensões embutidas e atributos selecionadas pelo MIFS é uma tarefa de alto custo computacional. Portanto, adotou-se as técnicas de Falsos Vizinhos mais Próximos (do inglês *False Nearest Neighbors* – FNN) (Kennel *et al.*, 1992) e Auto-Informação Mútua (do inglês *Auto-Mutual Information* – AMI) (Fraser & Swinney, 1986) para estimar a quantidade de dimensões embutidas e as coordenadas de atraso mais adequadas, respectivamente, para produzir a imersão dos sinais de controle (Takens, 1981). Avaliou-se, ainda, a convergência do ganho de informação calculado pelo algoritmo MIFS como critério para definir o número de dimensões utilizado pelo o conjunto de dados empregado na etapa de classificação. Essas técnicas selecionam os parâmetros mencionados por meio de critérios reconhecidos na literatura (de Mello, 2009).

A parametrização automática não implicou em maiores índices *kappa* quando executados os experimentos de classificação utilizando o mesmo método considerado pela *BCI Competition IV-2b*. Contudo, essa automatização permitiu a execução de experimentos adicionais com o intuito de avaliar a capacidade de generalização dos classificadores obtidos, uma vez que reduziu significativamente o tempo de processamento despendido. Essa etapa considerou o método de validação cruzada de 10 *folds* para verificar o comportamento das abordagens de extração e seleção de características. Concluiu-se que os índices *kappa* obtidos a partir da parametrização automática são equiparáveis aos produzidos pelo melhor cenário da varredura paramétrica.

Logo, essa automatização é útil como ferramental para a etapa de configuração de um sistema de BCI para quaisquer indivíduos. Vale destacar que poucos trabalhos na literatura aplicam validação cruzada para verificar a estabilidade dos classificadores, o que seria uma medida mais justa para a comparação entre abordagens. No contexto deste trabalho, apenas Alvarez-Meza *et al.* (2015) empregou a validação cruzada de 10 *folds* para o teste de seu modelo, cujo resultado, em termos de índice *kappa*, se encontra abaixo dos produzidos pelas abordagens deste trabalho em diversos casos. Além disso, a parametrização automática é necessária para cenários do mundo real, já que ocorrem variações comportamentais dos sinais de controle ao longo do tempo, pois o indivíduo costuma se adaptar ao sistema de BCI.

Em resumo, as principais contribuições deste trabalho de mestrado são: i) concluiu-se

que o extrator de características CSSSP apresenta resultados equiparáveis ao estado da arte, contudo não tem sido considerado no âmbito de Imagética Motora; ii) a técnica ICA não é necessária para a remoção de artefatos quando os extratores de características já são capazes de modelar correlações entre os canais de EEG e EOG; iii) os extratores baseados em bancos de filtros produzem melhores resultados, por considerar uma análise espectral; iv) a imersão dos sinais de controle em um espaço fase, por meio do Teorema de Imersão proposto por Takens (1981), permite representar recorrências temporais e, portanto, obter características mais relevantes para a classificação da Imagética Motora; v) a automatização da escolha dos parâmetros de coordenadas de atraso, dimensões embutidas e de seleção de atributos por meio do algoritmo MIFS, permite reduzir o tempo total de processamento despendido nos experimentos, bem como a obtenção de resultados mais relevantes para a validação cruzada, logo produz classificadores com maior capacidade de generalização (i.e., aprendizado); vi) a análise do ganho de informação, calculado pelo algoritmo MIFS, permite a definição de um critério de convergência para determinar o número de dimensões utilizadas para compor o conjunto de dados posteriormente empregado na etapa de classificação.

Após a conclusão deste trabalho de mestrado, o grupo de pesquisas conta com o conhecimento e as habilidades necessárias para projetar novos extratores de características a partir de sinais cerebrais de EEG, capturados a fim de classificar movimentos imaginados e, assim, contribuir com aplicações de cunho social, tais como sistemas para controlar cadeiras de rodas e interfaces de comunicação.

Referências

- Akansu, A. N. e Haddad, R. A. (1992). *Multiresolution Signal Decomposition: Transforms, Subbands, and Wavelets*. Academic Press, Inc., Orlando, FL, USA.
- Akansu, A. N. e Haddad, R. A. (2001). Preface. Em Akansu, A. N. e Haddad, R. A., editors, *Multiresolution Signal Decomposition (Second Edition)*. Academic Press, San Diego, second edition edition.
- Alligood, K., Sauer, T., e Yorke, J. (1997). *Chaos: An Introduction to Dynamical Systems*. Chaos: An Introduction to Dynamical Systems. New York, NY.
- Alvarez-Meza, A., Velasquez-Martinez, L., e Castellanos-Dominguez, G. (2015). Time-series discrimination using feature relevance analysis in motor imagery classification. *Neurocomputing*, 151, Part 1:122 – 129.
- Ang, K. K., Chin, Z. Y., Wang, C., Guan, C., e Zhang, H. (2012a). Filter bank common spatial pattern algorithm on bci competition iv datasets 2a and 2b. *Frontiers in Neuroscience*, 6(39).
- Ang, K. K., Chin, Z. Y., Zhang, H., e Guan, C. (2012b). Mutual information-based selection of optimal spatial-temporal patterns for single-trial eeg-based bcis. *Pattern Recogn.*, 45(6):2137–2144.
- Ang, K. K. e Quek, C. (2006). Rough set-based neuro-fuzzy system. Em *Neural Networks, 2006. IJCNN '06. International Joint Conference on*, páginas 742–749.
- Bashashati, A., Fatourechi, M., Ward, R. K., e Birch, G. E. (2007). A survey of signal processing

- algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, 4:32–57.
- Blackford, S. (1999).
- Burke, D., Kelly, S., De Chazal, P., Reilly, R., e Finucane, C. (2005). A parametric feature extraction and classification strategy for brain-computer interfacing. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 13(1):12–17.
- Chowdhury, A., Ramadas, R., e Karmakar, S. (2013). Muscle computer interface: A review. Em Chakrabarti, A. e Prakash, R. V., editors, *ICoRD'13, Lecture Notes in Mechanical Engineering*, páginas 411–421. Springer India.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1):37.
- Cortes, C. e Vapnik, V. (1995). Support-Vector Networks. Em *Machine Learning*, páginas 273–297.
- Coyle, D. (2009). Neural network based auto association and time-series prediction for bi-signal processing in Brain-Computer Interfaces. *Computational Intelligence Magazine, IEEE*, 4(4):47–59.
- Coyle, D., Prasad, G., e McGinnity, T. (2005). A time-series prediction approach for feature extraction in a brain-computer interface. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 13(4):461–467.
- Coyle, D., Satti, A., Prasad, G., e McGinnity, T. M. (2008). Neural time-series prediction preprocessing meets common spatial patterns in a brain-computer interface. Em *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, páginas 2626–2629.
- Croft, R. J., Chandler, J. S., Barry, R. J., Cooper, N. R., e Clarke, A. R. (2005). EOG correction: a comparison of four methods. *Psychophysiology*, 42(1):16–24.
- da Silva, F. H. L. e Pfurtscheller, G. (1999). Basic concepts on EEG synchronization and desynchronization. *Thrombosis and Haemostasis*, páginas 3–11.

- de Beer, N. A., van de Velde, M., e Cluitmans, P. J. (1995). Clinical evaluation of a method for automatic detection and removal of artifacts in auditory evoked potential monitoring. *J Clin Monit*, 11(6):381–391.
- de Mello, R. F. (2009). *Sistemas dinâmicos e técnicas inteligentes para a predição de comportamento de processos: uma abordagem para otimização de escalonamento em grades computacionais*. Tese de Livre Docência, Instituto de Ciências Matemáticas e de Computação.
- de Mello, R. F. e Yang, L. T. (2009). Prediction of dynamical, nonlinear, and unstable process behavior. *The Journal of Supercomputing*, 49(1):22–41.
- del R Millan, J., Mourino, J., Franze, M., Cincotti, F., Varsta, M., Heikkonen, J., e Babiloni, F. (2002). A local neural classifier for the recognition of EEG patterns associated to mental tasks. *Neural Networks, IEEE Transactions on*, 13(3):678–686.
- Doppelmayr, M., Klimesch, W., Pachinger, T., e Ripper, B. (1998). Individual differences in brain dynamics: important implications for the calculation of event-related band power. *Biol Cybern*, 79(1):49–57.
- Dornhege, G., Blankertz, B., Krauledat, M., Losch, F., Curio, G., e Muller, K.-R. (2006). Combined optimization of spatial and temporal filters for improving brain-computer interfacing. *Biomedical Engineering, IEEE Transactions on*, 53(11):2274–2281.
- Fatourechi, M., Bashashati, A., Ward, R. K., e Birch, G. E. (2006). EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, 118(3):480–494.
- Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals Eugen.*, 7:179–188.
- Flexer, A., Bauer, H., Pripfl, J., e Dorffner, G. (2005). Using ICA for removal of ocular artifacts in EEG recorded from blind subjects. *Neural Networks*, 18(7):998 – 1005.
- Fraser, A. M. e Swinney, H. L. (1986). Independent coordinates for strange attractors from mutual information. *Phys. Rev. A*, 33:1134–1140.
- Gandhi, V., Prasad, G., Coyle, D., Behera, L., e McGinnity, T. M. (2015). Evaluating quantum neural network filtered motor imagery brain-computer interface using multiple classification techniques. *Neurocomputing*, 170:161 – 167. Advances on Biological Rhythmic

- Pattern Generation: Experiments, Algorithms and Applications Selected Papers from the 2013 International Conference on Intelligence Science and Big Data Engineering (IScIDE 2013) Computational Energy Management in Smart Grids.
- Gaur, P., Pachori, R. B., Wang, H., e Prasad, G. (2015). An empirical mode decomposition based filtering method for classification of motor-imagery eeg signals for enhancing brain-computer interface. Em *Neural Networks (IJCNN), 2015 International Joint Conference on*, páginas 1–7.
- Gotman, J., Skuce, D. R., Thompson, C. J., Gloor, P., Ives, J. R., e Ray, W. F. (1973). Clinical applications of spectral analysis and extraction of features from electroencephalograms with slow waves in adult patients. *Electroencephalogr Clin Neurophysiol*, 35(3):225–235.
- Graimann, B., Allison, B., e Pfurtscheller, G. (2010). Brain-computer interfaces: A gentle introduction. Em Graimann, B., Allison, B., e Pfurtscheller, G., editors, *Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction*. Springer-Verlag Berlin Heidelberg.
- Hameroff, S. (1998). Quantum computation in brain microtubules? The Penrose–Hameroff ‘Orch OR’ model of consciousness. *Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, 356(1743):1869–1896.
- Hamsici, O. e Martinez, A. (2008). Bayes optimality in linear discriminant analysis. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 30(4):647–657.
- Hjorth, B. (1970). EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 29(3):306 – 310.
- Hopcroft, J. e Kannan, R. (2014). *Foundations of Data Science*.
- Hsu, W.-Y. (2013). Embedded prediction in feature extraction: Application to single-trial EEG discrimination. *Clinical EEG and Neuroscience*, 44(1):31–38.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C., e Liu, H. H. (1998). The Empirical Mode Decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences*, 454:903–995.
- Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *Information Theory, IEEE Transactions on*, 14(1):55–63.

- Ince, N., Tewfik, A., e Arica, S. (2007). Extraction subject-specific motor imagery time-frequency patterns for single trial EEG classification. *Computers in Biology and Medicine*, 37(4):499–508.
- Jastrzebowski, W. B. (1857). An outline of Ergonomics, or the science of work based upon the truths drawn from the science of nature. Reprinted in: W. Karwowski (ed.). 2001. International Encyclopedia of Ergonomics and Human Factors. London: Taylor & Francis.
- Jung, T. P., Makeig, S., Humphries, C., Lee, T. W., McKeown, M. J., Iragui, V., e Sejnowski, T. J. (2000). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(2):163–178.
- Jurcak, V., Tsuzuki, D., e Dan, I. (2007). 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *NeuroImage*, 34(4):1600 – 1611.
- Kang, H., Nam, Y., e Choi, S. (2009). Composite Common Spatial Pattern for subject-to-subject transfer. *Signal Processing Letters, IEEE*, 16(8):683–686.
- Kennel, M. B., Brown, R., e Abarbanel, H. D. I. (1992). Determining embedding dimension for phase-space reconstruction using a geometrical construction. *Phys. Rev. A*, 45:3403–3411.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. Em *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2, IJCAI'95*, páginas 1137–1143, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Koles, Z. (1991). The quantitative extraction and topographic mapping of the abnormal components in the clinical eeg. *Electroencephalography and Clinical Neurophysiology*, 79(6):440 – 447.
- Krizhevsky, A., Sutskever, I., e Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Em Pereira, F., Burges, C., Bottou, L., e Weinberger, K., editors, *Advances in Neural Information Processing Systems 25*, páginas 1097–1105. Curran Associates, Inc.
- Lagerlund, T. D., Sharbrough, F. W., e Busacker, N. E. (1997). Spatial filtering of multichannel electroencephalographic recordings through Principal Component Analysis by Singular Value decomposition. *J Clin Neurophysiol*, 14(1):73–82.

- Lemm, S., Blankertz, B., Curio, G., e Muller, K. R. (2005). Spatio-spectral filters for improving the classification of single trial EEG. *IEEE Trans Biomed Eng*, 52(9):1541–1548.
- Lins, O., Picton, T., Berg, P., e Scherg, M. (1993a). Ocular artifacts in EEG and event-related potentials i: Scalp topography. *Brain Topography*, 6(1):51–63.
- Lins, O., Picton, T., Berg, P., e Scherg, M. (1993b). Ocular artifacts in recording EEGs and event-related potentials ii: Source dipoles and source components. *Brain Topography*, 6(1):65–78.
- Lyons, R. G. (1996). *Understanding Digital Signal Processing*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1st edition.
- Makeig, S., Bell, A. J., ping Jung, T., e Sejnowski, T. J. (1996). Independent component analysis of electroencephalographic data. Em *in Advances in Neural Information Processing Systems*, páginas 145–151. MIT Press.
- Marsland, S. (2009). *Learning: An Algorithmic Perspective*. Chapman and Hall/CRC, Boca Raton, FL.
- McFarland, D. J. e Wolpaw, J. R. (2011). Brain-computer interfaces for communication and control. *Commun. ACM*, 54(5):60–66.
- McLachlan, G. J. (2004). *Discriminant Analysis and Statistical Pattern Recognition (Wiley Series in Probability and Statistics)*. Wiley-Interscience.
- Mika, S., Rätsch, G., Weston, J., Schölkopf, B., e Müller, K.-R. (1999). Fisher discriminant analysis with kernels.
- Mitchell, T. (1997). *Machine Learning*. McGraw Hill.
- Moray, N., editor (2005). *Ergonomics: The History and Scope of Human Factors*. Taylor & Francis, Avenida Madison, 270, Nova York, NY.
- Morimoto, C. H. e Mimica, M. R. M. (2005). Eye gaze tracking techniques for interactive applications. *Comput. Vis. Image Underst.*, 98(1):4–24.
- Neuper, C. e Pfurtscheller, G. (2001). Event-related dynamics of cortical rhythms: frequency-specific features and functional correlates. *Int J Psychophysiol*, 43(1):41–58.

- Neuper, C., Scherer, R., Wriessnegger, S., e Pfurtscheller, G. (2009). Motor imagery and action observation: Modulation of sensorimotor brain rhythms during mental control of a brain-computer interface. *Clinical Neurophysiology*, 120(2):239 – 247.
- Nguyen, H. T., Nguyen, H. V., Truong, K. Q. D., e Vo, T. V. (2013). Analysis of oxy-hb signals to determine relationship between jaw imbalance and arm strength using fnirs. *American Journal of Biomedical Engineering*, 3(5):107–118.
- Nicolas-Alonso, L. F. e Gomez-Gil, J. (2012). Brain Computer Interfaces, a Review. *Sensors*, 12:1211–1279.
- Ochoa, C. J. e Polich, J. (2000). P300 and blink instructions. *Clin Neurophysiol*, 111(1):93–98.
- of Education, F. M. e Interface, R. B. B.-C. (2014). BCI competition. Acessado a partir de <http://www.bbci.de/competition>.
- of Education, F. M. e Research (2016). Berlin brain computer-interface. Acessado a partir de <http://www.bbci.de/competition>.
- Pearson, K. (1895). Notes on regression and inheritance in the case of two parents. Em *Proceedings of the Royal Society of London*, number v. 58. Taylor & Francis.
- Pfurtscheller, G. e da Silva, F. L. (1999). Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11):1842 – 1857.
- Pfurtscheller, G. e Neuper, C. (2010). Dynamics of sensorimotor oscillations in a motor task. Em Graimann, B., Allison, B., e Pfurtscheller, G., editors, *Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction*. Springer-Verlag Berlin Heidelberg.
- Purves, D., Fitzpatrick, D., Katz, L., Lamantia, A., McNamara, J., Williams, S., e Augustine, G. (2001). *Neuroscience*. Sinauer Associates.
- Radüntz, T., Scouten, J., Hochmuth, O., e Meffert, B. (2015). EEG artifact elimination by extraction of ica-component features using image processing algorithms. *Journal of Neuroscience Methods*, 243:84 – 93.
- Raza, H., Cecotti, H., Li, Y., e Prasad, G. (2015). Adaptive learning with covariate shift-detection for motor imagery-based brain-computer interface. *Soft Computing*, páginas 1–12.

- Rios, R. A. e de Mello, R. F. (2013). Improving time series modeling by decomposing and analyzing stochastic and deterministic influences. *Signal Processing*, 93(11):3001 – 3013.
- Saa, J. F. e Cetin, M. (2012). A latent discriminative model-based approach for classification of imaginary motor tasks from EEG data. *J Neural Eng*, 9(2):026020.
- Schölkopf, B. e Smola, A. J. (2001). *Learning with Kernels - Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press Cambridge, Massachussets.
- Shannon, C. (1998). Communication in the presence of noise. *Proceedings of the IEEE*, 86(2):447–457.
- Soman, S. e Jayadeva (2015). High performance EEG signal classification using classifiability and the twin SVM. *Applied Soft Computing*, 30:305 – 318.
- Stone, J. V. (2004). *Independent Component Analysis: A Tutorial Introduction*. MIT Press, Cambridge, MA, USA.
- Takens, F. (1981). Detecting strange attractors in turbulence. Em Rand, D. e Young, L.-S., editors, *Dynamical Systems and Turbulence, Warwick 1980*, volume 898 of *Lecture Notes in Mathematics*, páginas 366–381. Springer Berlin Heidelberg.
- Tangemann, M., Müller, K.-R., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., Leeb, R., Mehring, C., Miller, K. J., Mueller-Putz, G., Nolte, G., Pfurtscheller, G., Preissl, H., Schalk, G., Schlögl, A., Vidaurre, C., Waldert, S., e Blankertz, B. (2012). Review of the bci competition iv. *Frontiers in Neuroscience*, 6(55).
- Teplan, M. (2002). Fundamentals of eeg measurement. *Measurement Science Review*, 2:1–11.
- Ting, W., Guo-zheng, Y., Bang-hua, Y., e Hong, S. (2008). EEG feature extraction based on Wavelet Packet Decomposition for Brain-Computer Interface. *Measurement: Journal of the International Measurement Confederation*, 41(6):618–625.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag New York, Inc., New York, NY, USA.
- Verleger, R. (1991). The instruction to refrain from blinking affects auditory P3 and N1 amplitudes. *Electroencephalogr Clin Neurophysiol*, 78(3):240–251.

- Vigário, R. N. (1997). Extraction of ocular artefacts from EEG using Independent Component Analysis. *Electroencephalography and Clinical Neurophysiology*, 103(3):395 – 404.
- von Luxburg, U. e Scholkopf, B. (2009). Statistical Learning Theory: Models, concepts and results. *Handbook of the History of Logic*, 10:651–706.
- Wang, Y., Berg, P. e Scherg, M. (1999). Common spatial subspace decomposition applied to analysis of brain responses under multiple task conditions: a simulation study. *Clinical Neurophysiology*, 110(4):604 – 614.
- Wang, Y., Zhang, Z., Li, Y., Gao, X., Gao, S., e Yang, F. (2004). BCI competition 2003-data set iv:an algorithm based on CSSD and FDA for classifying single-trial EEG. *Biomedical Engineering, IEEE Transactions on*, 51(6):1081–1086.
- Wilcoxon, F. (1945). Individual Comparisons by Ranking Methods. *Biometrics Bulletin*, 1(6):80–83.
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., e Vaughan, T. M. (2002). Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6):767–791.
- Yang, B.-h., Yan, G.-z., Yan, R.-g., e Wu, T. (2007). Adaptive subject-based feature extraction in Brain-Computer Interfaces using Wavelet Packet Best Basis Decomposition. *Medical Engineering and Physics*, 29(1):48–53.
- Zhou, W. e Gotman, J. (2005). Removing eye-movement artifacts from the EEG during the intracarotid amobarbital procedure. *Epilepsia*, 46(3):409–414.
- Zhou, Z. e Wan, B. (2012). Wavelet packet-based Independent Component Analysis for feature extraction from motor imagery EEG of complex movements. *Clinical Neurophysiology*, 123(9):1779–1788.