UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Seleção de bandas de frequência na classificação de eletroencefalogramas de imagética motora

Paul Augusto Bustios Belizario

Dissertação de Mestrado do Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional (PPG-CMC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Paul Augusto Bustios Belizario

Seleção de bandas de frequência na classificação de eletroencefalogramas de imagética motora

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. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. João Luis Garcia Rosa

USP – São Carlos
Agosto de 2017

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

Belizario, Paul Augusto Bustios

B431s Seleção de bandas de frequência na classificação
de eletroencefalogramas de imagética motora / Paul
Augusto Bustios Belizario; orientador João Luis
Garcia Rosa. - São Carlos - SP, 2017.

73 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, 2017.

1. Imagética motora. 2. Eletroencefalograma.
3. Classificação. I. Rosa, João Luis Garcia, orient.
II. Título.

Paul Augusto Bustios Belizario

**Selection of frequency bands in the classification of motor
imagery electroencephalograms**

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. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. João Luis Garcia Rosa

USP – São Carlos
August 2017

*Este trabalho é dedicado a minha família,
que me apoiou o tempo todo.*

AGRADECIMENTOS

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro para a realização desta pesquisa, ao professor João Rosa pela orientação, a minha família pelo apoio e a todos los envolvidos ao longo deste projeto.

RESUMO

BELIZARIO, P. A. B. **Seleção de bandas de frequência na classificação de eletroencefalogramas de imagética motora.** 2017. 73 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2017.

Imagética motora é um processo mental que produz modulações na amplitude dos sinais de eletroencefalogramas em progresso. Os padrões presentes nestas modulações podem ser usados para classificar este processo mental, mas a identificação destes padrões não é uma tarefa trivial, porque eles estão presentes em bandas de frequências que são específicas para cada pessoa. Neste trabalho, apresenta-se um novo método para selecionar as bandas de frequência específicas para cada pessoa baseado na arquitetura do método *Filter Bank Common Spatial Pattern*. Para selecionar as bandas de frequência mais relevantes para cada pessoa, o método proposto aplica uma busca exaustiva para encontrar o melhor subconjunto de bandas de frequência contendo os padrões mais discriminativos dentro de um espaço de busca restrito a um tamanho fixo para este subconjunto. Esse tamanho é determinado usando validação cruzada e o método *Sequential Forward Floating Selection*. O método proposto foi avaliado usando a base de dados pública *2b* da *BCI Competition IV*, mostrando melhores resultados do que todos os métodos também avaliados nessa base de dados.

Palavras-chave: Imagética motora, Eletroencefalograma, Classificação.

ABSTRACT

BELIZARIO, P. A. B. **Selection of frequency bands in the classification of motor imagery electroencephalograms**. 2017. 73 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2017.

Motor imagery is a mental process that when performed, produces modulations in the amplitude of ongoing electroencephalogram signals. These modulations happen following a series of patterns that can be used to classify this mental process, but the detection of those patterns is not a trivial task, because they occur in frequency bands that are specific for each person. In this work, we present a method to select these subject-specific frequency bands based on the architecture of the Filter Bank Common Spatial Pattern approach. To select the most relevant frequency bands for each person, our method uses an exhaustive search to find the best subset of frequency bands containing the most discriminative patterns, but with one restriction, the search space is restricted to find a subset with a fixed number of frequency bands. The number is determined using cross-validation and the Sequential Forward Floating Selection method. We demonstrate that, using the data set 2b of the BCI Competition IV, our method is more accurate than current methods evaluated on the same data set.

Keywords: Motor imagery, Electroencephalogram, Classification.

LISTA DE ILUSTRAÇÕES

Figura 1 – Eletroencefalograma composto de 10 sinais de aproximadamente 7 segundos de duração.	26
Figura 2 – Localização de eletrodos para o registro de EEG segundo o sistema 10-20. . .	32
Figura 3 – Eletroencefalograma composto de 3 canais gerados pelos eletrodos nas posições C3, Cz e C4.	33
Figura 4 – Eletroencefalograma com ERD/ERS acontecendo ao mesmo tempo durante o movimento do dedo direito.	36
Figura 5 – Córtex cerebral e suas divisões.	36
Figura 6 – Etapas no processo de transformação dos sinais de EEG em comandos. . . .	39
Figura 7 – Conjunto de dados linearmente separável e um exemplo hiperplano separador. .	45
Figura 8 – Um hiperplano de separação ótimo para dados de duas classes.	45
Figura 9 – Determinação gráfica das envoltórias convexas, dos vetores de suporte (pontos destacados) e do hiperplano separador.	46
Figura 10 – Hiperplanos de suporte H1 e H2 com a margem de separação máxima e as restrições para a máquina de vetores de suporte.	47
Figura 11 – Regiões abrangidas para o caso não separável.	49
Figura 12 – Vectores de suporte em um caso não separável com um hiperplano linear, a margem suave de separação e o conceito de variável de folga.	50
Figura 13 – Hiperplano discriminante não linear.	52
Figura 14 – Arquitetura do método FBCSP.	54
Figura 15 – Arquitetura para a fase de seleção de bandas de frequência do método proposto. .	55
Figura 16 – Arquitetura para a fase de classificação do método proposto.	55
Figura 17 – Protocolos de gravação. (a) Os ensaios nas sessões 01T e 02T foram registrados sem feedback. (b) Para os ensaios nas sessões 03T, 04E e 05E, o feedback começou no segundo 3.5 e terminou no segundo 7.5.	58
Figura 18 – Características CSP extraídas de todas as épocas da sessões para treinamento da pessoa 4, filtradas em 10 diferentes bandas de frequências.	60

LISTA DE QUADROS

Quadro 1 – Bandas de frequência nos eletroencefalogramas	34
Quadro 2 – Kernels mais usados nas SVMs	52

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo de seleção de bandas de frequências	57
---	----

LISTA DE TABELAS

Tabela 1 – Acurácia estimada por uma validação cruzada de 10×10 -fold e características CSP de 1 a 5 bandas de frequências selecionadas usando o método SFFS.	60
Tabela 2 – Bandas de frequência selecionadas usando uma busca exaustiva restrita. . .	61
Tabela 3 – Resultados da classificação das épocas extraídas das sessões de avaliação usando o coeficiente Kappa como métrica.	62
Tabela 4 – Resultados da classificação das épocas extraídas das sessões de avaliação usando a acurácia como métrica.	62

LISTA DE ABREVIATURAS E SIGLAS

ADL	Análise Discriminante Linear
BCI	<i>Brain–Computer Interface</i> (Interface Cérebro–Computador)
CSP	<i>Common Spatial Patterns</i>
CV	<i>Cross-validation</i> (Validação cruzada)
ECG	Eletrocardiograma
EEG	Eletroencefalograma
EMG	Eletromiograma
EOG	Eletrooculograma
ERD	<i>Event–Related Desynchronization</i> (Dessincronização Relacionada a Evento)
ERS	<i>Event–Related Synchronization</i> (Sincronização Relacionada a Evento)
FBCSP	<i>Filter Bank Common Spatial Pattern</i>
ICA	<i>Independent component analysis</i>
IM	Imagética Motora
MIBIF	<i>Mutual Information-based Best Individual Feature</i>
MIRSR	<i>Mutual Information-based Rough Set Reduction</i>
NBPW	<i>Naive Bayes Parzen-window</i>
RES	<i>Restricted Exhaustive Search</i> (Busca Exhaustiva Restrita)
RNA	Rede Neural Artificial
SBCSP	<i>Sub-band Common Spatial Pattern</i>
SBS	<i>Sequential Backward Selection</i>
SFFS	<i>Sequential Forward Floating Selection</i>
SFS	<i>Sequential Forward Selection</i>
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Justificativa e Motivação	27
1.2	Objetivo	28
1.3	Resultados	28
1.4	Organização do Trabalho	29
2	ELETROENCEFALOGRAMAS DE IMAGÉTICA MOTORA	31
2.1	Eletroencefalograma	31
2.1.1	<i>Bandas de frequência</i>	33
2.1.2	<i>Artefatos</i>	35
2.2	Imagética motora	35
2.2.1	<i>Ritmos sensório-motores</i>	37
3	CLASSIFICAÇÃO DE EEG DE IMAGÉTICA MOTORA	39
3.1	Métodos de melhoramento de qualidade dos sinais	39
3.2	Métodos de extração de características	41
3.3	Métodos de seleção de características	42
3.4	Métodos classificadores de características	43
3.4.1	<i>Máquina de Vetores de Suporte</i>	44
4	MÉTODO DE SELEÇÃO PROPOSTO	53
4.1	Filter Bank Common Spatial Pattern	53
4.2	Busca exaustiva em um espaço de bandas de frequência restrito	54
4.2.1	<i>Filtragem de frequências</i>	55
4.2.2	<i>Extração de características</i>	56
4.2.3	<i>Seleção de características (Seleção de frequências)</i>	56
4.2.4	<i>Classificação</i>	57
4.3	Materiais	58
4.4	Avaliação experimental	59
4.4.1	<i>Fase de seleção de características</i>	59
4.4.2	<i>Fase de classificação</i>	61
5	CONCLUSÃO	63
5.1	Trabalhos futuros	64

REFERÊNCIAS	65
GLOSSÁRIO	73

INTRODUÇÃO

Desde que o nosso conhecimento sobre o funcionamento do cérebro aumentou nas últimas décadas devido ao desenvolvimento de equipamento de baixo custo e refinamento das técnicas de registro da atividade cerebral, os grupos de pesquisa na área dos sistemas de Interface Cérebro–Computador (BCI do inglês *Brain–Computer Interface*) tem aumentado consideravelmente nos últimos anos. Uma das técnicas que permitiu isto é o eletroencefalograma (EEG).

Um EEG é um registro da atividade elétrica no córtex cerebral, medido usando eletrodos dispostos no couro cabeludo e é composto de vários sinais, sendo cada sinal produzido, na maioria dos casos, por um eletrodo. A Figura 1 ilustra um EEG composto de dez sinais com uma duração aproximada de sete segundos. Os EEGs são amplamente utilizados para a investigação do cérebro e nas BCIs por causa das vantagens que oferece, as quais são: medidas de alta resolução temporal, procedimento de gravação não invasivo e equipamento de gravação relativamente barato em comparação com outros dispositivos de registro de atividade cerebral. Na área de análise de EEGs, o tópico de classificação de sinais de EEG de imagética motora tem recebido atenção considerável devido à sua importância na ajuda a pessoas com alguma deficiência física, tais como a distrofia muscular (PFURTSCHELLER *et al.*, 2000; WOLPAW *et al.*, 2002; BIRBAUMER; COHEN, 2007; MULDER, 2007) e em outras aplicações como navegação em mundos virtuais (LEEB *et al.*, 2007) e entretenimento (NIJHOLT *et al.*, 2009; BONNET *et al.*, 2013).

A imagética motora é um processo mental que consiste em ensaiar um movimento mentalmente sem nenhum tipo de atividade muscular como resultado (MULDER, 2007). Este processo mental produz uma série de fenômenos que causam alterações na amplitude dos sinais de EEG dentro da banda de frequência de 8 a 30 Hz (PFURTSCHELLER; NEUPER, 1997). Estes fenômenos são chamados de Dessincronização Relacionada a Evento (ERD do inglês *Event–Related Desynchronization*), que representa uma diminuição da amplitude (PFURTSCHELLER;

Figura 1 – Eletroencefalograma composto de 10 sinais de aproximadamente 7 segundos de duração.

Fonte: Adaptada de Cherninskyi (2015).

ARANIBAR, 1977), e Sincronização Relacionada a Evento (ERS do inglês *Event-Related Synchronization*), que representa um aumento da amplitude (PFURTSCHELLER, 1992).

Os padrões gerados pelas ERD/ERS podem ser usados para classificar sinais de EEG de imagética motora, mas a identificação e classificação destes eventos não é uma tarefa trivial, porque a atividade cerebral é diferente entre as pessoas, o que significa que as ERD/ERS acontecem em uma banda de frequência específica para cada pessoa (PFURTSCHELLER; SILVA, 1999; PFURTSCHELLER, 2001), isto é, duas pessoas podem realizar a imagética motora de, por exemplo, a mão esquerda, mas os padrões discriminativos poderão estar na banda de frequência de 8–12 Hz em uma pessoa e, na outra, poderão estar nas bandas de frequência de 10–12 Hz e 20–22 Hz. Além disso, o EEG contém ruído, sendo necessário filtrar os sinais para melhorar sua qualidade.

O método chamado de Padrões Espaciais Comuns (CSP do inglês *Common Spatial Patterns*) (KOLES *et al.*, 1990) é eficaz na construção de filtros espaciais que discriminam duas classes de sinais de EEG de imagética motora. No entanto, o desempenho deste filtro espacial depende da banda de frequência dos sinais. A classificação realizada sobre as características geradas pelo CSP geralmente não produz bons resultados quando os sinais de EEG não são filtrados ou foram filtrados em uma banda de frequência inadequada (NOVI *et al.*, 2007). Assim, a seleção de uma banda de frequência ampla ou a seleção manual de uma banda de frequência específica para um sujeito são comumente usadas com o método CSP (DORNHEGE *et al.*, 2006).

Ang *et al.* (2012) mostraram que aplicar um filtro passa-banda entre os 7–35 Hz não é suficiente para obter bons resultados na classificação dos sinais de EEG de imagética motora, por

esse motivo eles propuseram o método *Filter Bank Common Spatial Pattern* (FBCSP), um dos métodos mais bem sucedidos e vencedor da *BCI Competition IV* nos conjuntos de dados 2a e 2b (TANGERMANN *et al.*, 2012). FBCSP filtra os sinais de EEG em várias bandas de frequência usando um banco de filtros passa-banda, cobrindo a banda dos 8–30 Hz da imagética motora. Após a filtragem, características são extraídas dos sinais filtrados. Para realizar a classificação, apenas são utilizadas as características que contêm os padrões discriminativos.

Neste trabalho, o objetivo é propor e desenvolver um método para melhorar a acurácia na classificação dos sinais de EEG de imagética motora por meio da seleção das bandas de frequência mais apropriadas para cada pessoa. Esta seleção de bandas de frequência será feita usando uma busca exaustiva em um espaço restrito de busca.

1.1 Justificativa e Motivação

Como mencionado anteriormente, os EEGs são utilizados como meio de comunicação entre o cérebro e o computador, sendo assim parte importante em uma BCI. Os sinais de EEG podem ser, por exemplo, utilizados para investigação dos seguintes problemas clínicos (TEPLAN, 2002):

- Monitoramento do estado de alerta, coma e morte cerebral.
- Localização de áreas de dano após traumatismo craniano.
- Monitoramento dos processos cognitivos.
- Controle da profundidade da anestesia.
- Investigação de crises epiléticas.
- Teste dos efeitos de drogas.
- Acompanhamento do desenvolvimento do cérebro.
- Pesquisa de distúrbios mentais.

Muitas doenças, tais como a Esclerose Lateral Amiotrófica, distrofias musculares, lesões cerebrais ou outras doenças neurológicas podem impedir o controle voluntário dos músculos imobilizando seus membros ou até mesmo seus corpos inteiros diminuindo drasticamente a qualidade de vida do paciente (WOLPAW *et al.*, 2002). Nesses casos, uma opção para a recuperação da função motora é prover um novo caminho para a execução da ordem cerebral em um dispositivo externo, como uma cadeira de rodas ou uma neuroprótese, o que pode aliviar o sofrimento psicológico e social da pessoa. Pessoas que sofrem de paraplegia ou outras deficiências físicas podem conduzir uma cadeira de rodas autonomamente, melhorando a sua qualidade de vida.

Nesse campo de pesquisa, a imagética motora tem-se mostrado eficaz, aumentando, nos últimos anos, o interesse da aplicação da prática mental na reabilitação (GAGGIOLI *et al.*, 2009). Outra aplicação da imagética motora acontece também na área da comunicação, onde há pessoas com deficiência para falar devido a doenças neurológicas. A imagética do movimento da mão ou pé pode ser interpretada como uma letra para depois formar palavras (OBERMAIER *et al.*, 2003).

Além dessas aplicações, existem outras importantes na indústria, tais como as aplicações orientadas para o entretenimento e controle dos ambientes domésticos (NICOLAS-ALONSO; GOMEZ-GIL, 2012) o que faz que os sistemas baseados em IM possam encontrar aplicações na população em geral, tornando-se um campo de pesquisa importante.

Esta lista de aplicações confirma o grande potencial da análise dos sinais de EEGs e motiva a necessidade de técnicas avançadas de processamento de sinais para auxiliar na sua interpretação.

No tópico de classificação de sinais de EEG de imagética motora, uma busca exaustiva para encontrar as bandas de frequência que contêm as características discriminativas específicas para cada pessoa pode ser o método mais eficaz, mas não é popular porque é demorado. No entanto, se soubéssemos quantas bandas de frequência são suficientes para obter um bom desempenho na classificação, a busca exaustiva seria reduzida para encontrar a melhor combinação de apenas esse número de bandas de frequência de todas as disponíveis no banco de filtros.

Dada a estrutura do problema, acreditamos que uma busca exaustiva em um espaço de busca restrito pode encontrar as bandas de frequência ótimas para cada pessoa e assim, melhorar a acurácia na classificação.

1.2 Objetivo

O objetivo principal deste trabalho é propor um método classificador de sinais de EEG de imagética motora e demonstrar que uma busca exaustiva em um espaço de busca limitado a certo número de bandas de frequência determinado pelo método *Sequential Forward Floating Selection* pode melhorar a acurácia na classificação deste tipo de EEGs.

Como demonstraremos, nosso método pode melhorar, em relação os métodos do estado da arte, não só a acurácia da classificação dos sinais de EEG de imagética motora, mas também a eficiência usando características de apenas duas bandas de frequência para cada pessoa.

1.3 Resultados

Como resultados deste trabalho ressalta-se:

- Uma nova configuração para o método *Filter Bank Common Spatial Pattern* com duas

fases, uma para selecionar as características e bandas de frequências relevantes para cada pessoa, e outra para classificar os EEGs de imagética motora usando um número reduzido de filtros passa-banda.

- Um novo método de seleção de bandas de frequência para melhorar a acurácia na classificação de sinais de EEG de imagética motora. Demonstramos em um conjunto de dados disponível publicamente que nosso método de seleção de bandas de frequência inserido na nova configuração proposta para o método FBCSP consegue melhores resultados do que os métodos avaliados no mesmo conjunto de dados, usando apenas dois filtros passa-banda. Esses resultados foram publicados na *International Joint Conference on Neural Networks 2017* (BUSTIOS; ROSA, 2017).
- Um framework para a classificação de sinais de EEG de imagética motora disponível em um repositório público de GitHub (BUSTIOS, 2017).

1.4 Organização do Trabalho

O restante deste trabalho está organizado do seguinte modo: o Capítulo 2 é destinado a descrever conceitos básicos de EEG e imagética motora; no Capítulo 3 são apresentados os conceitos básicos dos métodos usados nas abordagens que usam bancos de filtros na classificação de sinais de EEG de imagética motora; no Capítulo 4 são apresentados os experimentos e resultados da classificação dos sinais de EEG da base de dados *2b* da *BCI Competition IV* utilizando nosso método de classificação proposto; e por fim, no Capítulo 5 são apresentadas as conclusões deste trabalho.

ELETROENCEFALOGRAMAS DE IMAGÉTICA MOTORA

O primeiro registro da atividade elétrica no cérebro remonta ao ano de 1924, com Hans Berger (1873-1941) como inventor do eletroencefalograma (EEG) (FREEMAN; QUIAN-QUIROGA, 2013). A partir desse tempo, o EEG desencadeou uma revolução no modo de estudar processos cerebrais normais e patológicos. A história do EEG tem sido um processo contínuo, que trouxe o desenvolvimento de estudos clínicos, experimentais e computacionais para a descoberta, reconhecimento, diagnóstico e tratamento de um vasto número de anormalidades neurológicas e fisiológicas do cérebro e do resto do sistema nervoso central dos seres humanos.

Neste capítulo são abordados os conceitos básicos sobre os EEGs de imagética motora, os quais serão analisados e classificados neste trabalho. Na seção 2.1, são apresentados os conceitos básicos dos EEGs. Na seção 2.2, é apresentado o conceito de imagética motora e suas características observáveis nos EEGs.

2.1 Eletroencefalograma

O eletroencefalograma (EEG) é um método não invasivo que mede potenciais elétricos produzidos pela atividade elétrica no córtex cerebral (BAILLET *et al.*, 2001). O córtex cerebral é a camada superior do cérebro e tem uma espessura que varia de 2 a 4 milímetros na qual residem 19% dos aproximadamente 86 bilhões de neurônios no cérebro (AZEVEDO *et al.*, 2009).

O sistema de registro de EEG é composto de eletrodos, amplificadores de sinal, um conversor analógico-digital e um dispositivo de registro das medições feitas (TEPLAN, 2002). Os eletrodos são dispostos no couro cabeludo geralmente seguindo o sistema internacional 10-20 recomendado pela *International Federation of Societies for Electroencephalography and Clinical Neurophysiology* (KLEM *et al.*, 1999), como mostrado na Figura 2. Este sistema utiliza quatro pontos de referência padrão para definir as locações dos eletrodos os quais são o násion, o íñion e

os pontos pré-auriculares esquerdo (A1) e direito (A2). Os eletrodos são colocados em intervalos de 10% ou 20% sobre a medida total entre os pontos de referência. As locações dos eletrodos são rotulados segundo o hemisfério e os lobos cerebrais sobre os quais eles estão dispostos. Os eletrodos dispostos no lobo frontal serão rotulados com uma letra F mais um número ímpar se eles estão no hemisfério esquerdo, um número par se eles estão no hemisfério direito ou z se estão na linha central. Da mesma forma, os eletrodos dispostos no lobo central, parietal, occipital e temporal, serão rotulados com uma letra C, P, O e T, respectivamente, mais um número par ou ímpar, dependendo do hemisfério onde eles estão localizados (KLEM *et al.*, 1999).

Figura 2 – Localização de eletrodos para o registro de EEG segundo o sistema 10-20.

Fonte: Asanagi (2010).

As medições registradas no EEG são as diferenças de potencial elétrico entre um eletrodo ativo e outro eletrodo de referência. Cada um desses pares é chamado de canal de EEG. Geralmente, cada canal recebe o nome do eletrodo que fez o registro da atividade elétrica. Na Figura 3 podemos ver um EEG composto de 3 canais chamados de C3, Cz e C4. Atualmente é comum ver sistemas de registro multicanal com 128 ou 256 eletrodos ativos. Um eletrodo adicional, conhecido como eletrodo terra, é usado para medir a diferença de voltagem entre os eletrodos ativos e de referência (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Os sinais de EEG podem ser classificados de acordo com sua frequência, sendo assim separados em diferentes bandas, também chamadas de ritmos ou ondas. Esta classificação é apresentada a seguir.

Figura 3 – Eletroencefalograma composto de 3 canais gerados pelos eletrodos nas posições C3, Cz e C4.

Fonte: Elaborada pelo autor.

2.1.1 Bandas de frequência

Bandas de frequência bem conhecidas foram definidas de acordo com a distribuição ao longo do couro cabeludo ou significado biológico. Estas bandas de frequências são referidas como ondas ou ritmos delta (δ), teta (θ), alfa (α), beta (β) e gama (γ) (FREEMAN; QUIAN-QUIROGA, 2013).

Ritmos delta (δ)

Encontram-se abaixo de 4 Hz. Ritmos delta geralmente são observados apenas em adultos em estado de sono profundo e são incomuns em adultos em um estado de vigília. Uma grande quantidade da atividade delta em adultos acordados é anormal e está relacionada com doenças neurológicas. Devido à baixa frequência, é fácil confundir ondas delta com sinais de artefatos, que são causados pelos grandes músculos do pescoço ou mandíbula (FREEMAN; QUIAN-QUIROGA, 2013).

Ritmos teta (θ)

Situam-se entre os 4 e 7 Hz. Em um adulto acordado normal, apenas uma pequena quantidade de frequências teta pode ser gravada. A maior quantidade de frequências teta pode ser vista em crianças pequenas, crianças mais velhas e adultos sonolentos, estados meditativos ou sono. Como nas ondas delta, uma grande quantidade de atividade teta em adultos despertos está relacionada com doenças neurológicas. A banda teta tem sido associada à concentração meditativa e uma ampla gama de processos cognitivos como cálculo mental (FERNÁNDEZ *et al.*, 1995) ou jogo do labirinto (CAPLAN *et al.*, 2001).

Ritmos alfa (α)

Encontram-se nas frequências de 8 a 12 Hz. A amplitude dos sinais nesta banda de frequências aumenta quando a pessoa mantém os olhos fechados e o corpo relaxado, e a amplitude diminui quando os olhos estão abertos e algum esforço mental é feito. Esses ritmos refletem, principalmente, o processamento visual na região occipital do cérebro e também podem

estar relacionados com o funcionamento da memória (KLIMESCH, 1997). Existe também evidência de que a atividade alfa pode estar associada com um esforço mental. Aumentar o esforço mental provoca uma supressão da atividade alfa, particularmente das áreas frontais (VENABLES; FAIRCLOUGH, 2009). Ritmos mu (μ) podem ser encontrados na mesma faixa dos ritmos alfa, embora haja diferenças fisiológicas importantes entre ambos. Em contraste com os ritmos alfa, ritmos mu estão fortemente relacionados com as atividades motoras, em alguns casos, parecem correlacionar-se com os ritmos beta (PINEDA, 2005).

Ritmos beta (β)

São registrados dentro da banda de frequências de 12 a 30 Hz, nas regiões frontal e central do cérebro e estão associados com atividades motoras. Ritmos beta são dessincronizados durante o movimento real ou imaginário motor. São caracterizados pela sua distribuição simétrica quando não há atividade motora. No entanto, em caso de movimento ativo, as ondas beta atenuam-se, e sua distribuição simétrica muda. Também estão associados com o estado de alerta em uma pessoa, a concentração e a memória (PFURTSCHELLER, 2001).

Ritmos gama (γ)

Pertencem à banda de frequências de 30 a 100 Hz. A presença de ritmos gama na atividade do cérebro de um adulto saudável está relacionada com certas funções motoras ou percepções, entre outros (LEE *et al.*, 2003). Alguns experimentos revelaram uma relação em humanos normais entre atividades motoras e ritmos gama durante a contração muscular máxima (BROWN *et al.*, 1998).

Além destes ritmos, existe outro chamado de ritmos sensório-motores, mas será apresentado mais adiante neste capítulo, depois de apresentar o conceito de imagética motora. O Quadro 1 apresenta um resumo dos tipos de ritmos apresentados até agora nos quais os sinais de EEG podem ser classificados:

Quadro 1 – Bandas de frequência nos eletroencefalogramas

Tipo de banda	Frequência (Hz)	Normalmente
Delta – δ	< 4	Em adultos em estado de sono
Teta – θ	4 – 7	Em crianças. Associada à concentração meditativa e processos cognitivos
Alfa – α	8 – 12	Associado ao estado de relaxamento e reflexão
Beta – β	12 – 30	Associado com o estado de alerta, a concentração e a memória
Gama – γ	30 – 100	Em adultos saudáveis. Relacionada a percepções
Mu – μ	8 – 12	Relacionados com as atividades motoras

2.1.2 Artefatos

Os artefatos são potenciais elétricos não desejados que contaminam o registro da atividade cerebral no EEG e são majoritariamente de origem não cerebral. Já que os sinais dos fenômenos neurológicos são afetados, os artefatos reduzem o desempenho dos métodos classificadores. Os artefatos podem ser classificados em duas categorias: artefatos fisiológicos e artefatos técnicos.

Os artefatos fisiológicos são produzidos pela atividade muscular, ocular e cardíaca. A atividade elétrica muscular pode ser registrada através do Eletromiograma (EMG). Da mesma maneira, as atividades elétricas ocular e cardíaca são registradas através do Eletrooculograma (EOG) e Eletrocardiograma (ECG) respectivamente (FATOURECHI *et al.*, 2007). Os artefatos produzidos pelo movimento dos músculos presentes no rosto e pescoço, chamados de artefatos EMG, tipicamente implicam grandes alterações nos sinais cerebrais. Os artefatos oculares, também chamados de artefatos EOG, são produzidos pelo piscar e movimento dos olhos. O piscar geralmente produz padrões de amplitude alta sobre os sinais cerebrais, em contraste aos movimentos do olho que produzem padrões de frequência baixa. Os artefatos EOG afetam principalmente a área frontal (CROFT; BARRY, 2000). Finalmente, os artefatos ECG, os quais refletem a atividade cardíaca, introduzem sinais rítmicos na atividade cerebral (FATOURECHI *et al.*, 2007).

Os artefatos técnicos são atribuídos principalmente a ruídos da fonte de energia ou alterações nas impedâncias dos eletrodos, que geralmente podem ser evitados por filtragem ou blindagem adequada (FATOURECHI *et al.*, 2007). Portanto, os pesquisadores se concentram principalmente nos artefatos fisiológicos, dado que sua redução nos sinais de EEGs da atividade cerebral é uma questão muito mais desafiadora do que o tratamento dos artefatos técnicos.

2.2 Imagética motora

A Imagética Motora (IM) é a simulação ou ensaio mental de um ato motor sem realizá-lo fisicamente (MULDER, 2007). Este processo mental produz modulações na amplitude dos sinais de EEG, chamadas de Dessincronização Relacionada a Evento (ERD do inglês *Event-Related Desynchronization*) (PFURTSCHELLER; ARANIBAR, 1977), e Sincronização Relacionada a Evento (ERS do inglês *Event-Related Synchronization*) (PFURTSCHELLER, 1992). A ERD envolve uma supressão da amplitude dos sinais de EEG e a ERS implica aumento da amplitude. A Figura 4 ilustra que a ERD e a ERS podem acontecer simultaneamente em diferentes localizações do córtex cerebral (PFURTSCHELLER, 2001).

A IM ativa regiões corticais que se sobrepõem às regiões ativadas durante a atividade motora. Esta região é o córtex sensório-motor, e é composta pelo córtex motor e o córtex somatossensorial, como ilustrado na Figura 5. Mas mesmo quando a atividade motora e a IM ativam regiões cerebrais semelhantes, o cenário psicológico em prática difere claramente. Curiosamente, a imagética motora não requer a presença do membro em ação. Por exemplo,

Figura 4 – Eletroencefalograma com ERD/ERS acontecendo ao mesmo tempo durante o movimento do dedo direito.

Fonte: Adaptada de Pfurtscheller e Neuper (2001).

pacientes com amputação de membros ou com interrupção ou destruição do nervo aferente (nervo que recebe os estímulos nervosos) podem executar tarefas de IM envolvendo as partes do corpo feridas ou ausentes. Portanto, o processo da imagética não é dependente da habilidade física para executar um movimento, mas sim dos mecanismos de processamento do cérebro (PFURTSCHELLER; NEUPER, 1997).

Figura 5 – Córtex cerebral e suas divisões.

Fonte: Adaptada de CNX OpenStax (2016).

2.2.1 Ritmos sensório-motores

Os ritmos sensório-motores compreendem ritmos mu e beta, quer dizer, estão na banda de frequências de 8 a 30 Hz (PFURTSCHELLER; NEUPER, 1997; PFURTSCHELLER *et al.*, 1997; PFURTSCHELLER; SILVA, 1999; PFURTSCHELLER *et al.*, 2000; PICHIORRI *et al.*, 2011). Os ritmos mu e beta estão associados de tal maneira que alguns ritmos beta são ritmos mu harmônicos, embora alguns ritmos beta também possam apresentar-se de forma independente (PFURTSCHELLER; SILVA, 1999). A amplitude dos ritmos sensório-motores varia quando a atividade cerebral está relacionada a alguma tarefa motora (PFURTSCHELLER; NEUPER, 1997).

Os ritmos sensório-motores estão relacionados com a IM (PFURTSCHELLER; NEUPER, 1997). Isto torna possível a utilização dos ritmos sensório-motores para a concepção de sistemas baseados em interfaces cérebro-computador (BCI). No entanto, o auto-controle dos ritmos sensório-motores não é fácil, e a maioria das pessoas tem dificuldades com a IM. As pessoas tendem a realizar representações visuais de movimentos relacionados, que não é suficientemente útil para um sistema BCI, porque os padrões desses ritmos sensório-motores diferem da autêntica IM. O treinamento do usuário deve enfatizar experiências cinestésicas em vez de representações visuais de ações (NEUPER *et al.*, 2005).

CLASSIFICAÇÃO DE EEG DE IMAGÉTICA MOTORA

O análise de EEGs tem atraído muitos pesquisadores ao redor do mundo. Isso deve-se principalmente às inúmeras aplicações que tem esse tipo de dados, como o monitoramento do estado de alerta, localização de áreas de dano após traumatismo craniano, acidente vascular cerebral e tumor, investigação das crises epiléticas, etc.

Nos sistemas BCI baseados em EEG, o processo de transformação dos sinais de EEG em comandos, comumente é composto de 4 etapas (FATOURECHI *et al.*, 2007) como mostrado na Figura 6. Para cada uma dessas etapas foram propostos vários métodos na literatura. Nas seguintes sessões serão apresentados os métodos mais usados para processar os EEGs de imagética motora usados como fonte de controle nos sistemas BCI.

Figura 6 – Etapas no processo de transformação dos sinais de EEG em comandos.

Fonte: Elaborada pelo autor.

3.1 Métodos de melhoramento de qualidade dos sinais

Um sistema BCI baseado em EEGs de imagética motora transforma a atividade de imagética motora em comandos. Para conseguir isso, como primeiro passo, os sinais de EEG são filtrados para remover os artefatos presentes e melhorar sua qualidade. Os métodos mais

comumente usados são *Surface Laplacian* (BABILONI *et al.*, 2000), *Common Spatial Patterns* (CSP) (MÜLLER-GERKING *et al.*, 1999; BLANCHARD; BLANKERTZ, 2004; NOVI *et al.*, 2007; ANG *et al.*, 2008; ANG *et al.*, 2012) e *Independent component analysis* (ICA) (BAI *et al.*, 2014).

CSP foi descrito pela primeira vez por Koles *et al.* (1990) para extrair padrões espaciais de EEGs de indivíduos normais e pacientes com distúrbios neurológicos. Na literatura, o método CSP demonstrou sua eficácia na extração de padrões das modulações produzidas nas ERDs/ERSs. No entanto, este filtro espacial só deve ser aplicado às bandas de frequências informativas (bandas μ e β), que são específicas para cada pessoa. Em geral, a aplicação do método CSP em sinais de EEG não filtrados ou filtrados em bandas de frequências muito largas, não ajudará a melhorar a qualidade dos sinais. Por isso, antes de aplicar CSP, é necessário filtrar os sinais na banda de frequências que apresenta as ERDs/ERSs quando a pessoa realiza alguma tarefa de imagética motora.

Uma grande questão é como definir as frequências de corte inferior e superior da banda. As abordagens incluem realizar uma análise no espectro de frequências, usar a transformada de Wavelet contínua (PFURTSCHELLER; SILVA, 1999) ou aplicar vários filtros passa-banda, extrair características dos sinais em todas as bandas de frequência, e selecionar as mais discriminativas (LEEB *et al.*, 2007).

CSP constrói um conjunto de filtros espaciais a partir de segmentos de EEG, de agora em diante denominados épocas, a qual pode ser usada para projetar os sinais de EEG e melhorar sua qualidade. O procedimento matemático CSP para um problema de duas classes é descrito a seguir.

Primeiro, calcular as matrizes de covariância para cada classe $k \in a, b$ das épocas filtradas em alguma banda de frequências:

$$R_k = \frac{1}{n_k} \sum_{i=1}^{n_k} X_{k,i} X_{k,i}^T \quad (3.1)$$

sendo:

- $X_{k,i} \in \mathbb{R}^{c \times t}$: a i -ésima época da classe k , composta de t amostras de c canais.
- n_k : o número de épocas da classe k .
- $R_k \in \mathbb{R}^{c \times c}$: a matriz de covariância das épocas filtradas da classe k .

Em seguida, com as matrizes de covariância encontradas usando a equação Equação 3.1, resolver o problema de autovalor generalizado na forma matricial:

$$R_a W = (R_a + R_b) W \Lambda \quad (3.2)$$

sendo:

- $W \in \mathbb{R}^{c \times c}$: (com $c = \text{número de canais}$) a matriz dos autovetores generalizados $w_{j=\{1,\dots,c\}}$ de R_a e $R_a + R_b$.
- $\Lambda \in \mathbb{R}^{c \times c}$: é uma matriz diagonal que contém os autovalores generalizados $\lambda_{j=\{1,\dots,c\}}$, correspondentes aos autovetores w_j , de R_a e $R_a + R_b$.

Por fim, se os autovalores λ_j estão dispostos em uma ordem não crescente, isto é $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_c$, e seus correspondentes autovetores w_j compartilham a mesma ordem, então os primeiros m autovetores em W fornecerão, quando projetados sobre estes autovetores, variância alta para a classe a e variância baixa para a classe b . Por outro lado, os últimos m autovetores fornecerão variância baixa para a classe a e variância alta para a classe b . Assim, W pode ser considerado um conjunto de filtros espaciais (BLANKERTZ *et al.*, 2008).

3.2 Métodos de extração de características

Entre os métodos de extração de características temos: métodos que extraem parâmetros espectrais (BLANCHARD; BLANKERTZ, 2004; MCFARLAND *et al.*, 2006), modelos auto-regressivos (BURKE *et al.*, 2005) e o método CSP (KOLES *et al.*, 1990). Para extrair as características de uma época X usando o método CSP, aplicamos a seguinte equação:

$$f = \log \left(\frac{\text{diag}(W_{CSP}^T X X^T W_{CSP})}{t} \right) \quad (3.3)$$

sendo:

- $W_{CSP} \in \mathbb{R}^{c \times m}$: um conjunto de m filtros espaciais (com $c = \text{número de canais}$ e $m = \text{número de autovetores selecionados}$).
- $\text{diag}(\cdot)$: uma função que retorna os elementos da diagonal principal de uma matriz quadrada.
- t : o número de amostras na época X .
- $f \in \mathbb{R}^2$: a característica CSP.

Assim, aplicando o procedimento matemático CSP (equação Equação 3.1, Equação 3.2 e Equação 3.3) podemos obter um vetor de características a partir de uma época X de treinamento.

3.3 Métodos de seleção de características

Entre os métodos de seleção de características de EEGs de imagética motora, temos: *Sequential Forward Feature Selection* (SFFS) (LEEB *et al.*, 2007), *Recursive feature/channel elimination* (RFE) (SCHRÖDER *et al.*, 2005; RAZA *et al.*, 2015) e algoritmos genéticos (SCHERER *et al.*, 2004).

Raza *et al.* (2015) propuseram o uso dos métodos *Sequential Forward Selection* (SFS) e *Sequential Backward Selection* (SBS) na etapa de seleção de características no método FBCSP para selecionar as bandas de frequência apropriadas para cada pessoa. Eles obtiveram melhores resultados do que o método FBCSP, mas com uma desvantagem: para algumas pessoas, eles usaram até 9 dos 10 filtros passa-banda no banco de filtros, o que aumenta o tempo de processamento, tornando o método lento e desvantajoso para um sistema BCI que precisa resultados em tempo real. Isto foi consequência dos métodos de seleção de bandas de frequência, que segundo Pudil *et al.* (1994), são métodos sub-ótimos que sofrem do chamado “nesting effect”, isto é, características descartadas não podem ser selecionadas novamente e características já adicionadas não podem ser removidas uma vez selecionadas.

O método SFFS foi proposto por (PUDIL *et al.*, 1994) para evitar o chamado “nesting effect” nos métodos SFS e SBS. Embora SFFS não garante selecionar o melhor subconjunto de características, seu desempenho é bom em comparação com outros métodos de seleção de características. A seguir, é descrito o método SFFS usado como parte do nosso método de seleção de características e bandas de frequência.

Seja Y o conjunto de todas as características CSP, S um conjunto vazio que conterá as características CSP selecionadas e $J(\cdot)$ nossa função critério para medir o nível de significância discriminativa de uma característica CSP:

- Passo 1: usando $J(\cdot)$, procurar a característica CSP mais significativa (mais discriminativa) em Y . Em seguida, adicioná-la a S .
- Passo 2: procurar a seguinte característica CSP f em $Y - S$ de modo que maximize $J(S \cup f)$. Em seguida, adicionar f a S .
- Passo 3: novamente, procurar a seguinte característica CSP f em $Y - S$ de modo que maximize $J(S \cup f)$. Em seguida, adicionar f a S .
- Passo 4: encontrar a característica CSP menos significativa $f_i \in S$. Se a última característica CSP f for a menos significativa, isto é $J(S - f) \geq J(S - f_i)$, $\forall f_i \in \{S - f\}$, então retornar ao passo 3, do contrário excluir f_i de S . Se o tamanho de S for dois, retornar ao passo 3, do contrário ir ao passo 5.
- Passo 5: encontrar a característica CSP f_i menos significativa em S . f_i pode ser removida de S se uma nova combinação de características CSP selecionadas posteriormente conse-

guirem melhores resultados. Se o tamanho de S for dois, retornar ao passo 3, do contrário repetir o passo 5.

Os passos do método SFFS são executados até alcançar o número desejado de características. Neste trabalho, a função critério $J(\cdot)$ é a média das acurácias obtidas por uma SVM em todas as repetições de um procedimento de validação cruzada de 10×10 —*fold*.

3.4 Métodos classificadores de características

No contexto do processamento de sinais biomédicos, especialmente com aplicação em sinais de EEG, é necessária a classificação dos dados em espaços característicos. Por exemplo, para detectar se há movimento da mão esquerda ou direita, precisam ser classificadas as características temporais e espaciais extraídas dos sinais de EEG da área motora do cérebro.

O objetivo da classificação é desenhar uma fronteira entre duas ou mais classes e rotulá-las com base em suas características extraídas. Em um espaço de características multidimensional, este limite toma a forma de um hiperplano de separação. O trabalho aqui é encontrar o melhor hiperplano que tenha uma distância máxima entre todas as classes para obter uma melhor generalização.

Várias técnicas de classificação têm sido usadas para classificar as características extraídas dos sinais de EEG. Entre elas, as Redes Neurais Artificiais (RNAs) (WANG *et al.*, 2004), Análise Discriminante Linear (ADL) (LEEB *et al.*, 2007), e Máquina de Vetores de Suporte (SVM do inglês *Support Vector Machine*) (NOVI *et al.*, 2007; ANG *et al.*, 2008) têm sido populares.

Neste trabalho, o método classificador supervisionado SVM é usado para realizar a classificação das características extraídas dos sinais de EEG de imagética motora. Este método foi escolhido porque apresenta as seguintes vantagens sobre outros métodos classificadores:

- Tem um parâmetro de regularização, o que faz com que o usuário pense em evitar o *overfitting*.
- Usa o chamado truque do kernel (*kernel trick*), para que se possa criar conhecimento especializado sobre o problema através da engenharia do kernel.
- É definido por um problema de otimização convexo (sem mínimos locais) para o qual existem métodos eficientes.
- Maximiza a margem de separação entre classes, o que faz que o modelo classificador seja mais robusto.

As SVMs já têm sido aplicadas em sinais de EEG para a remoção de artefatos oculares (SHOKER *et al.*, 2005c; SHOKER *et al.*, 2005a), detecção de crises epiléticas (GONZALEZ-VELLON *et al.*, 2003) e classificação dos movimentos do dedo esquerdo e direito (SHOKER *et al.*, 2005b). A seguir, é apresentado um resumo da teoria usada em uma SVM.

3.4.1 Máquina de Vetores de Suporte

Ao contrário de muitos problemas matemáticos em que alguma forma de fórmula explícita baseada em um número de entradas resulta em uma saída, em certas formas de classificação de dados não haverá nenhum modelo ou fórmula deste tipo. Em tais casos, o sistema deve ser treinado para ser capaz de reconhecer as entradas. Muitos algoritmos de classificação não funcionam eficientemente quando:

- O número de características é grande.
- Há uma ponderação não uniforme entre as características.
- Existe uma relação não linear entre as entradas e as saídas.
- A distribuição dos dados não é conhecida.
- A convergência não é convexa (monotônica), gerando mínimos locais.

Entre todos os classificadores supervisionados, a SVM é aquela que tem um bom desempenho nos casos anteriores (CORTES; VAPNIK, 1995; VAPNIK, 1995; BURGESS, 1998; BENNETT; CAMPBELL, 2000). A primeira versão do algoritmo de aprendizado da SVM foi inventado por Vladimir Vapnik e Alexey Chervonenkis in 1963 e o algoritmo atual foi proposto por Corinna Cortes e Vladimir Vapnik em 1993 (CORTES; VAPNIK, 1995; VAPNIK, 1995). Para entender o conceito da SVM, vamos mostrar um caso simples de classificação binária em um espaço bidimensional. Seja $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ nosso conjunto de dados de treinamento linearmente separável como mostrado na Figura 7.

Em cada par (x_i, y_i) , x_i representa um ponto, neste caso em $\mathbb{R}^2$, e $y_i \in \{-1, +1\}$ é o rótulo da classe do ponto x_i . Cada ponto x_i também é chamado de vetor. Uma função discriminante para classificar estes dados de treinamento poderia ser definida como:

$$f(x) = \text{sgn}(w^T x + b) = \begin{cases} +1 & \text{se } x \text{ pertence à primeira classe} \\ -1 & \text{se } x \text{ pertence à segunda classe} \end{cases}$$

Nesta formulação, w determina a orientação de um hiperplano discriminante. Claramente, existe um número infinito de possíveis hiperplanos que poderiam classificar corretamente esses dados de treinamento. Um desses possíveis hiperplanos é mostrado na Figura 7.

Figura 7 – Conjunto de dados linearmente separável e um exemplo hiperplano separador.

Fonte: Elaborada pelo autor.

Então, como é que faremos a escolha do hiperplano separador? Nosso objetivo deve ser encontrar um hiperplano que fique o mais longe possível de todos os pontos, porque se o hiperplano passar muito perto dos pontos, será sensível ao ruído e não generalizará corretamente no momento de classificar os dados. Assim, o algoritmo de aprendizado SVM baseia-se em encontrar o hiperplano que fornece a maior distância entre o hiperplano e os dados de treino. Essa distância recebe o nome de *margem* dentro da teoria da SVM. Portanto, o melhor hiperplano de separação maximiza a margem dos dados de treinamento. Este hiperplano seria semelhante ao mostrado na Figura 8.

Figura 8 – Um hiperplano de separação ótimo para dados de duas classes.

Fonte: Elaborada pelo autor.

Uma forma de encontrar o hiperplano de separação em um caso separável é construindo as envoltórias convexas (*convex hulls*) de cada conjunto de dados como mostrado na Figura 9,

onde as regiões envolvidas são as envoltórias convexas. Ao examinar as envoltórias, é possível determinar os pontos mais próximos situados nas envoltórias de cada classe. Observe na Figura 9 que três pontos foram identificados com círculos. Estes são os únicos pontos necessários para determinar o hiperplano ideal, e são comumente referidos como os vetores de suporte. Um hiperplano perpendicular aos vetores de suporte deve resultar em um classificador robusto. Em casos onde os dados são multidimensionais e a quantidade de pontos é grande, a solução gráfica para encontrar o hiperplano não será mais prática, pelo qual será necessária uma solução matemática.

Figura 9 – Determinação gráfica das envoltórias convexas, dos vetores de suporte (pontos destacados) e do hiperplano separador.

Fonte: Elaborada pelo autor.

Para mostrar como formular uma SVM, vamos começar com o caso mais simples: máquinas lineares treinadas em dados linearmente separáveis (será visto que na análise para o caso geral, máquinas não lineares treinadas em dados linearmente não separáveis resultam em um problema de programação quadrática muito semelhante). Os dados de treinamento serão $S = \{(x_i, y_i); i = 1, \dots, m\}$, $x_i \in \mathbb{R}^2$, $y_i \in \{-1, +1\}$. Agora suponha que um hiperplano separa os exemplos (pontos) positivos (classe 1) dos negativos (classe 2). Os pontos que caem no hiperplano, satisfazem:

$$w^T x + b = 0$$

sendo:

- w é perpendicular ao hiperplano.
- $\|w\|_2$ é a norma euclidiana de w .
- $|b|/\|w\|_2$ é a distância perpendicular entre o hiperplano e a origem.

Defina-se a “margem” de um hiperplano separador como mostrado na Figura 10. Para o caso de dados linearmente separáveis, o algoritmo da SVM simplesmente procura o hiperplano com a maior margem de separação.

Figura 10 – Hiperplanos de suporte H_1 e H_2 com a margem de separação máxima e as restrições para a máquina de vetores de suporte.

Fonte: Elaborada pelo autor.

A abordagem aqui é reduzir o problema para uma otimização convexa minimizando uma função quadrática sob restrições de desigualdade linear. Primeiro, deve-se notar que na definição de classificadores lineares existe um grau inerente de liberdade, na qual a função pode ser escalada arbitrária. Isto permite que as margens sejam ajustadas para serem iguais à unidade por simplicidade (os hiperplanos com uma margem funcional de unidade são por vezes referidos como hiperplanos canônicos) e subsequentemente minimizar a norma do vetor de peso. Para encontrar o hiperplano mais distante de ambas as classes de dados, as margens entre os hiperplanos canônicos de apoio para cada classe são simplesmente maximizadas. Os planos de suporte são empurrados para fora até encontrar os pontos de dados mais próximos, que são então considerados como os vetores de suporte, destacados na Figura 10. Portanto, uma vez que:

$$w^T x_i + b \geq +1 \text{ para } y_i = +1$$

$$w^T x_i + b \leq -1 \text{ para } y_i = -1$$

que podem ser combinados em: $y_i(w^T x_i + b) - 1 \geq 0, \forall i$. Para maximizar a margem entre os hiperplanos de suporte H_1 e H_2 , é necessário minimizar $w^T w$ sujeito a: $y_i(w^T x_i + b) \geq 1, \forall i$.

Para resolver este problema de otimização restrita, a restrição pode ser incorporada na função de custo principal usando multiplicadores de Lagrange. A fim de realizar a otimização de Lagrange, a chamada forma primal deve ser construída:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i [y_i (w^T x_i + b) - 1] \quad (3.4)$$

sendo α_i os multiplicadores de Lagrange. Assim, a função primal de Lagrange tem de ser minimizada em relação a w, b e maximizada com respeito a $\alpha_i \geq 0$. A construção da forma dual Lagrangiana clássica facilita esta solução. Isto é conseguido estabelecendo as derivadas do primal para zero e substituindo-as de volta para o primal. Consequentemente,

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^m \alpha_i y_i x_i = 0$$

assim

$$w = \sum_{i=1}^m \alpha_i y_i x_i. \quad (3.5)$$

Quanto à derivada em relação a b , obtemos:

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^m \alpha_i y_i = 0. \quad (3.6)$$

Se considerarmos a definição de w na Equação 3.5, substituímos ela na Equação 3.4 e simplificarmos, obteremos:

$$L(w, b, \alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y_i y_j \alpha_i \alpha_j x_i^T x_j - b \sum_{i=1}^m \alpha_i y_i.$$

Mas a partir da Equação 3.6, o último termo deve ser igual a zero, então obtém-se:

$$L(w, b, \alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y_i y_j \alpha_i \alpha_j x_i^T x_j$$

considerando $\alpha_i \geq 0$.

Estas equações podem ser resolvidas matematicamente (com a ajuda de um computador) usando algoritmos de programação quadrática. Existem vários algoritmos disponíveis dentro de inúmeros websites públicos (CRISTIANINI; SHAW-TAYLOR, 2000; CRISTIANINI, 2007).

No entanto, em muitas situações práticas os conjuntos de dados não são linearmente separáveis, ou seja, eles têm sobreposições no espaço dos dados). Portanto, o classificador de margem máxima descrito acima não será mais aplicável. Obviamente, é possível definir um

hiperplano não linear complexo para separar os conjuntos de dados perfeitamente, mas, como será visto depois, isso provoca *overfitting*, o que reduz a robustez do classificador.

Como pode ser visto na Figura 11, as envoltórias convexas se sobrepõem e os conjuntos de dados não são mais linearmente separáveis. A solução ideal onde nenhum ponto é classificado incorretamente e nenhum ponto está dentro da margem já não é viável. Isso significa que as restrições precisam ser relaxadas para permitir um mínimo de classificação errada.

Figura 11 – Regiões abrangidas para o caso não separável.

Fonte: Elaborada pelo autor.

Neste caso, os pontos que subsequentemente caem no lado errado da margem são considerados erros. Porém, a eles é atribuída uma menor influência (de acordo com uma variável de folga) na localização do hiperplano e, portanto, são considerados vetores de suporte (ver Figura 12). O classificador assim obtido é chamado de classificador de margem suave.

Para otimizar o classificador de margem suave, é necessário permitir que as restrições de margem sejam violadas de acordo com uma variável de folga ξ_i predefinida nas restrições, que então se tornam:

$$w^T x_i + b \geq +1 - \xi_i \quad \text{para } y_i = +1$$

$$w^T x_i + b \leq -1 + \xi_i \quad \text{para } y_i = -1$$

sujeito a $\xi_i \geq 0, \forall i$. Assim, para que o algoritmo funcione para conjuntos de dados linearmente não separáveis e seja menos sensível ao ruído, reformulamos nossa otimização da seguinte forma:

$$\min w^T w + C \sum_{i=1}^m \xi_i$$

sujeito a:

Figura 12 – Vectores de suporte em um caso não separável com um hiperplano linear, a margem suave de separação e o conceito de variável de folga.

Fonte: Elaborada pelo autor.

$$\begin{aligned} y_i(w^T x_i + b) &\geq 1 - \xi_i, \quad i = 1, \dots, m \\ \xi_i &\geq 0, \quad i = 1, \dots, m \end{aligned}$$

Assim, os exemplos podem ter margem inferior a 1, e se um exemplo tiver uma margem $1 - \xi_i$ (com $\xi > 0$) pagaríamos o custo da função objetivo aumentado por $C\xi_i$. O parâmetro de regularização C controla a ponderação relativa entre os objetivos de fazer o $\|w\|^2$ pequeno (que vimos anteriormente faz a margem grande) e de garantir que a maioria dos exemplos tenha uma margem maior o igual a 1.

Como antes, podemos formar o Lagrangiano:

$$L(w, b, \xi, \alpha, r) = \frac{1}{2} w^T w + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \alpha_i [y_i(x_i^T w + b) - 1 + \xi_i] - \sum_{i=1}^m r_i \xi_i.$$

Aqui, os α_i e r_i são os nossos multiplicadores de Lagrange (limitados a serem maiores que zero). Não iremos passar a derivação do dual novamente em pormenor, mas depois de colocar as derivadas com respeito a w e b a zero como antes, substituindo-as de volta e simplificando, obtemos a seguinte forma dual do problema:

$$\max_{\alpha} W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m y_i y_j \alpha_i \alpha_j x_i^T x_j$$

sujeito a:

$$0 \leq \alpha_i \leq C, i = 1, \dots, m$$

$$\sum_{i=1}^m \alpha_i y_i = 0.$$

Como antes, também temos que w pode ser expresso em termos de α_i como dado na Equação 3.5, de modo que depois de resolver o problema dual, podemos continuar a usar a seguinte equação para fazer nossas previsões:

$$w^T x + b = \left(\sum_{i=1}^m \alpha_i y_i x_i \right)^T x + b$$

$$= \sum_{i=1}^m \alpha_i y_i x_i x^T + b.$$

Observe que ao adicionar o parâmetro de regularização, a única mudança para o problema dual é que o que era originalmente uma restrição de $0 \leq \alpha_i$ passou a ser $0 \leq \alpha_i \leq C$.

Isto implica que o valor de C estabelece um limite superior para as variáveis de otimização Lagrangiana α_i . Isso às vezes é chamado de restrição de caixa. O valor de C oferece um equilíbrio entre a precisão do ajuste do modelo e a prevenção de *overfitting*. Um valor pequeno de C (i.e. < 1) limita significativamente a influência dos *outliers*, enquanto que um valor de C muito grande (ou infinito), faria a abordagem de margem suave (como na Figura 12) tornar-se idêntica à do classificador de margem máxima. Portanto, no uso do classificador de margem suave, a escolha do valor de C dependerá fortemente dos dados. A seleção apropriada do valor de C é de grande importância e é uma área de pesquisa, mas pode ser encontrado empiricamente (CHAPELLE *et al.*, 2002).

Não haverá alteração na formulação da SVM para os casos multidimensionais. A dimensão do hiperplano varia de acordo com o número características.

Kernels

Em muitos casos com conjuntos de dados não linearmente separáveis, o uso de uma função não linear pode ajudar a tornar os dados em conjuntos linearmente separáveis. Como pode ser visto na Figura 13, os conjuntos de dados são separáveis se um hiperplano não linear for usado. O mapeamento do kernel oferece uma solução alternativa através de uma projeção não linear dos dados a um espaço de características de maior dimensão para permitir a separação de tais casos.

Em vez de aplicar as SVMs usando as características de entrada originais x , podemos usar outras características $\phi(x)$, sendo ϕ uma função de mapeamento. Para fazer isso, simplesmente precisamos examinar nosso algoritmo anterior e substituir cada x por $\phi(x)$.

Figura 13 – Hiperplano discriminante não linear.

Fonte: Elaborada pelo autor.

Uma vez que o algoritmo pode ser escrito inteiramente em termos dos produtos internos $\langle x, z \rangle$, isto significa que substituiríamos todos esses produtos internos por $\langle \phi(x), \phi(z) \rangle$. Especificamente, dada uma função de mapeamento ϕ , definimos o Kernel correspondente como:

$$K(x, z) = \phi(x)^T \phi(z).$$

sendo x e z os vetores no espaço de entrada. Então, em todos os lugares em que anteriormente tínhamos o produto interno de x e z em nosso algoritmo, poderíamos simplesmente substituí-lo por $K(x, z)$, e nosso algoritmo agora estaria aprendendo com as características ϕ . Desta forma, todos os benefícios do método SVM linear original são mantidos. Alguns dos kernels mais utilizados são:

Quadro 2 – Kernels mais usados nas SVMs

Tipo de kernel	Função correspondente	Comentário
Polinomial	$K(x, z) = (x^T z + 1)^p$	d : parâmetro livre
Gaussiano	$K(x, z) = \exp\left(-\frac{\ x-z\ ^2}{2\sigma^2}\right)$	σ : parâmetro livre
Sigmoidal	$K(x, z) = \tanh(\beta_0 x z + \beta_1)$	Restrito a alguns valores de β_0 e β_1

Fonte: Haykin (1998).

Um problema relacionado com as SVMs é que é possível ajustar um hiperplano usando um kernel apropriado aos dados para evitar sobreposição dos conjuntos (ou casos não-separáveis) e, portanto, produzir um classificador sem erro no conjunto de treinamento. Porém, é improvável que esse classificador generalize corretamente. Mais especificamente, o principal problema com isto é que o sistema pode não ser mais robusto, uma vez que um teste ou uma nova entrada pode ser facilmente classificado erroneamente (CHAPELLE *et al.*, 2002).

MÉTODO DE SELEÇÃO PROPOSTO

O método proposto para a seleção de características e bandas de frequências é inserido em uma nova configuração para o método *Filter Bank Common Spatial Pattern* (FBCSP) para a classificação de sinais de EEG de imagética motora. Na seção 4.1 é apresentado o método FBCSP. Na seção 4.2, é descrito nosso método de seleção de características e bandas de frequência. Na seção 4.3 é descrita a base de dados usada para avaliar nosso método e por fim, na seção 4.4 são apresentados os resultados da avaliação do nosso método.

4.1 Filter Bank Common Spatial Pattern

O método *Filter Bank Common Spatial Pattern* (FBCSP) foi proposto por Ang *et al.* (2008) como uma melhora do método *Sub-band Common Spatial Pattern* (SBCSP) (NOVI *et al.*, 2007). FBCSP é composto de quatro etapas progressivas como ilustrado na Figura 14. Na primeira etapa, os sinais de EEG são filtrados usando um banco de filtros composto por nove filtros passa-banda nas bandas de frequência de 4–8, 8–12, 12–16, 16–20, 20–24, 24–28, 28–32, 32–36 e 36–40 Hz. A segunda etapa emprega o método *Common Spatial Patterns* (CSP) para extrair características dos sinais de EEG filtrados. A terceira e quarta etapas realizam a seleção e a classificação das características, respectivamente. Qualquer método pode ser utilizado nas duas últimas etapas, mas para a *BCI Competition IV*, FBCSP foi configurado com os algoritmos *Mutual Information-based Best Individual Feature* (MIBIF) e *Mutual Information-based Rough Set Reduction* (MIRSR) para realizar a seleção das características e o classificador Naive Bayes junto com o algoritmo *Parzen-window* (NBPW) para a classificação (ANG *et al.*, 2008).

Figura 14 – Arquitetura do método FBCSP.

Fonte: Adaptada de Ang *et al.* (2008).

4.2 Busca exaustiva em um espaço de bandas de frequência restrito

Neste trabalho, o método proposto para encontrar as bandas de frequência que contêm as características discriminativas, tem o objetivo de melhorar a acurácia na classificação dos sinais de EEG de imagética motora, e é parte de uma nova configuração para o método FBCSP. Esta nova configuração tem duas fases, uma para selecionar as bandas de frequência que contenham as características discriminativas e a outra para a classificação.

A fase de seleção de bandas de frequências é composta de três etapas como mostrado na Figura 15. Na primeira fase, cada segmento de EEG, de agora em diante denominado época, utilizado para treinar nosso método é filtrado em 10 bandas de frequência diferentes. Em seguida, na segunda etapa, é extraído um conjunto de características, de agora em diante chamadas de características CSP, utilizando o método CSP. Finalmente, na terceira etapa, usamos o método *Sequential Forward Floating Selection* (SFFS) e uma Busca Exaustiva Restrita (RES do inglês *Restricted Exhaustive Search*) dentro de um espaço de busca reduzido para determinar quais bandas de frequência mantêm padrões discriminativos para obter uma boa acurácia na classificação.

Para a fase de classificação, o nosso método também é composto por três etapas, como ilustrado na Figura 16. Mas com a diferença de que agora, as épocas são apenas filtradas nas bandas de frequência selecionadas na fase anterior; e na última etapa, o método classificador SVM é introduzido para classificar as características CSP extraídas na etapa anterior.

Figura 15 – Arquitetura para a fase de seleção de bandas de frequência do método proposto.

Fonte: Elaborada pelo autor.

Figura 16 – Arquitetura para a fase de classificação do método proposto.

Fonte: Elaborada pelo autor.

4.2.1 Filtragem de frequências

Já que estamos interessados nos ritmos sensório-motores, que estão na banda de frequências de 8 a 30 Hz (PFURTSCHELLER; NEUPER, 1997; PFURTSCHELLER *et al.*, 1997; PFURTSCHELLER; SILVA, 1999; PFURTSCHELLER *et al.*, 2000; PICHIORRI *et al.*, 2011), usamos um banco de filtros que abrange essa banda de frequências, composto de 10 filtros passa-banda Chebyshev Tipo II, cada um deles com uma largura de banda igual a 4 Hz e uma sobreposição de 2 Hz com o filtro seguinte, isto é, 8–12, 10–14, 12–16, 14–18, 16–20, 18–22, 20–24, 22–26, 24–28 e 26–30 Hz, como mostrado na Figura 15. Este banco de filtros já foi aplicado por Raza *et al.* (2015).

A vantagem deste banco sobre o banco de filtros em FBCSP é a sobreposição. Se uma pessoa tiver algum ERD/ERS acontecendo em, por exemplo, na banda de frequências de 10 a 14 Hz, usando o banco de filtros em FBCSP, o ERD/ERS ficaria dividido em duas bandas (8–12 Hz e 12–16 Hz), o que diminuiria a qualidade das características extraídas.

A configuração proposta para o banco de filtros é utilizada apenas na fase de seleção

das bandas de frequências. Para a fase de classificação, as épocas são filtradas só nas bandas de frequência selecionadas.

4.2.2 Extração de características

Como em FBCSP, nosso método utiliza o procedimento matemático CSP para encontrar um filtro espacial para cada conjunto de épocas filtradas em uma banda de frequências específica.

Uma vez que o conjunto de dados utilizado neste trabalho para avaliar o método proposto tem três canais de EEG, a matriz W é composta por três autovetores. Consequentemente, há duas opções para construir a matriz de filtros espaciais: usar todos os autovetores como filtros ou apenas os dois autovetores que fornecem a maior/menor variância para cada classe de imagética motora. Neste trabalho, foi escolhida a segunda opção, isto é, foram utilizados o primeiro e o último autovetor de W para compor nosso conjunto de filtros espaciais W_{CSP} .

Para extrair as características de uma época X , aplicamos a equação Equação 3.3. Assim, aplicando CSP na fase de seleção de bandas de frequência, podemos obter um vetor de características $F = [f_1, f_2, \dots, f_{10}]$ a partir de uma época X de treinamento. Cada característica f_i corresponde a uma época filtrada na banda de frequências i , sendo i uma das dez bandas de frequência no banco de filtros.

4.2.3 Seleção de características (Seleção de frequências)

Nesta etapa, selecionamos as características CSP mais discriminativas, e como consequência desta seleção, é possível identificar quais bandas de frequência são relevantes para a classificação, já que cada característica CSP resulta de uma época filtrada em uma banda de frequências específica. Além disso, essa seleção tornará a classificação mais eficiente e interpretável.

Nosso método é composto dos métodos SFFS e uma busca exaustiva restrita. A seguir explicamos como busca exaustiva restrita é aplicada.

Busca Exaustiva Restrita

Como o método SFFS não garante que obteremos as melhores n características CSP, uma busca exaustiva restrita (RES) é usada para encontrá-las. A restrição consiste em encontrar apenas a combinação $C(m, n)$ de características CSP mais significativa, sendo m o número de filtros passa-banda no banco de filtros. Assim, esta restrição irá reduzir o espaço de busca de 2^m para $C(m, n) = m! / (n!(m - n)!)$ possíveis combinações. Dado que cada característica CSP está relacionada com uma banda de frequência, as características CSP selecionadas determinarão quais bandas de frequência são relevantes para classificar as tarefas MI. A significância de uma característica CSP é medida com a mesma função critério utilizada no método SFFS.

Com os dois métodos explicados acima, selecionamos as bandas de frequência seguindo um procedimento de dois passos como mostrado no próximo algoritmo:

Algoritmo 1 – Algoritmo de seleção de bandas de frequências

```

1: procedimento SELECIONAR( $Y$ )                                 $\triangleright Y \leftarrow$  características de todos os sujeitos
2:    $n \leftarrow 1$ 
3:    $S_{n+1} \leftarrow \text{SFFS}(Y, n)$ 
4:   repita
5:      $S_n \leftarrow S_{n+1}$ 
6:      $n \leftarrow n + 1$ 
7:      $S_{n+1} \leftarrow \text{SFFS}(Y, n)$ 
8:   até  $CV(S_{n+1}) \approx CV(S_n)$ 
9:    $n \leftarrow n - 1$ 
10:   $S \leftarrow \text{RES}(Y, n)$ 
11:  retorna  $S$ 
12: fim procedimento
  
```

- No primeiro passo (linhas 1-8), usamos o método SFFS para determinar, para todos os sujeitos em paralelo, quantas bandas de frequência são suficientes para obter padrões discriminativos para classificar as tarefas de IM. Começamos buscando um subconjunto de tamanho 1 (linha 3) e interrompemos a busca quando o subconjunto de tamanho $n + 1$ não oferece uma diferença significativa nos resultados de validação cruzada (CV do inglês *Cross-validation*) em relação ao subconjunto anterior de tamanho n (linha 8). Usamos um *paired t-test* para verificar a significância dos resultados e definimos nosso nível de significância α em 0.05. O número ótimo de bandas de frequência é denotado por n .
- Na segunda etapa (linhas 9-11), é realizada uma busca exaustiva restrita (RES) para encontrar, para todos os sujeitos em paralelo, a melhor combinação de n bandas de frequência de entre todas as disponíveis no banco de filtros. Em seguida, as bandas de frequência selecionadas para cada pessoa são retornadas em S .

4.2.4 Classificação

As características extraídas das épocas filtradas nas bandas de frequências selecionadas são classificadas usando uma SVM. Este modelo de aprendizagem supervisionado mapeia as características para um espaço de grande dimensão e usa apenas um subconjunto delas, chamadas de vetores de suporte, para criar uma função de decisão linear. Este classificador foi escolhido porque tem alta capacidade de generalização, vem com garantias teóricas sobre o desempenho e não é afetado pelos mínimos locais. Configuramos a SVM com um parâmetro $C = 0.04$ e um kernel linear, porque é menos propenso a *overfitting* do que os kernels não lineares.

4.3 Materiais

O método proposto neste trabalho foi avaliado usando o conjunto de dados 2b da *BCI Competition IV* (TANGERMANN *et al.*, 2012). Este conjunto de dados inclui EEGs com três canais (C3, Cz e C4). Cada canal foi registrado de forma bipolar, isto é, que o registro dos sinais é o resultado da diferença da atividade elétrica registrada por dois eletrodos adjacentes. No caso desta base de dados, não foram divulgados os nomes dos eletrodos adjacentes aos eletrodos C3, Cz e C4 que foram utilizados para gerar os sinais bipolares.

Nove sujeitos realizaram os ensaios de IM que constituem esta base de dados. A frequência de amostragem dos EEGs é de 250 Hz, isto é, 250 amostras cada segundo. Para cada sujeito, existem cinco sessões de gravação: três para treinamento (01T, 02T e 03T) e duas para avaliação (04E e 05E). Cada sessão contém vários ensaios de duas classes de IM, IM da mão esquerda e IM da mão direita. As sessões 01T e 02T foram gravadas sem feedback, e as sessões 03T, 04E e 05E foram gravadas com feedback, ou seja, os sujeitos sabiam se estavam realizando de forma correta (*smiley* feliz de cor verde) ou não (*smiley* triste de cor vermelho) a tarefa de IM. A Figura 17 ilustra o protocolo de gravação para cada ensaio em cada tipo de sessão. Para os ensaios das sessões sem feedback, foi apresentada uma dica no segundo 3 com uma duração de 1.25 segundos para indicar que tarefa IM tinha de ser realizada. Estes tipos de ensaios têm uma duração de 7 segundos. Para os ensaios das sessões com feedback, uma dica foi apresentada a partir do segundo 3 ao 7.5. A duração destes ensaios é de 7.5 segundos. Mais detalhes sobre este conjunto de dados podem ser encontrados em Leeb *et al.* (2007), Tangermann *et al.* (2012).

Figura 17 – Protocolos de gravação. (a) Os ensaios nas sessões 01T e 02T foram registrados sem feedback. (b) Para os ensaios nas sessões 03T, 04E e 05E, o feedback começou no segundo 3.5 e terminou no segundo 7.5.

Fonte: Adaptada de Tangermann *et al.* (2012).

4.4 Avaliação experimental

Para garantir que nossos experimentos sejam facilmente reproduzíveis, disponibilizamos nosso código em um repositório público em GitHub (BUSTIOS, 2017). A seguir, descrevemos o procedimento experimental executado:

- Para classificar uma amostra x_t , foram tomadas 499 amostras antes de x_t , ou seja x_{t-499} , x_{t-498} , ..., x_{t-1} . Assim, para as fases de seleção de bandas de frequências e classificação do nosso método, foram usadas épocas de 2 segundos, o que equivale a 500 amostras.
- Para a fase de seleção de bandas, as épocas foram tomadas a partir do segundo 3.5 de todos os ensaios das:
 - sessões 01T e 03T para o sujeito 1.
 - sessões 01T, 02T e 03T para os sujeitos 2 e 3.
 - sessão 03T para os sujeitos 4, 5, 6, 7, 8 e 9.
- Esta seleção de sessões foi proposta por Ang *et al.* (2012). Neste trabalho, outras combinações também foram avaliadas, mas essa seleção foi a que obteve melhores resultados em uma validação cruzada de 10×10 —fold.
- As sessões selecionadas foram também usadas para calcular os filtros espaciais e para treinar a SVM na fase de classificação.

4.4.1 Fase de seleção de características

Seguindo as etapas desta fase, a primeira tarefa foi filtrar cada época usando os 10 filtros passa-banda no banco de filtros. Após a filtragem, a segunda tarefa foi extrair as características CSP. A Figura 18 ilustra as características CSP extraídas para a pessoa 4 em cada banda de frequências.

Na terceira etapa, usando nosso método de seleção de bandas, foi determinado o número ótimo de bandas de frequência para cada pessoa. A Tabela 1 mostra que, segundo os resultados da validação cruzada 10×10 —fold, duas bandas de frequências são suficientes para obter bons resultados na classificação. Como já foi mencionado, ao encontrar o número ótimo de características CSP, também estamos encontrando o número ótimo de bandas de frequências necessárias. Assim, o algoritmo de nosso método selecionador começa procurando a característica CSP mais significativa usando o método SFFS. Depois de encontrá-la, começa a procurar as 2 características mais significativas e compara os resultados da validação cruzada usando 1 e 2 características CSP. Já que existe uma melhora significativa nos resultados, com um valor $p = 0.015$, nosso algoritmo procura as 3 características mais significativas. Os resultados da validação cruzada usando 3 características CSP não mostram uma melhora significativa em

Figura 18 – Características CSP extraídas de todas as épocas da sessão para treinamento da pessoa 4, filtradas em 10 diferentes bandas de frequências.

Fonte: Elaborada pelo autor.

comparação aos resultados de usar 2 características CSP, com um valor $p = 0.083$. Com este resultado, nosso algoritmo pára a busca e começa a executar a busca exaustiva restrita a procurar a melhor combinação de 2 características CSP. Na Tabela 1 são apresentados resultados de usar até 5 características CSP selecionadas, apenas para mostrar que também não houve melhora significativa nos resultados.

Tabela 1 – Acurácia estimada por uma validação cruzada de 10×10 -fold e características CSP de 1 a 5 bandas de frequências selecionadas usando o método SFFS.

Sujeito	Acurácia (%)				
	1 banda	2 bandas	3 bandas	4 bandas	5 bandas
1	79.68	82.29	82.57	82.04	82.11
2	58.80	61.62	63.15	64.47	64.15
3	60.25	60.72	63.25	64.10	63.58
4	99.69	100.0	100.0	100.0	100.0
5	83.75	88.63	89.31	90.94	90.75
6	79.44	83.75	84.12	84.81	84.69
7	89.81	90.44	90.81	91.06	92.81
8	90.19	90.94	91.00	90.75	90.69
9	85.06	85.19	84.75	85.81	85.69
Média	80.74	82.62	83.22	83.78	83.83

Uma vez determinado o número ótimo de bandas de frequência, o próximo passo é usar a busca exaustiva restrita para encontrar a melhor combinação de duas bandas de frequência para cada pessoa. Os resultados desta busca são mostrados na Tabela 2. Como podemos ver, houve uma melhora nos resultados da validação cruzada usando estas bandas de frequência.

Tabela 2 – Bandas de frequência selecionadas usando uma busca exaustiva restrita.

Sujeito	Bandas de frequência selecionadas (Hz)	Acurácia (%)
1	10 - 14, 20 - 24	82.29
2	10 - 14, 20 - 24	61.62
3	8 - 12, 18 - 22	61.72
4	8 - 12, 10 - 14	100.0
5	22 - 26, 26 - 30	88.63
6	10 - 14, 12 - 16	83.75
7	12 - 16, 18 - 22	91.50
8	8 - 12, 10 - 14	90.94
9	18 - 22, 22 - 26	85.19
Média		82.85

4.4.2 Fase de classificação

Na Tabela 3 são apresentados os máximos valores kappa obtidas ao longo do tempo de execução dos ensaios das sessões de avaliação para cada sujeito. As máximas acurácias obtidas também são apresentadas na Tabela 4. Os resultados são comparados as abordagens aFBCSP (ANG *et al.*, 2011), FBCSP (ANG *et al.*, 2012), HCRF (SAA; ÇETIN, 2011), UB Eval (RAZA *et al.*, 2016) e EMD (GAUR *et al.*, 2015), que também foram avaliadas no conjunto de dados 2b da *BCI Competition IV*, mostrando que, em média, o nosso método é melhor. Além disso, nosso método usa apenas duas bandas de frequência para a classificação das épocas.

Para o método EMD, apresentamos a média das acurácias da classificação dos ensaios nas sessões de avaliação, já que foram apresentadas separadamente para cada sessão (GAUR *et al.*, 2015), com o objetivo de poder comparar os resultados.

Tabela 3 – Resultados da classificação das épocas extraídas das sessões de avaliação usando o coeficiente Kappa como métrica.

Sujeito	Valores Kappa			
	aFBCSP	FBCSP	HCRF	Método proposto
1	0.406	0.400	0.560	0.462
2	0.179	0.207	0.240	0.343
3	0.150	0.219	0.180	0.263
4	0.963	0.950	0.950	0.956
5	0.863	0.856	0.930	0.856
6	0.606	0.613	0.720	0.656
7	0.575	0.550	0.510	0.631
8	0.856	0.850	0.800	0.863
9	0.738	0.744	0.710	0.756
Média	0.593	0.599	0.622	0.643

Tabela 4 – Resultados da classificação das épocas extraídas das sessões de avaliação usando a acurácia como métrica.

Sujeito	Acurácia (%)		
	UB Eval	EMD	Método proposto
1	70.31	62.80	73.13
2	61.25	67.05	67.14
3	59.69	98.70	63.13
4	97.19	88.40	97.81
5	90.94	96.25	92.81
6	85.63	75.25	82.81
7	78.44	72.15	81.56
8	88.75	87.80	93.13
9	78.44	85.25	87.81
Média	78.96	81.52	82.15

CONCLUSÃO

A grande e importante quantidade de aplicações dos EEGs, tais como o monitoramento dos processos mentais e doenças neurológicas, justifica a necessidade de métodos mais precisos para analisar esse tipo de dados e identificar as características e padrões presentes. Pesquisas e avanços nesses métodos podem ajudar a entender o funcionamento do cérebro e os processos que acontecem nele.

A imagética motora é um processo mental com aplicação direta nos sistemas BCI. Os sistemas BCI baseados em imagética motora têm aplicações tais como a restauração motora mediante neuróproteses em pessoas com algum problema motor ou nos jogos eletrônicos. Nestas aplicações é necessário identificar e classificar a tarefa de imagética motora realizada pela pessoa para depois traduzir essa tarefa em um comando. Porém, há evidência na literatura que demonstra que imagética motora produz modulações nos sinais de EEG em frequências específicas para cada pessoa, o que faz da identificação destes padrões uma tarefa complicada.

Nesse cenário, o método de seleção de bandas de frequências apresentado neste trabalho é de interesse para a classificação de sinais de EEG de imagética motora. O método consiste em aplicar o método *Sequential Forward Floating Selection* para encontrar o número ótimo de bandas de frequências necessárias para classificar as tarefas de IM, e uma busca exaustiva restrita a procurar a melhor combinação desse número ótimo de bandas de frequências de todas as disponíveis em um banco de filtros passa-banda. Além do método proposto para seleção de bandas de frequência, foi apresentada uma nova configuração para o método FBCSP.

Nosso método de seleção de bandas de frequências inserido na nova configuração proposta para o método FBCSP deu como resultado um novo método classificador de EEGs de imagética, o qual foi avaliado usando um conjunto de dados disponível publicamente. Nessa avaliação, foi demonstrado que nosso método é mais preciso do que os métodos avaliadas no mesmo conjunto de dados. Particularmente, temos mostrado que o nosso método obteve melhores resultados usando apenas duas bandas de frequência de dez disponíveis. Assim, o problema

descrito na Introdução deste trabalho foi resolvido como demonstrado no Capítulo 4, o que permitiu validar a hipótese do trabalho.

O código fonte da implementação dos métodos propostos neste trabalho, assim como também dos testes realizados, foi disponibilizado em um repositório público de GitHub, para permitir que outras pessoas possam usar, confirmar e ampliar nosso trabalho.

5.1 Trabalhos futuros

Durante o desenvolvimento deste trabalho foram identificadas diversas questões interessantes que podem contribuir no seguimento deste trabalho. Algumas dessas questões são:

- Estender nosso método para que, além de selecionar bandas de frequência, selecione os canais de EEG mais relevantes para classificar tarefas de imagética motora em um EEG com grande quantidade de canais.
- Usar um *ensemble* de métodos classificadores como função critério de seleção de características e como classificador para melhorar a acurácia na classificação.
- Reduzir o tamanho das épocas para classificar uma amostra nos EEGs.

REFERÊNCIAS

ANG, K. K.; CHIN, Z. Y.; WANG, C.; GUAN, C.; ZHANG, H. Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. **Frontiers in neuroscience**, v. 6, p. 39, jan 2012. ISSN 1662-453X. Citado nas páginas 26, 40, 59 e 61.

ANG, K. K.; CHIN, Z. Y.; ZHANG, H.; GUAN, C. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. In: **International Joint Conference on Neural Networks (IJCNN)**. [S.l.]: IEEE, 2008. p. 2390–2397. ISBN 978-1-4244-1820-6. ISSN 1098-7576. Citado nas páginas 40, 43, 53 e 54.

ANG, K. K.; CHIN, Z. Y.; ZHANG, H.; GUAN, C. Filter Bank Common Spatial Pattern (FBCSP) algorithm using online adaptive and semi-supervised learning. In: **The 2011 International Joint Conference on Neural Networks**. [S.l.]: IEEE, 2011. p. 392–396. ISBN 978-1-4244-9635-8. ISSN 2161-4393. Citado na página 61.

ASANAGI. **Electrode locations of International 10-20 system for EEG (electroencephalography) recording**. 2010. Wikimedia Commons. Disponível em: <https://commons.wikimedia.org/wiki/File:21_electrodes_of_International_10-20_system_for_EEG.svg>. Citado na página 32.

AZEVEDO, F. A. C.; CARVALHO, L. R. B.; GRINBERG, L. T.; FARFEL, J. M.; FERRETTI, R. E. L.; LEITE, R. E. P.; FILHO, W. J.; LENT, R.; HERCULANO-HOUZEL, S. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. **Journal of Comparative Neurology**, v. 513, n. 5, p. 532–541, 2009. ISSN 00219967. Citado na página 31.

BABILONI, F.; CINCOTTI, F.; LAZZARINI, L.; MILLÁN, J.; MOURIÑO, J.; VARSTA, M.; HEIKKONEN, J.; BIANCHI, L.; MARCIANI, M. G. Linear classification of low-resolution EEG patterns produced by imagined hand movements. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 2, p. 186–188, 2000. ISSN 10636528. Citado na página 40.

BAI, X.; WANG, X.; ZHENG, S.; YU, M. The offline feature extraction of four-class motor imagery EEG based on ICA and Wavelet-CSP. In: **Proceedings of the 33rd Chinese Control Conference**. IEEE, 2014. p. 7189–7194. ISBN 978-9-8815-6387-3. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6896188>>. Citado na página 40.

BAILLET, S.; MOSHER, J.; LEAHY, R. Electromagnetic brain mapping. **IEEE Signal Processing Magazine**, v. 18, n. 6, p. 14–30, 2001. ISSN 10535888. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=962275>>. Citado na página 31.

BENNETT, K. P.; CAMPBELL, C. Support vector machines: hype or hallelujah? **ACM SIGKDD Explorations Newsletter**, v. 2, n. 2, p. 1–13, 2000. ISSN 19310145. Disponível em: <<http://portal.acm.org/citation.cfm?doid=380995.380999>>. Citado na página 44.

BIRBAUMER, N.; COHEN, L. G. Brain-computer interfaces: communication and restoration of movement in paralysis. **The Journal of Physiology**, Blackwell Publishing Ltd, v. 579, n. 3, p. 621–636, mar 2007. Citado na página 25.

BLANCHARD, G.; BLANKERTZ, B. BCI competition 2003 - Data set IIa: Spatial patterns of self-controlled brain rhythm modulations. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1062–1066, 2004. ISSN 00189294. Citado nas páginas 40 e 41.

BLANKERTZ, B.; TOMIOKA, R.; LEMM, S.; KAWANABE, M.; MÜLLER, K.-R. Optimizing spatial filters for robust EEG single-trial analysis. **IEEE Signal Processing Magazine**, v. 25, p. 41–56, 2008. ISSN 10535888. Citado na página 41.

BONNET, L.; LOTTE, F.; LECUYER, A. Two Brains, One Game: Design and Evaluation of a Multiuser BCI Video Game Based on Motor Imagery. **IEEE Transactions on Computational Intelligence and AI in Games**, v. 5, n. 2, p. 185–198, jun 2013. ISSN 1943-068X. Citado na página 25.

BROWN, P.; SALENIUS, S.; ROTHWELL, J. C.; HARI, R. Cortical correlate of the Piper rhythm in humans. **Journal of neurophysiology**, v. 80, n. 6, p. 2911–7, dez. 1998. ISSN 0022-3077. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/9862895>>. Citado na página 34.

BURGES, C. J. C. A Tutorial on Support Vector Machines for Pattern Recognition. **Data Mining and Knowledge Discovery**, Kluwer Academic Publishers, v. 2, n. 2, p. 121–167, jun. 1998. ISSN 1384-5810. Disponível em: <<http://dl.acm.org/citation.cfm?id=593419.593463>>. Citado na página 44.

BURKE, D. P.; KELLY, S. P.; De Chazal, P.; REILLY, R. B.; FINUCANE, C. A parametric feature extraction and classification strategy for brain-computer interfacing. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 13, n. 1, p. 12–17, 2005. ISSN 15344320. Citado na página 41.

BUSTIOS, P. **Repositorio de código fonte**. 2017. GitHub. Disponível em: <<https://github.com/bustios/res>>. Citado nas páginas 29 e 59.

BUSTIOS, P.; ROSA, J. L. Restricted exhaustive search for frequency band selection in motor imagery classification. In: **2017 International Joint Conference on Neural Networks (IJCNN)**. IEEE, 2017. p. 4208–4213. ISBN 978-1-5090-6182-2. Disponível em: <<http://ieeexplore.ieee.org/document/7966388/>>. Citado na página 29.

CAPLAN, J. B.; MADSEN, J. R.; RAGHAVACHARI, S.; KAHANA, M. J. Distinct patterns of brain oscillations underlie two basic parameters of human maze learning. **Journal of neurophysiology**, v. 86, n. 1, p. 368–80, jul. 2001. ISSN 0022-3077. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/11431517>>. Citado na página 33.

CHAPELLE, O.; VAPNIK, V.; BOUSQUET, O.; MUKHERJEE, S. Choosing Multiple Parameters for Support Vector Machines. **Machine Learning**, Kluwer Academic Publishers, v. 46, n. 1/3, p. 131–159, 2002. Disponível em: <<http://link.springer.com/10.1023/A:1012450327387>>. Citado nas páginas 51 e 52.

CHERNINSKYI, A. **Human EEG with prominent alpha-rhythm**. 2015. Wikimedia Commons. Disponível em: <https://commons.wikimedia.org/wiki/File:Human_EEG_with_prominent_alpha-rhythm.png>. Citado na página 26.

CNX OpenStax. **Biology**. 2016. Wikimedia Commons. Disponível em: <https://commons.wikimedia.org/wiki/File:Figure_35_03_03.png>. Citado na página 36.

CORTES, C.; VAPNIK, V. Support-Vector Networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995. Citado na página 44.

CRISTIANINI, N. **Kernel Machines**. 2007. Disponível em: <<http://www.kernel-machines.org/>>. Citado na página 48.

CRISTIANINI, N.; SHAWE-TAYLOR, J. **An introduction to support vector machines and other kernel-based learning methods**. Cambridge University Press, 2000. ISBN 0521780195. Disponível em: <www.support-vector.net>. Citado na página 48.

CROFT, R. J.; BARRY, R. J. Removal of ocular artifact from the EEG: a review. **Neurophysiologie clinique/Clinical neurophysiology**, v. 30, n. 1, p. 5–19, fev. 2000. ISSN 0987-7053. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0987705300000551>>. Citado na página 35.

DORNHEGE, G.; BLANKERTZ, B.; KRAULEDAT, M.; LOSCH, F.; CURIO, G.; MÜLLER, K. R. Combined optimization of spatial and temporal filters for improving brain-computer interfacing. **IEEE Transactions on Biomedical Engineering**, v. 53, n. 11, p. 2274–2281, 2006. ISSN 00189294. Citado na página 26.

FATOURECHI, M.; BASHASHATI, A.; WARD, R. K.; BIRCH, G. E. EMG and EOG artifacts in brain computer interface systems: A survey. **Clinical neurophysiology: official journal of the International Federation of Clinical Neurophysiology**, v. 118, n. 3, p. 480–94, mar. 2007. ISSN 1388-2457. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1388245706015124>>. Citado nas páginas 35 e 39.

FERNÁNDEZ, T.; HARMONY, T.; RODRÍGUEZ, M.; BERNAL, J.; SILVA, J.; REYES, A.; MAROSI, E. EEG activation patterns during the performance of tasks involving different components of mental calculation. **Electroencephalography and clinical neurophysiology**, v. 94, n. 3, p. 175–82, mar. 1995. ISSN 0013-4694. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/7536152>>. Citado na página 33.

FREEMAN, W. J.; QUIAN-QUIROGA, R. **Imaging Brain Function With EEG**. New York, NY: Springer New York, 2013. ISBN 978-1-4614-4983-6. Disponível em: <<http://link.springer.com/10.1007/978-1-4614-4984-3>>. Citado nas páginas 31 e 33.

GAGGIOLI, A.; MORGANTI, F.; MENEGHINI, A.; POZZATO, I.; GREGGIO, G.; PIGATTO, M.; RIVA, G. Computer-guided mental practice in neurorehabilitation. **Studies in health technology and informatics**, v. 145, p. 195–208, jan. 2009. ISSN 0926-9630. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/19592795>>. Citado na página 28.

GAUR, P.; PACHORI, R. B.; PRASAD, G. An empirical mode decomposition based filtering method for classification of motor-imagery EEG signals for enhancing brain-computer interface. In: **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.]: IEEE, 2015. p. 1–7. ISBN 978-1-4799-1960-4. Citado na página 61.

GONZALEZ-VELLON, B.; SANEI, S.; CHAMBERS, J. Support vector machines for seizure detection. In: **Proceedings of the 3rd IEEE International Symposium on Signal Processing and Information Technology**. IEEE, 2003. p. 126–129. ISBN 0-7803-8292-7. Disponível em: <<http://ieeexplore.ieee.org/document/1341076/>>. Citado na página 44.

HAYKIN, S. **Neural networks : a comprehensive foundation**. [S.l.]: Prentice Hall, 1998. ISBN 0780334949. Citado na página 52.

KLEM, G. H.; LÜDERS, H. O.; JASPER, H. H.; ELGER, C. The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology. **Electroencephalography and clinical neurophysiology. Supplement**, v. 52, p. 3–6, jan. 1999. ISSN 0424-8155. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/10590970>>. Citado nas páginas 31 e 32.

KLIMESCH, W. EEG-alpha rhythms and memory processes. **International Journal of Psychophysiology**, v. 26, n. 1-3, p. 319–340, jun. 1997. ISSN 01678760. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167876097007733>>. Citado na página 34.

KOLES, Z. J.; LAZAR, M. S.; ZHOU, S. Z. Spatial patterns underlying population differences in the background EEG. **Brain Topography**, v. 2, n. 4, p. 275–284, 1990. ISSN 0896-0267. Citado nas páginas 26, 40 e 41.

LEE, K.-H.; WILLIAMS, L. M.; BREAKSPEAR, M.; GORDON, E. Synchronous Gamma activity: a review and contribution to an integrative neuroscience model of schizophrenia. **Brain Research Reviews**, v. 41, n. 1, p. 57–78, jan. 2003. ISSN 01650173. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165017302002205>>. Citado na página 34.

LEEB, R.; LEE, F.; KEINRATH, C.; SCHERER, R.; BISCHOF, H.; PFURTSCHELLER, G. Brain-computer communication: Motivation, aim, and impact of exploring a virtual apartment. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 15, n. 4, p. 473–482, dec 2007. ISSN 15344320. Citado nas páginas 25, 40, 42, 43 e 58.

MCFARLAND, D. J.; ANDERSON, C. W.; MÜLLER, K.-R.; SCHLÖGL, A.; KRUSIENSKI, D. J. BCI Meeting 2005–workshop on BCI signal processing: feature extraction and translation. **IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society**, v. 14, n. 2, p. 135–8, jun. 2006. ISSN 1534-4320. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16792278>>. Citado na página 41.

MULDER, T. Motor imagery and action observation: Cognitive tools for rehabilitation. **Journal of Neural Transmission**, v. 114, n. 10, p. 1265–1278, 2007. ISSN 03009564. Citado nas páginas 25 e 35.

MÜLLER-GERKING, J.; PFURTSCHELLER, G.; FLYVBJERG, H. Designing optimal spatial filters for single-trial EEG classification in a movement task. **Clinical Neurophysiology**, v. 110, n. 5, p. 787–798, maio 1999. ISSN 13882457. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1388245798000388>>. Citado na página 40.

NEUPER, C.; SCHERER, R.; REINER, M.; PFURTSCHELLER, G. Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG. **Brain research. Cognitive brain research**, v. 25, n. 3, p. 668–77, dez. 2005. ISSN 0926-6410. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0926641005002533>>. Citado na página 37.

NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. **Sensors (Basel, Switzerland)**, v. 12, n. 2, p. 1211–79, jan. 2012. ISSN 1424-8220. Disponível em: <<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3304110&tool=pmcentrez&rendertype=abstract>>. Citado nas páginas 28 e 32.

NIJHOLT, A.; REUDERINK, B.; BOS, D. O. Turning shortcomings into challenges: Brain-computer interfaces for games. **Entertainment Computing**, International Federation for Information Processing, v. 1, n. 2, p. 85–94, 2009. ISSN 18678211. Citado na página 25.

NOVI, Q.; GUAN, C.; DAT, T. H.; XUE, P. Sub-band Common Spatial Pattern (SBCSP) for Brain-Computer Interface. In: **2007 3rd International IEEE/EMBS Conference on Neural Engineering**. IEEE, 2007. p. 204–207. ISBN 1-4244-0791-5. ISSN 1948-3546. Disponível em: <<http://ieeexplore.ieee.org/articleDetails.jsp?arnumber=4227252>>. Citado nas páginas 26, 40, 43 e 53.

OBERMAIER, B.; MÜLLER, G. R.; PFURTSCHELLER, G. "Virtual keyboard" controlled by spontaneous EEG activity. **IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society**, v. 11, n. 4, p. 422–6, dez. 2003. ISSN 1534-4320. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/14960119>>. Citado na página 28.

PFURTSCHELLER, G. Event-related synchronization (ERS): an electrophysiological correlate of cortical areas at rest. **Electroencephalography and Clinical Neurophysiology**, v. 83, n. 1, p. 62–69, 1992. Citado nas páginas 26 e 35.

PFURTSCHELLER, G. Functional brain imaging based on ERD/ERS. **Vision Research**, v. 41, n. 10, p. 1257–1260, 2001. Citado nas páginas 26, 34 e 35.

PFURTSCHELLER, G.; ARANIBAR, A. Event-related cortical desynchronization detected by power measurements of scalp EEG. **Electroencephalography and Clinical Neurophysiology**, v. 42, n. 6, p. 817–826, 1977. Citado nas páginas 26 e 35.

PFURTSCHELLER, G.; GUGER, C.; MÜLLER, G.; KRAUSZ, G.; NEUPER, C. Brain oscillations control hand orthosis in a tetraplegic. **Neuroscience Letters**, v. 292, n. 3, p. 211–214, oct 2000. ISSN 03043940. Citado nas páginas 25, 37 e 55.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery activates primary sensorimotor area in humans. **Neuroscience Letters**, v. 239, n. 2, p. 65–68, 1997. Citado nas páginas 25, 36, 37 e 55.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. **Proceedings of the IEEE**, v. 89, n. 7, p. 1123–1134, jul. 2001. ISSN 00189219. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=939829>>. Citado na página 36.

PFURTSCHELLER, G.; NEUPER, C.; FLOTZINGER, D.; PREGENZER, M. EEG-based discrimination between imagination of right and left hand movement. **Electroencephalography and Clinical Neurophysiology**, v. 103, n. 6, p. 642–651, dec 1997. ISSN 00134694. Citado nas páginas 37 e 55.

PFURTSCHELLER, G.; SILVA, F. H. Lopes-da. Event-related EEG/MEG synchronization and desynchronization: basic principles. **Clinical Neurophysiology**, v. 110, n. 11, p. 1842–1857, nov 1999. ISSN 13882457. Citado nas páginas 26, 37, 40 e 55.

PICHIORRI, F.; De Vico Fallani, F.; CINCOTTI, F.; BABILONI, F.; MOLINARI, M.; KLEIH, S. C.; NEUPER, C.; KÜBLER, A.; MATTIA, D. Sensorimotor rhythm-based brain-computer interface training: the impact on motor cortical responsiveness. **Journal of neural engineering**, v. 8, n. 2, 2011. Citado nas páginas 37 e 55.

PINEDA, J. A. The functional significance of mu rhythms: translating "seeing" and "hearing" into "doing". **Brain research. Brain research reviews**, v. 50, n. 1, p. 57–68, dez. 2005. ISSN 01650173. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165017305000573>>. Citado na página 34.

PUDIL, P.; NOVOVIČOVÁ, J.; KITTLER, J. Floating search methods in feature selection. **Pattern Recognition Letters**, v. 15, n. 11, p. 1119–1125, nov 1994. ISSN 01678655. Citado na página 42.

RAZA, H.; CECOTTI, H.; PRASAD, G. Optimising frequency band selection with forward-addition and backward-elimination algorithms in EEG-based brain-computer interfaces. In: **Proceedings of the International Joint Conference on Neural Networks**. [S.l.]: IEEE, 2015. v. 2015-Sept, p. 1–7. ISBN 9781479919604. Citado nas páginas 42 e 55.

RAZA, H.; CECOTTI, H.; PRASAD, G. A combination of transductive and inductive learning for handling non-stationarities in motor imagery classification. In: **2016 International Joint Conference on Neural Networks (IJCNN)**. [S.l.]: IEEE, 2016. p. 763–770. ISBN 978-1-5090-0620-5. Citado na página 61.

SAA, J. F. D.; ÇETIN, M. Hidden conditional random fields for classification of imaginary motor tasks from EEG data. In: IEEE. **Signal Processing Conference, 2011 19th European**. [S.l.], 2011. p. 171–175. ISSN 2076-1465. Citado na página 61.

SCHERER, R.; MULLER, G.; NEUPER, C.; GRAIMANN, B.; PFURTSCHELLER, G. An Asynchronously Controlled EEG-Based Virtual Keyboard: Improvement of the Spelling Rate. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 979–984, jun 2004. Disponível em: <<http://ieeexplore.ieee.org/document/1300792/>>. Citado na página 42.

SCHRÖDER, M.; LAL, T. N.; HINTERBERGER, T.; BOGDAN, M.; HILL, N. J.; BIRBAUMER, N.; ROSENSTIEL, W.; SCHÖLKOPF, B. Robust EEG channel selection across subjects for brain-computer interfaces. **Eurasip Journal on Applied Signal Processing**, v. 2005, n. 19, p. 3103–3112, 2005. ISSN 11108657. Citado na página 42.

SHOKER, L.; SANEI, S.; CHAMBERS, J. Artifact removal from electroencephalograms using a hybrid BSS-SVM algorithm. **IEEE Signal Processing Letters**, v. 12, n. 10, p. 721–724, oct 2005. Disponível em: <<http://ieeexplore.ieee.org/document/1510668/>>. Citado na página 44.

SHOKER, L.; SANEI, S.; SUMICH, A. Distinguishing Between Left and Right Finger Movement from EEG using SVM. In: **2005 IEEE Engineering in Medicine and Biology 27th Annual Conference**. IEEE, 2005. p. 5420–5423. ISBN 0-7803-8741-4. Disponível em: <<http://ieeexplore.ieee.org/document/1615708/>>. Citado na página 44.

SHOKER, L.; SANEI, S.; WANG, W.; CHAMBERS, J. A. Removal of eye blinking artifact from the electroencephalogram, incorporating a new constrained blind source separation algorithm. **Medical & Biological Engineering & Computing**, Springer-Verlag, v. 43, n. 2, p. 290–295, apr 2005. Disponível em: <<http://link.springer.com/10.1007/BF02345968>>. Citado na página 44.

TANGERMANN, M.; MÜLLER, K.-R.; AERTSEN, A.; BIRBAUMER, N.; BRAUN, C.; BRUNER, C.; LEEB, R.; MEHRING, C.; MILLER, K. J.; MÜLLER-PUTZ, G. R.; NOLTE, G.; PFURTSCHELLER, G.; PREISSEL, H.; SCHALK, G.; SCHLÖGL, A.; VIDAURRE, C.; WALTER, S.; BLANKERTZ, B. Review of the BCI Competition IV. **Frontiers in neuroscience**, Frontiers, v. 6, p. 55, jan 2012. ISSN 1662-453X. Citado nas páginas 27 e 58.

TEPLAN, M. Fundamentals of EEG measurement. **Measurement Science Review**, v. 2, p. 1–11, 2002. ISSN 15353893. Citado nas páginas 27 e 31.

VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer, 1995. ISBN 0387945598. Citado na página 44.

VENABLES, L.; FAIRCLOUGH, S. H. The influence of performance feedback on goal-setting and mental effort regulation. **Motivation and Emotion**, v. 33, n. 1, p. 63–74, jan. 2009. ISSN 0146-7239. Disponível em: <<http://link.springer.com/10.1007/s11031-008-9116-y>>. Citado na página 34.

WANG, Y.; ZHANG, Z.; LI, Y.; GAO, X.; GAO, S.; YANG, F. BCI Competition 2003—Data Set IV: An Algorithm Based on CSSD and FDA for Classifying Single-Trial EEG. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1081–1086, jun 2004. Disponível em: <<http://ieeexplore.ieee.org/document/1300807/>>. Citado na página 43.

WOLPAW, J. R.; BIRBAUMER, N.; MCFARLAND, D. J.; PFURTSCHELLER, G.; VAUGHAN, T. M. Brain–computer interfaces for communication and control. **Clinical Neurophysiology**, v. 113, n. 6, p. 767–791, jun 2002. ISSN 13882457. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1388245702000573>>. Citado nas páginas 25 e 27.

GLOSSÁRIO

Envoltória convexa: Em matemática, a envoltória convexa (também chamada de invólucro convexo ou fecho convexo) de um conjunto de pontos S , é o menor polígono convexo que contém S .

Framework: é uma abstração na qual o *software* proporciona funcionalidades genéricas que podem ser usadas ou modificadas no código fonte do usuário.

Overfitting: em aprendizado de máquina, o *overfitting* acontece quando um modelo se torna excessivamente complexo, diminuindo seu desempenho ao momento de fazer alguma predição usando novos dados, por causa de ter modelado todos os dados de treinamento, incluindo o ruído.

Valor Kappa: é uma estatística que mede o grau de concordância entre dois avaliadores classificando um mesmo conjunto de observações.

Época: Segmento de EEG, composto de m canais e n amostras. Representado por uma matriz $X \in R^{m \times n}$.