

---

Conjuntos K de redes neurais e sua aplicação na  
classificação de imagética motora

*Denis Renato de Moraes Piazzentin*

---



SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito: 5 de dezembro de 2014

Assinatura: \_\_\_\_\_

# Conjuntos K de redes neurais e sua aplicação na classificação de imagética motora

**Denis Renato de Moraes Piazzentin**

***Orientador:* Prof. Dr. João Luís Garcia Rosa**

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*

**USP - São Carlos  
Dezembro de 2014**

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

RRP584 Renato de Moraes Piazzentin, Denis  
cc Conjuntos K de redes neurais e sua aplicação na  
classificação de imagem motora / Denis Renato de  
Moraes Piazzentin; orientador João Luís Garcia Rosa. -  
- São Carlos, 2014.  
93 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, 2014.

1. redes neurais artificiais. 2. interface  
cérebro-computador. 3. eletroencefalograma. 4.  
conjuntos-K. I. Luís Garcia Rosa, João, orient. II.  
Título.

*A mente é tudo. O que você pensa, você se torna.*

***Siddhartha Gautama***



*À Vânia, Gabriel e Lúcia.*





# Agradecimentos

---

---

*Ao professor Dr. João Luís Garcia Rosa, pela orientação ao longo desse projeto.*

*Ao professor Dr. Rodrigo Fernandes de Mello, pela ajuda.*

*À Mayara, Luis e Raphael pela ajuda, apoio e discussões durante o projeto.*

*À FAPESP pelo apoio financeiro para a realização desta pesquisa.*



**E**sta dissertação de mestrado tem por objetivo analisar os conjuntos-K, uma hierarquia de redes neurais biologicamente mais plausíveis, e aplicá-los ao problema de classificação de imagética motora através do eletroencefalograma (EEG). A imagética motora consiste no ato de processar um movimento motor da memória humana de longo tempo para a memória de curto prazo. A imagética motora deixa um rastro no sinal do EEG que torna possível a identificação e classificação dos diferentes movimentos motores. A tarefa de classificação de imagética motora através do EEG é reconhecida como complexa devido à não linearidade e quantidade de ruído da série temporal do EEG e da pequena quantidade de dados disponíveis para aprendizagem. Os conjuntos-K são um modelo conexionista que simula o comportamento dinâmico e caótico de populações de neurônios do cérebro e foram modelados com base em observações do sistema olfatório feitas por Walter Freeman. Os conjuntos-K já foram aplicados em diversos domínios de classificação diferentes, incluindo EEG, tendo demonstrado bons resultados. Devido às características da classificação de imagética motora, levantou-se a hipótese de que a aplicação dos conjuntos-K na tarefa pudesse prover bons resultados. Um simulador para os conjuntos-K foi construído para a realização dos experimentos. Não foi possível validar a hipótese levantada no trabalho, dado que os resultados dos experimentos realizados com conjuntos-K e imagética motora não apresentaram melhorias significativas para a tarefa nas comparações realizadas.



# Abstract

---

---

**T**His dissertation aims to examine the K-sets, a hierarchy of biologically plausible neural networks, and apply them to the problem of motor imagery classification through electroencephalogram (EEG). Motor imagery is the act of processing a motor movement from long-term to short-term memory. Motor imagery leaves a trail in the EEG signal, which makes possible the identification and classification of different motor movements. Motor imagery classification is a complex problem due to non-linearity of the EEG time series, low signal-to-noise ratio, and the small amount of data typically available for learning. K-sets are a connectionist model that simulates the dynamic and chaotic behavior of populations of neurons in the brain, modeled based on observations of the olfactory system by Walter Freeman. K-sets have already been used in several different classification domains, including EEG, showing good results. Due to the characteristics of motor imagery classification, a hypothesis that the application of K-sets in the task could provide good results was raised. A simulator for K-sets was created for the experiments. Unfortunately, the hypothesis could not be validated, as the results of the conducted experiments with K-sets and motor imagery showed no significant improvements in comparison in the task performed.



# Sumário

---

---

<b>Resumo</b>	<b>i</b>
<b>Abstract</b>	<b>iii</b>
<b>1 Introdução</b>	<b>1</b>
<b>2 Eletroencefalograma</b>	<b>5</b>
2.1 Considerações Iniciais . . . . .	5
2.2 Eletroencefalograma . . . . .	5
2.3 Cérebro . . . . .	6
2.3.1 Correntes e Potenciais no Cérebro . . . . .	8
2.3.2 Origem da atividade elétrica cerebral . . . . .	9
2.4 Gravação do EEG . . . . .	10
2.5 Interfaces Cérebro-Computador . . . . .	11
2.6 Imagética Motora . . . . .	14
2.7 Considerações Finais . . . . .	17
<b>3 Processamento de Eletroencefalograma</b>	<b>19</b>
3.1 Considerações Iniciais . . . . .	19
3.2 Características do Sinal do EEG . . . . .	19
3.3 Remoção de artefatos em eletroencefalogramas . . . . .	21
3.4 Redução de dimensionalidade e Extração de Características . . . . .	24
3.5 Classificação de eletroencefalogramas . . . . .	26
3.6 Considerações Finais . . . . .	27
<b>4 Conjuntos-K</b>	<b>29</b>
4.1 Considerações Iniciais . . . . .	29
4.2 Sistemas Dinâmicos . . . . .	30
4.3 Percepção e Cognição . . . . .	32
4.4 Modelo Biológico de Populações de Neurônios . . . . .	34
4.5 Conjunto-KO: modelo não interativo de massa de neurônios . . . . .	35
4.5.1 Operação de conversão de ondas para pulsos . . . . .	37
4.6 Conjunto-KI: modelo de interação entre massas . . . . .	38
4.7 Conjunto-KII . . . . .	39
4.8 Conjunto-KIII . . . . .	41

4.8.1	Aprendizado no conjunto-KIII . . . . .	47
4.8.2	Classificação com o conjunto-KIII . . . . .	49
4.9	Conjunto-KIV . . . . .	49
4.10	Considerações Finais . . . . .	50
<b>5</b>	<b>Metodologia e Resultados</b>	<b>53</b>
5.1	Considerações Iniciais . . . . .	53
5.2	Simulador para os conjuntos-K . . . . .	53
5.3	Agrupamento de dados sociais utilizando o conjunto-KIII . . . . .	56
5.4	Conjuntos de Dados . . . . .	59
5.4.1	Conjunto de Dados I da BCI Competition IV . . . . .	61
5.4.2	Conjunto de Dados IVb da BCI Competition III . . . . .	62
5.4.3	Conjunto de Dados IVa da BCI Competition III . . . . .	62
5.5	Pré-processamento . . . . .	63
5.5.1	Algoritmo dos Padrões Espaciais Comuns . . . . .	63
5.5.2	Padrão Espacial Comum com Banco de Filtros . . . . .	65
5.6	Classificação . . . . .	66
5.6.1	Filtragem dos dados com o conjunto-KIII . . . . .	68
5.6.2	Classificadores . . . . .	68
5.6.3	Avaliação . . . . .	72
5.7	Resultados e Discussão . . . . .	73
5.8	Considerações Finais . . . . .	76
<b>6</b>	<b>Conclusões</b>	<b>79</b>
6.1	Contribuições e Limitações . . . . .	79
6.2	Considerações Finais . . . . .	80



# Lista de Figuras

---

---

2.1	Representação do sistema nervoso central. Adaptado de Nunez e Srinivasan (2006).	7
2.2	Estrutura simplificada de um neurônio biológico simples. Adaptado de Braga et al. (2007).	7
2.3	Posicionamento de eletrodos no sistema 10-20. Adaptado de Sanei e Chambers (2007).	12
2.4	Sincronização e dessincronização relacionada a evento. Adaptado de Pfurtscheller (1992).	16
4.1	Hierarquia dos conjuntos-K de redes neurais do conjunto-KO ao conjunto-KIV. Adaptado de Kozma et al. (2007).	30
4.2	Curva sigmóide com a distribuição de probabilidade de pulso (linha sólida) obtida por Freeman (1979). Adaptado de Freeman (1979).	38
4.3	Topologia do conjunto-KI com conexões de <i>feedback</i> excitatórias. Adaptado de Freeman (1975).	38
4.4	Simulação da resposta a impulso de três conjuntos-KII representando os modelos biológicos encontrados respectivamente no bulbo olfatório (OB), núcleo olfatório anterior (AON) e córtex prepiriforme (PC).	40
4.5	Estrutura de um KII set com dois KO excitatórios (KOe) e dois KO inibitórios (KOi). As conexões entre os KO estão nomeadas como <i>ee</i> , <i>ei</i> , <i>ie</i> e <i>ii</i> , onde cada conexão possui um peso fixo definido. Adaptado de Li e Kozma (2003).	41
4.6	Representação do sistema olfatório. O conjunto-KIII é baseado na estrutura do sistema olfatório. Adaptado de Principe et al. (2001).	43
4.7	Representação do conjunto-KIII. O conjunto-KIII é baseado na estrutura do sistema olfatório. Adaptado de Principe et al. (2001).	44
4.8	Resposta ao impulso obtida das três camadas de um conjunto-KIII com tamanho de entrada $n = 1$ obtida através da simulação dos conjuntos-K.	45
4.9	Diagrama de um conjunto-KIV. Adaptado de (Kozma et al., 2007).	50
5.1	Evolução dos pesos laterais para um conjunto-KIII após 1000 ciclos de treinamento.	55
5.2	Conjunto-KIII tendo o comportamento alterado devido ao excesso de excitação a partir do instante de tempo 2000.	55
5.3	Algoritmo FBCSP. O algoritmo seleciona pares de filtros passa-banda e espaciais criados com o CSP seguindo o critério de máxima informação mútua.	65
5.4	Série temporal correspondente ao canal C4 do EEG, extraída do subconjunto de teste do indivíduo <i>a</i> do conjunto de dados I da <i>BCI Competition IV</i> .	67



# Lista de Tabelas

---

---

5.1	Pesos utilizados nos conjuntos-KII de cada camada do conjunto-KIII. . . . .	54
5.2	Configuração padrão utilizada como valor inicial para os pesos laterais das três camadas do conjunto-KIII. . . . .	54
5.3	Configuração das conexões entre camadas do conjunto-KIII. . . . .	56
5.4	Razão $\bar{R}$ para os três conjuntos de dados sociais com 9 características selecionadas.	60
5.5	Distribuição dos dados de treino e teste no conjunto de dados IVa. . . . .	63
5.6	Erro médio quadrático obtido para os indivíduos $a$ , $b$ , $f$ e $g$ e média, para o conjunto de dados $I$ da <i>BCI Competition IV</i> . Resultados menores indicam melhor desempenho. O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	74
5.7	Medida $kappa$ obtida para os subconjuntos $a$ , $b$ , $f$ e $g$ e média, para o conjunto de dados $I$ da <i>BCI Competition IV</i> . Resultados maiores indicam melhor desempenho. O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	75
5.8	Erro médio quadrático obtido para os subconjuntos $c$ , $d$ e $e$ de dados artificiais e média dos resultados, para o conjunto de dados $I$ da <i>BCI Competition IV</i> . O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	76
5.9	Coeficiente $kappa$ para os subconjuntos $c$ , $d$ e $e$ de dados artificiais e média dos resultados, para o conjunto de dados $I$ da <i>BCI Competition IV</i> . O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	77
5.10	Erro médio quadrático e medida $kappa$ para os conjuntos de dados IVb da <i>BCI Competition III</i> . O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	77
5.11	Medida $kappa$ para o Conjunto de Dados IVa da <i>BCI Competition III</i> . O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	77
5.12	Acurácia para o Conjunto de Dados IVa da <i>BCI Competition III</i> . O prefixo $k$ indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII. . . . .	78



---

# Introdução

---

Os conjuntos-K são modelos de populações de neurônios criados a partir de observações feitas com eletroencefalograma no cérebro de animais. Os modelos são agrupados na forma de uma hierarquia de complexidade crescente, onde o modelo mais simples, o conjunto-KO, que representa uma pequena população de 10.000 neurônios, é utilizado para construir redes mais complexas, como o conjunto-KI, o conjunto-KII e o conjunto-KIII, que representa o bulbo olfatório de um mamífero, a parte do cérebro responsável pelo olfato e que exibe comportamentos de alta complexidade.

O conjunto-KIII é o primeiro nível da hierarquia dos conjuntos-K a apresentar uma dinâmica que permite sua utilização em atividades de aprendizado de máquina. No nível KIII, a simulação do conjunto exibe atividade constante e caótica que mimetiza o comportamento do bulbo olfatório. O treinamento da rede nesse nível por meio da adaptação da força da conexão entre as populações que formam o conjunto permite que a rede aprenda padrões que identificam diferentes classes de entrada. Esse aprendizado da rede é feito por meio do reforço entre as conexões ativas de forma similar, usando o conceito de aprendizado introduzido por Donald Hebb.

O conjunto-KIII já foi aplicado em diversos domínios com sucesso, incluindo a detecção de faces, navegação de robôs, reconhecimento de fala, predição de séries temporais e agrupamento. Além disso, também já foi usado com sucesso na classificação de eletroencefalograma e detecção de hipóxia através de eletroencefalograma. A partir dos resultados obtidos com os conjuntos-K em diversas aplicações, Erwin e Freeman (2008) alegam que os conjuntos-K costumam obter os melhores resultados quando comparados a outros algoritmos quando aplicados em ambientes complexos, com poucos exemplos disponíveis para aprendizado e muito ruído.

O eletroencefalograma (EEG) é uma técnica não invasiva muito utilizada em interfaces cérebro-computador (BCI). O EEG compreende uma série de eletrodos posicionados na cabeça que permitem monitorar o comportamento cognitivo de animais e seres humanos, por meio da leitura de ondas cerebrais. O uso de um sistema BCI elimina a necessidade de interação direta com o computador pela mão ou por voz e tem possíveis aplicações em jogos de computador, no suporte a pessoas com deficiências ou limitações físicas e para melhorar o controle de máquinas complexas como aeronaves (Wolpaw et al., 2002).

Vários fenômenos cerebrais podem ser explorados por meio do EEG com fins de uso em BCI. Neste trabalho focou-se na imagética motora. Imagética é o nome dado ao processo de geração mental de uma imagem similar à da percepção, mas na ausência de estímulos. A imagética motora, relacionada a movimentos, ocorre, por exemplo, ao se imaginar ou lembrar do movimento das mãos (Munzert et al., 2009).

A classificação de EEGs mostra resultados bem promissores em ambientes controlados (Bashashati et al., 2007). Porém a classificação da imagética motora por meio do EEG continua um desafio na área. Lotte et al. (2007) citam entre as características da tarefa: dados com muitos ruídos, alta dimensionalidade, a existência de informação temporal, sinais não-estacionários e conjuntos de treinamento, em geral, pequenos.

As características da tarefa de classificação de imagética motora por meio do EEG tornam o problema uma aplicação interessante para as redes neurais dos conjuntos-K. Cabe ressaltar que os conjuntos-K já foram utilizados diversas vezes para a classificação de EEGs (Kozma e Beliaev, 2004), e conseguiram atingir bons resultados. Contudo, a utilização dos conjuntos-K para a classificação de imagética motora por meio de EEG permanecia inexplorada. Dessa forma, a hipótese de que a aplicação dos conjuntos-K de redes neurais possam contribuir trazendo bons resultados para a tarefa de classificação de imagética motora é levantada. Infelizmente a hipótese levantada não foi verificada, visto que não foi possível obter em nenhum dos testes e experimentos realizados resultados que a validassem.

Os objetivos definidos para este trabalho são o desenvolvimento e modelagem da rede neural conjunto-KIII e sua adaptação e aplicação para classificação de imagética motora por meio do EEG.

A descrição da metodologia utilizada para os experimentos, os resultados obtidos e a discussão sobre esses são apresentados no capítulo 5. O capítulo também apresenta uma descrição das técnicas e algoritmos utilizados nos experimentos, além da descrição do simulador para os conjuntos-K que foi construído durante o projeto para a execução dos experimentos e dos resultados obtidos em um experimento paralelo ao trabalho desenvolvido, que envolve o uso dos conjuntos-K na tarefa de agrupamento de dados.

Os capítulos 2, 3 e 4 tratam da revisão bibliográfica realizada sobre o tema. O capítulo 2 contém a revisão bibliográfica sobre o eletroencefalograma e a imagética motora. Neste capítulo são discutidas a estrutura do cérebro, a origem da atividade elétrica cerebral que é capturada pelo

EEG, os tipos de sinais mentais utilizados em BCI e, em particular, a imagética motora, que permite discernir entre diferentes movimentos imaginados a partir do sinal capturado pelo EEG.

O capítulo 3 trata do processamento do sinal do EEG. São apresentados conceitos básicos de processamento de sinais e séries temporais e discutidas especificidades do processamento de EEG, como a remoção de artefatos, técnicas de extração de características e métodos de classificação tipicamente utilizados.

O capítulo 4 discute sobre os conjuntos-K. É feita uma introdução a conceitos fundamentais sobre sistemas dinâmicos e, em sequência, é apresentada a motivação biológica das massas de neurônios que são modeladas nos conjuntos-K e a relação dos conjuntos-K com as teorias sobre percepção e cognição desenvolvidas por Walter Freeman. As equações para os conjuntos-K são desenvolvidas a partir do modelo básico de neurônio até o conjunto-KIII. O conjunto-KIII, nível da hierarquia e rede neural utilizado neste trabalho, é apresentado juntamente com seu funcionamento como memória associativa por meio de transições entre atratores caóticos.





---

# Eletroencefalograma

---

## 2.1 Considerações Iniciais

Neste Capítulo é apresentada uma revisão bibliográfica sobre o eletroencefalograma (EEG). São discutidas a estrutura do cérebro, as origens da atividade elétrica cerebral e as propriedades das correntes elétricas no cérebro, a captura do EEG e sua utilização em interfaces cérebro-computador e os fenômenos de imagética motora, que permitem discernir entre movimentos imaginados a partir do EEG capturado.

## 2.2 Eletroencefalograma

O eletroencefalograma é uma técnica não invasiva que consiste de um registro das oscilações do potencial elétrico do cérebro gravado com eletrodos na superfície do couro cabeludo (Nunez e Srinivasan, 2006).

As primeiras pessoas a registrarem sinais elétricos emitidos por humanos foram Carlo Matteucci e Emil Du Bois-Reymond, ainda no século XIX, usando um galvanômetro e estabelecendo o conceito de neurofisiologia. A natureza elétrica do cérebro em si foi descoberta em 1875 por Richard Caton, da Real Escola de Medicina em Liverpool, que a descobriu experimentalmente utilizando um galvanômetro e dois eletrodos no couro cabeludo, reportando variações na corrente elétrica capturada do cérebro quando a retina era estimulada por luz (Sanei e Chambers, 2007).

A descoberta da existência do EEG em humanos foi de Hans Berger, que iniciou seus estudos com EEG em humanos em 1920, registrando a primeira gravação, que se tem notícia, do sinal do

EEG em um humano em 1929 (Sanei e Chambers, 2007). Hans Berger observou que os sujeitos de seu experimento causavam mudanças significativas no EEG ao fechar os olhos e ao resolver problemas aritméticos mentalmente, incluindo o ritmo alfa como um dos principais componentes do sinal do EEG.

Vários progressos foram obtidos no desenvolvimento do EEG após isso e hoje em dia o EEG pode ser gravado de forma invasiva ou não invasiva com o auxílio de sistemas computadorizados, equipados com várias ferramentas de processamento de sinal, eletrodos precisos e capacidade de gravação de diversas horas (Vallabhaneni et al., 2005).

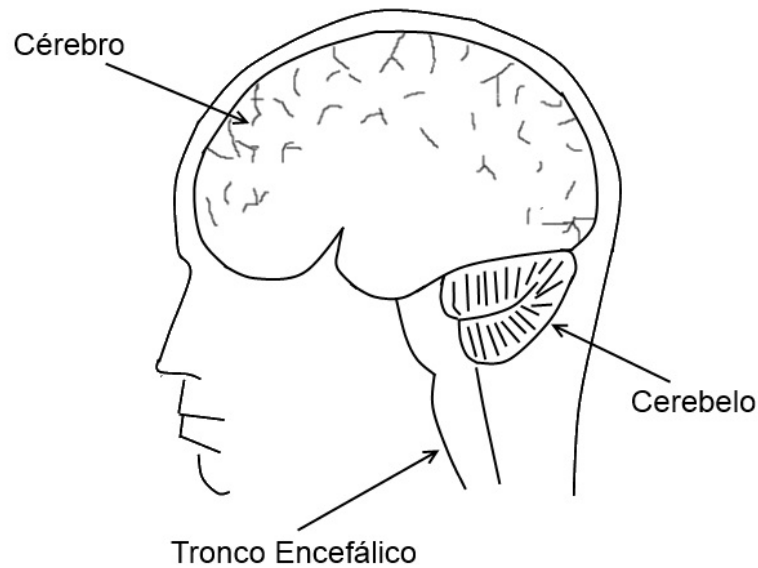
O EEG é útil por prover medidas robustas e em larga escala do funcionamento dinâmico do cérebro. Um único eletrodo provê uma estimativa da ação média de uma área do cérebro contendo de 100 milhões a 1 bilhão de neurônios. Dessa forma, é possível a partir do EEG com diversos eletrodos capturar a dinâmica do cérebro com certa precisão, o que faz com que ele seja aplicável ao diagnóstico de epilepsia e hipóxia, como ferramenta de diagnóstico em caso de lesões na cabeça, e em aplicações diversas não relacionadas diretamente à área médica, como as interfaces cérebro-computador (Lodder e van Putten, 2013).

## 2.3 Cérebro

O EEG mede a atividade elétrica do sistema nervoso central, principalmente do cérebro. A atividade elétrica medida surge da interação de milhões de neurônios por meio de sinapses. As três divisões primárias do sistema nervoso superior humano são o tronco encefálico, o cerebelo e o cérebro (Figura 2.1). O tronco encefálico é a estrutura pela qual as fibras nervosas enviam seus sinais (potenciais de ação) para a medula espinhal e para as partes superiores do sistema nervoso e que controla funções involuntárias como a respiração, o batimento do coração e a regulação hormonal. O cerebelo, localizado na parte de trás do topo do tronco encefálico, é associado com o controle preciso dos movimentos musculares e possui alguns papéis adicionais na cognição (Nunez e Srinivasan, 2006).


A parte restante, o cérebro, é dividida quase igualmente em dois hemisférios. A porção exterior do cérebro, o córtex cerebral, é uma estrutura enrugada com espessura variando de 2 a 5 milímetros, com uma superfície de 1600 até 4000 cm<sup>2</sup> e contém cerca de 10<sup>10</sup> neurônios (células nervosas). Neurônios do córtex são fortemente interconectados, podendo fazer até 10<sup>5</sup> sinapses cada, que transmitem impulsos para outros neurônios (Nunez e Srinivasan, 2006). Muito da nossa consciência envolve a interação entre neurônios corticais. O córtex também é a estrutura que gera a maior parte do potencial elétrico medido no couro cabeludo (Michel et al., 2004).

Um neurônio biológico é dividido, tipicamente, em três partes. O corpo da célula, ou soma, de onde saem várias fibras chamadas dendritos e uma única e longa fibra chamada axônio. O corpo da célula possui apenas alguns milésimos de milímetros, os dendritos alguns poucos milímetros e



**Figura 2.1:** Representação do sistema nervoso central. Adaptado de Nunez e Srinivasan (2006).

o axônio medindo de 1 mm a até 2 metros (Russell e Norvig, 2010). Na Figura 2.2 é mostrada uma estrutura aproximada de um neurônio típico.



**Figura 2.2:** Estrutura simplificada de um neurônio biológico simples. Adaptado de Braga et al. (2007).

A função dos dendritos é receber os impulsos elétricos nervosos de outros neurônios e conduzi-los até o corpo celular. Em certas situações, se os impulsos recebidos dos dendritos ultrapassarem um determinado limiar o corpo do neurônio gera um novo impulso. Esse impulso então é transmitido através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre o axônio da célula e um dendrito do neurônio seguinte é chamado de sinapse e é assim que os neurônios se unem formando as redes neurais biológicas (Haykin, 1999).

O tipo predominante de sinapse é a sinapse química, que opera através da liberação de substâncias neurotransmissoras pelo neurônio pré-sináptico que se ligam a canais de íon na superfície do neurônio pós-sinápticos e causam fluxos de  $\text{Na}^+$  e  $\text{Ca}^{2+}$ , por exemplo, que alteram o potencial do neurônio (Kandel et al., 2000).

As conexões sinápticas para um neurônio podem ser de dois tipos: as que produzem um potencial pós-sináptico excitatório fazendo com que o neurônio alvo tenha maior chance de disparar um potencial de ação e as que produzem um potencial pós-sináptico inibitório, que funciona da maneira oposta (Michel et al., 2004).

Neurônios do córtex dentro de cada hemisfério são conectados por axônios curtos de até 1 mm. Além disso, o córtex humano é interconectado por cerca de  $10^{10}$  axônios com tamanho de 1 mm a 15 cm. O tempo de transmissão dos potenciais de ação entre os axônios varia de 10 a 30 milissegundos entre locais remotos do córtex, enquanto os atrasos locais devido à natureza capacitivo-resistiva dos neurônios são de 1 a 10 milissegundos. A interação entre múltiplas regiões parece ser necessária para o cérebro se conscientizar de um evento externo, o que faz com o que a consciência leve algumas centenas de milissegundos para se formar (Nunez e Srinivasan, 2006).

Os processos cerebrais dinâmicos podem envolver a formação de conjuntos de células em diversas escalas espaciais (Freeman, 1975). Parte desse comportamento dinâmico pode ser medido em nível macroscópico pelos eletrodos do EEG no couro cabeludo. A atividade elétrica capturada pelo EEG pode então ser dividida em duas principais categorias: potenciais espontâneos, como os ritmos alfa e o de sono e potenciais evocados ou potenciais relacionados a eventos. Os potenciais evocados são uma resposta direta a um estímulo externo como um *flash* de luz ou um som audível.

### 2.3.1 Correntes e Potenciais no Cérebro

A maior parte do EEG parece ser gerada por fontes amplamente distribuídas, apesar de ser possível identificar regiões específicas do cérebro produzindo potenciais elétricos grandes quando associadas com uma tarefa cognitiva específica. Dados de EEG em larga escala são relacionados a múltiplas fontes de corrente sináptica produzidas em um volume macroscópico de tecido cerebral, contendo muitas células (Nunez e Srinivasan, 2006).

Um importante aspecto da condução de correntes e potenciais no cérebro é a linearidade, apesar da irregularidade do cérebro. O tecido macroscópico é considerado linear se a lei de Ohm se mostrar válida para este. Para um circuito resistor de resistência  $R$ , a lei de Ohm é dada por

$$V_1 - V_2 = RI \quad (2.1)$$

onde  $V_1 - V_2$  é a diferença de potencial entre os terminais do resistor e  $I$  é a corrente atravessando o resistor. A corrente move-se de potenciais altos para baixos, portanto um  $I$  positivo é consistente com  $V_1$  sendo maior que  $V_2$ .

Em tecido vivo, quem carrega a corrente são íons positivos e negativos. Os íons positivos e negativos movem-se em direções opostas, e ambos contribuem para a corrente medida. A corrente positiva é definida como a direção em que a carga positiva corre. Impedância é o equivalente a resistência em corrente alternada e é responsável por possíveis mudanças de fases devido às propriedades capacitivas e indutivas dos elementos dos circuitos. Esses efeitos indutivos, porém, são ínfimos e os efeitos capacitivos são muito pequenos no tecido neural macroscópico em frequências de EEG interessantes (cerca de 1 a 40 Hz). Apesar de não serem muito relevantes em nível macroscópico, os efeitos capacitivos são de crítica importância no nível microscópico e de célula (Kandel et al., 2000).

A lei de Ohm em condutores de volume consiste de uma relação linear entre o vetor de densidade de corrente  $\mathbf{J}$  (microampères por milímetro quadrado ou  $\mu\text{A}/\text{mm}^2$ ) e o campo elétrico  $\mathbf{E}$  (microvolts por milímetro, ou  $\mu\text{V}/\text{mm}$ )

$$\mathbf{J} = \sigma \mathbf{E} \quad (2.2)$$

onde  $\sigma(1/\Omega\text{mm})$  é a condutividade do material físico ou biológico.

Apesar da não homogeneidade do tecido vivo, experimentos indicam que este é linear em escala macroscópica, pelo menos para campos não muito grandes e, portanto, a lei de Ohm é aplicável.

O fato de o tecido ser um condutor linear em escala macroscópica implica que o princípio da superposição é válido. Supondo a existência de uma fonte de corrente  $I_1$  em um local  $r_1$  causa o potencial  $V_1$  em um local qualquer  $r$  na cabeça; a fonte de corrente  $I_2$  no local  $r_2$  causa o potencial  $V_2$  no mesmo local  $r$ , e da mesma forma para a fonte  $I_n$ . O princípio da superposição então diz que se todas as fontes ( $I_1 + I_2 + \dots + I_n$ ) são ativadas ao mesmo tempo, o potencial no local  $r$  vai ser a superposição linear ou soma dos potenciais individuais ( $V_1 + V_2 + \dots + V_n$ ), o que justifica a afirmação de que muitos fenômenos do EEG são gerados por um grande número de fontes correlacionadas superpostas (Nunez e Srinivasan, 2006).

A diferença do potencial  $V$  no cérebro entre dois locais dá origem a um campo elétrico que pode ser monitorado através de eletrodos. Se o monitoramento ocorre a partir do couro cabeludo, o procedimento é chamado de EEG, caso seja monitorado com eletrodos na superfície do córtex é eletrocorticograma (ECoG) e potenciais de campo local (*Local Field Potentials*, LFP) ou EEG intracraniano quando são usados eletrodos inseridos no cérebro (Buzsaki et al., 2012).

### 2.3.2 Origem da atividade elétrica cerebral

Todas as membranas excitáveis de neurônios do cérebro contribuem para o campo elétrico extracelular. A atividade sináptica dos neurônios é normalmente a fonte mais importante de fluxo de corrente no cérebro. Neurotransmissores agindo sobre as sinapses com os canais receptores de íons  $\text{Na}^+$  e  $\text{Ca}^{2+}$  causam um fluxo para dentro do neurônio. Esse influxo de cátions extracelulares para dentro da célula dá origem a um sumidouro local (Buzsaki et al., 2012). Para atingir a neutralidade elétrica o influxo de cátions precisa ser contrabalanceado por uma fonte extracelular,

que é chamada de corrente passiva ou corrente de retorno dos neurônios. Uma fonte de corrente é definida como o local da membrana do neurônio onde a carga positiva sai e um sumidouro como o local onde a carga positiva entra no neurônio.

Uma mini coluna de neurônios no córtex com 3 mm de altura contém cerca de 100 células piramidais e um milhão de sinapses. Experimentos com ratos mostraram que há pelo menos 6 sinapses excitatórias para cada inibitória. Cada sinapse inibitória ativa produz uma fonte de corrente local numa superfície da membrana e um ou mais sumidouros (fonte negativa). De forma similar, cada sinapse excitatória ativa produz um sumidouro e uma ou mais fontes de correntes distribuídas na membrana (Buzsaki et al., 2012).

A magnitude do potencial elétrico no couro cabeludo gerada por uma coluna de neurônios depende principalmente da distribuição das sinapses e da sincronia das ativações das sinapses. Por exemplo, se sinapses excitatórias e inibitórias são distribuídas de forma relativamente uniforme pela coluna, ou se sinapses são ativadas aleatoriamente, as forças (momentos de dipolo) das fontes na região da coluna serão pequenas (Petsche et al., 1984).

Uma única mini coluna ou até uma única macro coluna (contendo 1000 mini colunas ou 100.000 neurônios) não é capaz de gerar um momento de dipolo com força suficiente para produzir os potenciais de alguns poucos microvolts, que são detectáveis pelo EEG. Como uma regra geral cerca de 6 cm<sup>2</sup> do tecido do córtex (contendo cerca de 600.000 mini colunas) deve estar sincronamente ativa para produzir um potencial mensurável no couro cabeludo (Nunez e Srinivasan, 2006).

Conjuntos de células são vistos como um grupo de neurônios ou massas de neurônios (mini colunas, colunas corticais, macro colunas) no qual a interação preferencial persiste sobre intervalos de tempo de, talvez, alguns segundos ou mais. Atividade sináptica causa fontes de corrente que geram EEG independentemente das sinapses ativas serem parte de um ou mais conjuntos de células. Porém, grandes potenciais no escalpo ocorrem porque momentos de dipolo de colunas de neurônios são alinhados e ativados sincronamente, e esse requerimento de sincronia sináptica favorece a captura das fontes que são parte de um conjunto de neurônios (Buzsaki et al., 2012).

Há muitas outras possíveis fontes de atividade elétrica no couro cabeludo, que devem ser consideradas e tratadas no processamento do sinal do EEG. Movimentos do olho e da língua, contrações musculares e o batimento do coração podem produzir potenciais no couro cabeludo maiores que as amplitudes do EEG (Sanei e Chambers, 2007).

## 2.4 Gravação do EEG

Conforme mencionado, os primeiros registros de atividade elétrica cerebral foram feitos usando simples galvanômetros. Sistemas de gravação de EEG mais atuais, ainda analógicos, consistem de uma série de eletrodos, um conjunto de amplificadores (um para cada eletrodo) seguidos por filtros

e agulhas registradoras, que imprimem o sinal dos múltiplos canais do EEG em papel para análise (Vallabhaneni et al., 2005).

Com o aumento do número de eletrodos e o conseqüente crescimento do volume de dados, a transição para sistemas digitais foi o próximo passo na captura do sinal do EEG. O sinal digitalizado permite que pesquisadores possam analisar o sinal do EEG e ajustar múltiplas configurações, como a frequência de amostragem e, em alguns casos, aplicar diretamente ferramentas simples ou avançadas de processamento de sinal (Sanei e Chambers, 2007).

A largura de banda efetiva do sinal do EEG é limitada a aproximadamente 100 Hz, portando, uma frequência mínima de 200 amostragens por segundos é o bastante para a maioria das aplicações (Sanei e Chambers, 2007). Para manter as informações contidas no EEG, cada amostragem do sinal é gravada com até 16 bits de precisão, o que torna massivo o volume dos dados para arquivamento.

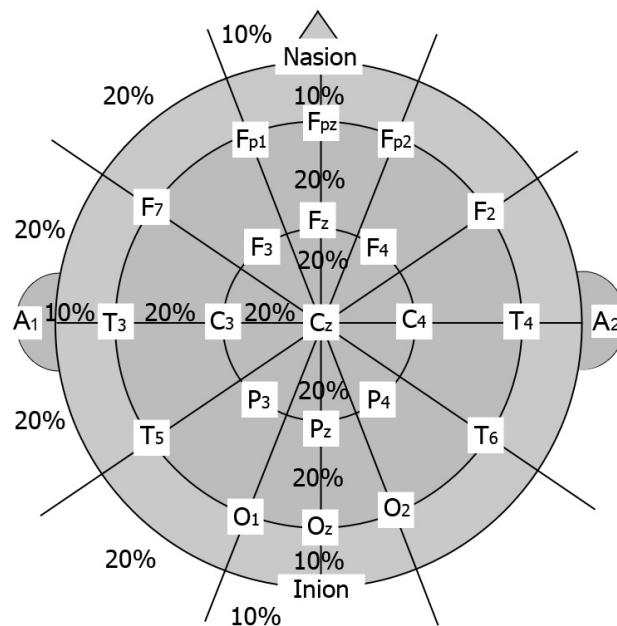
Os eletrodos são parte essencial da gravação do EEG. Os tipos de eletrodos comumente usados para gravação no couro cabelo consistem de discos de prata e cloreto de prata (Ag/AgCl) com menos de 3 mm de diâmetro, com cabos longos que podem ser conectados em um amplificador. Sistemas comerciais de EEG também são comumente equipados com monitores de impedância, pois a alta impedância entre o córtex e os eletrodos, ou nos eletrodos em si, podem causar distorções no sinal (Vallabhaneni et al., 2005).

O posicionamento dos eletrodos no couro cabeludo costuma seguir a convenção 10-20 de posicionamento recomendada pela *International Federation of Societies for Electroencephalography and Clinical Neurophysiology*. Nesse sistema os eletrodos chamados A1 e A2, conectados nos lóbulos das orelhas, são usados como eletrodos de referência de potencial. O sistema 10-20 possui inicialmente 21 eletrodos posicionados de acordo com alguns marcos anatômicos para os quais a distância pode ser calculada, sendo usada 10% ou 20% dessa distância como o intervalo dos eletrodos (Figura 2.3). Sistemas mais densos posicionam eletrodos equidistantes entre os 21 do sistema 10-20. Em outros sistemas, como aplicações BCI, menos canais são necessários. É possível, por exemplo, usar os canais C3 e C4 para gravar o movimento para dedos da mão esquerda ou direita (Vallabhaneni et al., 2005).

## 2.5 Interfaces Cérebro-Computador

Um sistema de interface cérebro-computador (BCI) é um sistema em que mensagens ou comandos que um indivíduo envia para o mundo externo não precisem passar pelas saídas normais do cérebro para os nervos periféricos e músculos. Em sistemas BCI baseados no EEG, por exemplo, os comandos do indivíduo estão codificados no sinal do EEG (Wolpaw et al., 2002).

Um BCI consiste de três partes: a aquisição da atividade cerebral de alguma forma, o processamento do sinal obtido e tradução destes em comandos, e algum dispositivo que receba e faça uso da saída obtida (Wolpaw et al., 2002).



**Figura 2.3:** Posicionamento de eletrodos no sistema 10-20. Adaptado de Sanei e Chambers (2007).

Apesar de várias estratégias serem possíveis para adquirir sinais cerebrais, como por exemplo, magnetoencefalografia (MEG) e ressonância magnética funcional (fMRI), eletroencefalogramas como alternativa não invasiva e eletrocorticogramas (ECoG) como alternativa minimamente invasiva são muito mais exploradas e viáveis, pois são significativamente menores e menos caras (Fatourehchi et al., 2007).

Dispositivos com vários fins podem ser utilizados com o BCI, como dispositivos de suporte a pessoas com deficiências ou limitações físicas como cadeiras de rodas, controle de jogos eletrônicos e auxílio ao controle de máquinas complexas como aeronaves (Wolpaw et al., 2002).

Indivíduos participantes em experimentos com sistemas BCI são orientados a produzirem e controlarem certas mudanças em sinais de EEG pensando sobre algumas coisas específicas ou concentrando-se no movimento de um cursor. O uso do sistema BCI requer então alguma forma de controle intencional sobre um tipo de atividade cerebral (Curran e Stokes, 2003).

Um sistema BCI pode ser ritmado por estímulos externos, BCI síncrono, ou estímulos internos, BCI assíncrono. No caso do BCI síncrono, estados mentais específicos são produzidos por eventos externos e ocorrem em uma janela de tempo específica. Essa janela de tempo é então analisada e classificada de acordo com a atividade oscilatória do EEG nesse período. Em sistemas BCI assíncronos o usuário é livre para controlar os estados mentais e pensamentos, e é necessário identificar os estados relacionados a eventos internos, os pensamentos, e classificá-los. Vários tipos de potenciais relacionados a evento são usados nesse caso, como eventos visuais evocados (*Visual Evoked Potentials*, VEP), o P300 e os fenômenos de dessincronização e sincronização relacionados à evento durante a imagética motora (Pfurtscheller e Neuper, 2001).



Um VEP é gerado em resposta a um estímulo visual, como luzes piscantes por exemplo, e causa pequenas mudanças no sinal do EEG. Um evento visual evocado de estado estacionário (*Steady-State Visual Evoked Potential*, SSVEP) é um caso especial que surge quando um estímulo visual é apresentado numa taxa de 5Hz ou maior, que resulta numa resposta oscilatória contínua do cérebro. VEPs e SSVEPs são mais proeminentes sobre a área occipital do cérebro (Bashashati et al., 2007).

P300 é o nome dado a um pico de potencial que costuma ocorrer sobre o córtex parietal cerca de 300 ms após um estímulo sensorial significativo infrequente entre outros estímulos frequentes. Um exemplo de experimento em que o P300 ocorre consiste de tocar um áudio contínuo para um indivíduo consistindo de 80% de tons graves e 20% de tons agudos. É possível observar claramente picos de potencial 300 ms após o início dos sons agudos (P300) (Devlaminck et al., 2009). O P300 também é observável para estímulos visuais, sendo primeiramente usado em um sistema de digitação através de estímulos visuais por Farwell e Donchin (1988). O experimento de Farwell e Donchin consistia de uma matriz com 6 linhas por 6 colunas, onde o sujeito deveria focar na letra correspondente. As linhas e colunas piscavam aleatoriamente, o que gerava um P300 quando a letra relevante era selecionada.

Potenciais lentos do córtex (*Slow Cortical Potentials*, SCP) também são usados em sistemas BCI. SCPs refletem mudanças na polarização do córtex e costumam durar de 300 ms a alguns segundos (Bashashati et al., 2007). O uso de SCP para BCI requer treinamento extensivo para que os indivíduos sejam capazes de controlar as ondas lentas. A técnica é mais usada como método de *feedback* neural em tratamento de distúrbios como epilepsia e déficit de atenção, que mostram melhoras com o treinamento para o controle do SCP (Devlaminck et al., 2009).

A imagética motora é relativamente mais estável entre indivíduos e mais fácil de controlar em sistemas assíncronos. Em experimentos, 78% dos voluntários conseguiram utilizar um sistema BCI com mais de 60% de acurácia com apenas alguns minutos de treinamento (Pfurtscheller e Neuper, 2001). Pelo menos quatro grupos de pesquisas trabalham ou já trabalharam com imagética (Curran e Stokes, 2003): um grupo na Universidade de Roma, na Itália (Babiloni et al., 2001); um grupo na Universidade de Tecnologia de Graz (Friedrich et al., 2013; Hasan e Gan, 2012), na Áustria; um grupo de colaboradores entra a Universidade de Oxford e o Hospital Real de Neurodeficiência de Londres, na Inglaterra (Penny et al., 2000) e o grupo *Berlin Brain-Computer Interface*, que conta com a cooperação de diversos centros de pesquisa na Alemanha (Kawanabe et al., 2009).

Os primeiros experimentos reportados datam de 1971, com o uso controlado do ritmo alfa por Stoyva e Kamiya (1972). Desde então, experimentos realizados por diversos grupos de pesquisa já conseguiram resultados usando diferentes características dos estados mentais como, por exemplo, uma taxa de escrita de cerca de 7 letras por minuto usando P300, 3 letras por minuto com o uso de eventos visuais evocados e a identificação entre três diferentes movimentos imaginados, ou seja, imagética motora, com razoável taxa de sucesso (Pfurtscheller e Neuper, 2001).

Uma dificuldade existente no projeto de sistemas BCI é que os padrões de ativação do cérebro se alteram com o tempo, incluindo a prática da atividade explorada e o aprendizado de novas

coisas não relacionadas. Um exemplo disso é a mudança que os ritmos do EEG obtidos do bulbo olfatório para um determinado estímulo (um odor) sofrem após o sujeito ser condicionado a um novo odor, conforme demonstrado por Freeman (2000). Além disso, fatores como a atenção, o estado emocional e outras tarefas mentais (como ouvir música ou fixar a visão em algo) afetam o EEG obtido. A variação entre indivíduos é ainda maior, principalmente entre diferentes gêneros (Curran e Stokes, 2003).

Outra preocupação no projeto de sistemas BCI é a duração de tempo necessário para o treinamento de sujeitos para uso de sistemas BCI. Alguns sistemas usam mais de 10 a 15 sessões de uma hora cada para atingir um grau de controle satisfatório em alguns sistemas (Curran e Stokes, 2003).

## 2.6 Imagética Motora

Imagética pode ser definida como um processo de geração de imagem similar ao da percepção na ausência de estímulos externos (Munzert et al., 2009). O conceito foi primeiramente desenvolvido para a imagética visual e então adaptado para a imagética motora. O processo de imagética consiste em processar a informação sobre um ato motor da memória de longo termo para a memória de trabalho ou de curto prazo. Embora as imagens possam se referir a qualquer um dos sentidos, as imagens dinâmicas dos atos motores consistem tipicamente de informação cenestésica ou visual.

Pesquisas em imagética mostraram que a imagética visual e a percepção, além da imagética motora e a execução do movimento motor, compartilham de representações neurais semelhantes, criando estados mentais similares aos da real execução do movimento. Isso levou à criação do conceito de equivalência funcional entre imagética motora e execução motora. O mesmo processo emerge em outros processos cognitivos motores, como a observação de movimentos e planejamento e verbalização da ação (Munzert et al., 2009). A ideia básica, então, é que as populações neurais responsáveis pelo movimento são ativadas enquanto imaginando as ações motoras.

Durante experimentos com imagética pode ser solicitado ao sujeito para explicitamente imaginar um movimento do pé, das mãos ou da língua, por exemplo, ou pode-se tentar obter a imagética de forma implícita como, por exemplo, perguntando qual seria a melhor forma de se segurar um objeto, onde se espera que o indivíduo se imagine executando o movimento no processo (de Lange et al., 2008).

Vários experimentos de fato comprovam que a imagética se manifesta de forma similar à atual execução do movimento nas áreas parietais superiores e inferiores, no córtex pré-motor, no giro do cíngulo anterior e no cerebelo. A ativação do córtex sensorimotor também foi detectada, apesar de menos evidente do que durante o movimento motor real (Pfurtscheller e Neuper, 2001). Há discussões se o mecanismo envolvido na imagética consiste de um movimento planejado que é

interrompido logo antes da execução ou se consiste de uma fase de planejamento de movimento comum para os movimentos (de Lange et al., 2008).

O EEG é comumente categorizado de acordo com sua frequência em delta ( $\delta$ , 1-4 Hz) associada com o sono profundo; teta ( $\theta$ , 4-8 Hz) associada com o inconsciente, inspiração criativa e meditação profunda; alfa ( $\alpha$ , 8-13 Hz), presente na parte posterior da cabeça, associada a um estado relaxado do cérebro sem atenção ou concentração; beta ( $\beta$ , 13-20 Hz), associada com atenção, estado de foco, durante a resolução de problemas concretos, e gama ( $\gamma$ , maior que 20 Hz), além da frequência mu ( $\mu$ ), particularmente importante para a detecção de imagética motora. Essas categorias são aplicadas apenas com base em inspeções visuais e um EEG real é composto por uma mistura de múltiplos componentes de diversas frequências que podem ser reveladas claramente pela análise espectral (Sanei e Chambers, 2007).


O ritmo  $\mu$  tem uma frequência quase idêntica à do ritmo  $\alpha$  (8-12 Hz) e é comumente observado durante a imagética motora na região sensorio-motora, na lateral central do couro cabeludo, ou região de Rolandic (Pfurtscheller et al., 1997; Wolpaw et al., 2002), localizada logo acima do córtex sensorio-motor, próximo aos eletrodos C3, C4 e Cz. Devido a isso, este ritmo é comumente associado com a ativação dessa região do córtex em estudos com interfaces cérebro-computador (Mizuhara, 2012). Junto com o ritmo  $\mu$ , o ritmo  $\beta$  da região central, que tem um espectro mais amplo, também contém oscilações importantes para a imagética motora.

O córtex sensorimotor demonstra uma grande variedade de ritmos  $\mu$  com topografias e propriedades específicas. É possível delinear ritmos  $\mu$  distintos localizados em áreas específicas do córtex sensorimotor, o que é coerente com os conceitos atuais de organização da função motora que assume que as áreas da mão, pé e rosto têm um grande número de neurônios mas são pouco conectadas umas com as outras. As regiões da face e da mão são mais facilmente observadas no ritmo  $\mu$ , enquanto os pés são mais difíceis de detectar devido à posição, mais central e interna, da área responsável. A detecção do movimento dos pés nas frequências mais baixas do ritmo  $\beta$  é normalmente mais fácil do que no ritmo  $\mu$  (Pfurtscheller et al., 1996).

É possível observar nessas faixas de frequência os fenômenos de dessincronização, nome dado ao bloqueio de algumas frequências e sincronização, o aumento da potência, associados a eventos específicos relacionados à atividade motora. Foi observado que sempre é possível relatar esses fenômenos a um evento conhecido e identificado. Pfurtscheller e Aranibar (1977) deram o nome a esse efeito de sincronização relacionada a evento (*Event-Related Synchronization*, ERS) e dessincronização relacionada a evento (*Event-Related Desynchronization*, ERD) (Pfurtscheller, 1992).

A excitação de uma área do córtex resulta num padrão de baixa amplitude no EEG, resultado de uma dessincronização dos neurônios. Sabe-se que movimentos voluntários ativos, passivos ou reflexos, executados ou imaginados, causam bloqueios, e conseqüentemente ERD, em faixas específicas, como a  $\mu$  e a  $\beta$  (Figura 2.6. Um exemplo de ERS é o aumento do ritmo  $\mu$  na área sensorimotora durante uma atividade visual, pois durante essas circunstâncias os neurônios da área sensorimotora não são necessários, ao mesmo tempo em que ocorre um ERD na área responsável pela visão. Ou seja, ERDs e ERSs podem ser observados quase que ao mesmo tempo, formando

um padrão espaço-temporal em que o local do ERD define a área relacionada à tarefa e o ERS marca as áreas em repouso ou inativas (Pfurtscheller, 1992; Pfurtscheller et al., 1996).



**Figura 2.4:** Sincronização e dessincronização relacionada a evento. Adaptado de Pfurtscheller (1992)

A magnitude e tamanho do ERD reflete a massa de neurônios envolvida numa tarefa específica, assim, tarefas mais complexas provocam ERDs maiores. ERS são eventos de curta duração correlacionados com a inatividade localizada no córtex. Por exemplo, durante uma tarefa visual, como a leitura, ou o movimento de uma área diferente como os pés, a área do córtex sensorimotor responsável pelas mãos não é necessária e, portanto, espera-se um aumento localizado dos ritmos nas frequências  $\mu$  e  $\beta$  nessa área. Ocorre também uma variação do padrão espaço-temporal formado pelos ERDs e ERS para eventos motores distintos, como entre o movimento da mão esquerda e da direita. Essa variação é dependente do indivíduo, podendo variar no local de ativação ou na banda de frequência, por exemplo (Pfurtscheller et al., 1997).

Os ERS e ERD então fornecem informações sobre o início e a finalização do movimento motor e possuem padrões espaço-temporais diferentes de acordo com o movimento planejado, que permite que esses eventos possam ser identificados a partir do EEG do couro cabeludo (Wolpaw et al., 2002). A reação mais comum a um evento é um ERD seguido por um ERS na mesma área. O ERS em si pode ser um ERS secundário, seguindo um ERD com um atraso de uma fração de segundo ou com grande latência sem um ERD, ou primário, sendo invocado ao mesmo tempo que o ERD em áreas diferentes do cérebro. Num movimento, por exemplo, o ERD é localizado na área sensorimotora e o ERS na área occipital, próxima aos eletrodos O1 e O2, que contém a área responsável pela visão.

O método mais clássico de quantificação de ERDs consiste de filtrar as amostras de sinal com filtros passa banda de forma a isolar a frequência relevante ao evento, elevar a amplitude do sinal ao quadrado para obter a energia das amostras e fazer a média da potência sobre todas as amostras (Pfurtscheller e Lopes da Silva, 1999).

Diversos tipos de eventos podem causar ERDs e ERSs, com os mais notáveis sendo estímulos sensoriais e movimento motor. O movimento motor causa dessincronização da parte mais alta do

ritmo  $\mu$  até a mais baixa do ritmo  $\beta$ , em áreas próximas às áreas sensorimotoras. A dessincronização começa cerca de 2 segundos antes do início do movimento sobre a área contralateral da região de Rolandic e se torna bilateralmente simétrica imediatamente antes da execução do movimento (Pfurtscheller e Lopes da Silva, 1999). O ERD pré-movimento é similar para movimentos em diferentes velocidades das mãos, punho e dedos, sugerindo que se trata de uma preparação independente dos neurônios das áreas motoras para o movimento. Cabe acrescentar que, ao contrário das mãos, o movimento dos pés não causa tão frequentemente um ERD sobre a área responsável.

O ERS pós-movimento no ritmo  $\beta$ , encontrado normalmente 1 segundo após o movimento, tem uma taxa de sinal-ruído relativamente boa. É possível observar durante a imagética motora um bloqueio do ritmo  $\mu$ , da mesma forma que num movimento real, sobre o córtex sensorimotor. De forma similar, o ERD no ritmo  $\beta$  sofre uma recuperação rápida seguida de uma ERS. Uma diferença notável entre o ERD causado pela imagética e o ERD do movimento motor executado é que o ERD da imagética se manifesta somente sobre a área contralateral da região de Rolandic, e não se tornam simétricas logo antes da execução do movimento (Pfurtscheller e Lopes da Silva, 1999).

## 2.7 Considerações Finais

Neste Capítulo foi apresentada uma revisão bibliográfica sobre o eletroencefalograma (EEG). Foi descrita a forma com que os potenciais elétricos capturados pelo EEG são gerados no cérebro, a estrutura e propriedades elétricas do cérebro e a imagética motora e os eventos neurais que permitem sua identificação no EEG.



---

# Processamento de Eletroencefalograma

---

## 3.1 Considerações Iniciais

Neste Capítulo é apresentada uma revisão bibliográfica sobre o processamento do sinal de EEG. São apresentados conceitos básicos de processamento de sinais e séries temporais e são discutidas as especificidades do processamento de EEG como a remoção de artefatos e as técnicas de extração de características, além dos métodos de classificação tipicamente usados.

## 3.2 Características do Sinal do EEG

Os sinais capturados com o EEG contendo a imagética motora também contém ruídos gerados por atividades do cérebro e do corpo não relacionadas. O objetivo do processamento do sinal do EEG consiste em eliminar esses ruídos indesejados e extrair características do sinal que maximizem a taxa sinal-ruído de modo a facilitar a tarefa de conversão desses sinais em comandos úteis (Vallabhaneni et al., 2005).

A classificação de EEGs aplicada a sistemas BCI oferece diversas possibilidades por permitir a interação com computadores sem o uso de músculos, como auxílio a deficientes, uso em jogos eletrônicos e em aparelhos complexos, como aeronaves. A classificação de EEGs tem também outras aplicações, como a detecção de ataques epiléticos (Goelz et al., 1999) ou hipóxia (Hu

et al., 2006b), sendo, portanto, aplicável nas áreas da saúde, entretenimento, engenharias, entre outras.

A maioria dos sistemas BCI funciona de modo não contínuo, síncrono, que usa conjuntos de dados do sinal do EEG já separados em janelas de tempo pré-definidas, cada uma correspondendo a uma determinada classe de atividade mental. Aplicações práticas de BCI precisam ser capazes de analisar o sinal completo e distinguir entre os estados de repouso da mente e os diferentes estados de controle, imagética motora por exemplo, possíveis (Satti et al., 2009).

A classificação contínua de EEGs é definida como um dos desafios para a popularização dos sistemas BCI fora dos laboratórios e foi incluída na última competição internacional de BCI, a *BCI Competition IV*, organizada pelo grupo de pesquisa *Berlin Brain-Computer Interface* da Universidade de Medicina de Berlim (Tangermann et al., 2012), na qual os pesquisadores Zhang et al. (2012) obtiveram o melhor resultado, com erro quadrático médio de 0,382. Além dos participantes da competição, Hsu (2011); Townsend et al. (2004); del Millán (2004) também trabalham com classificação contínua de EEGs e Khorshidtalab e Salami (2011) fazem uma revisão sobre os métodos aplicados à tarefa.

Como foi citado, entre as características da tarefa de classificação de EEG estão: dados ruidosos, alta dimensionalidade, a existência de informação temporal, sinais não-estacionários e conjuntos de treinamento, em geral, pequenos. Além disso, em se tratando da análise de EEG, tem-se o desafio extra de distinguir entre os estados de comando e o estado de repouso, em que não há intenção de ação, já que uma taxa alta de falsos positivos pode invalidar o sistema em algumas aplicações (Townsend et al., 2004).

Os sinais do EEG são de séries temporais com características específicas, de origem biológica. O cérebro pode ser visualizado como um sistema complexo que produz saídas continuamente, com forte dependência temporal, que podem ser capturadas pelo EEG na forma de séries temporais com características específicas.

Séries temporais são compostas por observações, dados sequenciais obtidos de uma série univariada, ou mais, no caso de séries multivariadas, sobre o tempo. Uma série multivariada  $X$  com  $k$  variáveis observadas por instante de tempo  $t$  possui a forma  $(x_{1t}, x_{2t}, \dots, x_{kt})$  (Ishii et al., 2011).

Há outras características a se considerar quando se analisa uma série temporal. Uma série temporal pode ser determinística ou estocástica, linear ou não-linear e estacionária ou não-estacionária. Uma série determinística apresenta um comportamento recorrente, se repetindo com o tempo na mesma ou em outras escalas. É possível prever o comportamento dessas séries, ao menos em curto prazo, modelando-as com técnicas derivadas da teoria do caos. Séries estocásticas, por sua vez, dependem de algum processo aleatório, além de poderem depender de seu histórico de observações. Técnicas estatísticas são mais apropriadas para uso em séries estocásticas (Shumway e Stoffer, 2010; Ishii et al., 2011).

No caso de uma série estocástica, deve-se ainda considerar se a série é linear, formada por uma combinação linear de valores do passado e ruídos, ou não-linear, formada por combinações não



lineares desses valores e que são mais difíceis de modelar. Além disso, a série temporal ainda pode ser classificada como estacionária, evoluindo no tempo sobre uma média e variância constante e não estacionária quando a série não satisfaz essas condições, apresentando comportamentos evolucionários com a média dos valores mudando quando novos valores são considerados (Morettin e Toloï, 2004; Ishii et al., 2011).

O sinal do EEG é um exemplo de série multivariada, com as  $k$  variáveis sendo obtidas simultaneamente por cada um dos diversos eletrodos, é não linear e é não estacionaria entre diferentes seções ou períodos de tempo, pois ocorrem mudanças na estrutura do cérebro no meio tempo que alteram os padrões de onda (Tangermann et al., 2012; Lotte et al., 2007). Existem ainda discussões sobre o determinismo no cérebro, mas em geral é aceito que o cérebro, e os sinais capturados deste, compreendem de um sistema determinístico caótico (Faure e Korn, 2001; Korn e Faure, 2003).

### 3.3 Remoção de artefatos em eletroencefalogramas

Fenômenos neurológicos devem ser a única fonte de controle para um sistema BCI. Artefatos são potenciais elétricos indesejados que contaminam o sinal do cérebro capturado pelo EEG e são, em sua maioria, de origem não cerebral, apesar de potenciais do cérebro poderem ser considerados artefatos em algumas aplicações. Potenciais evocados visuais podem, por exemplo, contaminar um sistema baseado no ritmo  $\mu$  de um BCI (Fatourechì et al., 2007).

Os artefatos podem ser de origem fisiológica ou externa. Os de origem externa, não fisiológica, como o ruído de 60Hz causado pela corrente elétrica dos equipamentos, são normalmente evitados por meio de blindagens e filtragens elétricas durante a captura do sinal. Artefatos fisiológicos surgem de uma variedade de atividades corporais. Artefatos de eletrocardiografia (ECG) são causados pelo batimento do coração e podem introduzir uma atividade rítmica no EEG; artefatos de eletromiografia (EMG) são causados por movimentos musculares (principalmente da cabeça, mandíbula ou língua) e o eletro-oculograma (EOG), causado por movimentos dos olhos, também é origem de muitos artefatos no EEG (Fatourechì et al., 2007).

A remoção do ruído ocular é a tarefa de remoção de ruído mais importante para sistemas BCI (Croft e Barry, 2000), filtros lineares passa-banda são uma alternativa efetiva de remoção de ruído. Além de filtros lineares, transformadas matemáticas como a transformada de Fourier e a transformada ondeleta são usadas para extrair características e eliminar ruídos das séries temporais do EEG (Lakany e Conway, 2005; Hsu e Sun, 2009; Ubeyli, 2008; Goelz et al., 1999).

A atividade do EMG pode causar grandes perturbações no sinal do cérebro e também possui um espectro de frequência grande, com seu máximo acima de 30 Hz. Artefatos de EOG normalmente são de alta amplitude, causados pelo piscar de olhos, ou de baixa frequência causado pelo movimento dos olhos. Artefatos de EOG tem um espectro de frequência amplo, com seu máximo de frequência abaixo de 4 Hz (Fatourechì et al., 2007).

O movimento dos olhos causa mudanças no campo elétrico em volta dos olhos e, consequentemente, no couro cabeludo. As distorções causadas pelo movimento do olho, devido a sua proximidade com o couro cabeludo, são as causas das distorções mais significativas no campo elétrico capturado pelo EEG, e a interpretação desses chamados artefatos oculares é problemática (Croft e Barry, 2000).

Há algumas formas de lidar com os artefatos oculares que não envolvem a correção do EEG. É possível realizar os experimentos de captura do EEG com os olhos fechados, o que reduz os artefatos introduzidos pelos movimentos rápidos dos olhos e elimina interferências causadas pelo ato de piscar. Também é possível realizar um controle experimental, fazendo com que os sujeitos do experimento se fixem em um ponto para reduzir o movimento dos olhos e as piscadas (Croft e Barry, 2000). Esses dois métodos apresentam, entre outros, o problema de serem um fator limitante nos tipos de experimentos que podem ser realizados.

Além disso, é possível ainda rejeitar os trechos do EEG que contêm artefatos oculares com uma voltagem maior que  $50\mu V$ , por exemplo. Essa abordagem em específico apresenta os problemas de não rejeitar os potenciais menores que o limiar definido, que podem continuar a afetar os resultados e um limiar pequeno o bastante para eliminar todos os artefatos oculares também eliminaria grande parte do EEG, incluindo dados que venham a ser relevantes (Croft e Barry, 2000). A rejeição também pode-se dar de forma manual, com um especialista inspecionando e rejeitando trechos do sinal que apresentem artefatos visíveis, o que é inviável para aplicações que processem o EEG continuamente, como sistemas BCI. A rejeição pode também ser feita de forma automática, que pode usar eletrodos específicos para capturar o sinal do EOG ou EMG e rejeitar trechos acima de um determinado limiar (Fatourechí et al., 2007). Devido ao grande número de artefatos existentes no EEG, como de piscadas, movimento dos olhos, respiração e EMG, nem todos os artefatos podem ser rejeitados e apenas trechos com presença forte de artefatos são removidos. Portanto, a rejeição não elimina completamente os artefatos.

A correção do EEG pela remoção dos artefatos oculares é a melhor alternativa para aplicações mais livres. Na análise em tempo real do EEG para um sistema BCI não podem haver pausas para descartar trechos do EEG devido a artefatos oculares. Da mesma forma, eliminar ou limitar a visão do sujeito a um ponto fixo não é eficiente para aplicações que fujam do ambiente controlado de um laboratório.

Uma das primeiras técnicas analógicas de remoção de artefatos é de Girton e Kamiya (1973) e envolvia o cálculo de um coeficiente de relação que incluía ajustar um atenuador enquanto o sujeito do experimento fazia movimentos extremos com os olhos. Depois de ajustar visualmente a possível atenuação para um dos dez possíveis fatores, a voltagem atenuada era subtraída do EEG para eliminar os artefatos. O principal problema com essas primeiras técnicas analógicas é que elas não eram sensíveis o bastante para estimar com acurácia os efeitos oculares e, apesar de visualmente o efeito corretor parecer bom, alguns artefatos permaneciam no EEG (Croft e Barry, 2000).

Gotman et al. (1973) introduziram o uso de filtros lineares, que têm como vantagem sua simplicidade e o fato que o sinal do EOG não é necessário para remover os artefatos. Filtros são bem sucedidos até certo grau em aplicações que usem frequências como a  $\mu$  e a  $\beta$ , caso dos sistemas BCI baseados em imagética motora. Esse método, apesar de se mostrar falho quando o fenômeno neurológico de interesse e os artefatos estão na mesma banda de frequência (Fatourechhi et al., 2007), ainda é usado atualmente em sua versão digital por ser relativamente simples e rápido, sendo incluído automaticamente ao se selecionar frequências em técnicas de extração de características como o algoritmo dos padrões espaciais comuns.

Whitton et al. (1978) propõem um método utilizando a transformada rápida de Fourier, filtrando o espectro do EOG com um filtro passa-baixa. Whitton então escalava linearmente o EEG e o EOG para que seus picos de baixa frequência fossem numericamente iguais e em seguida subtraía os segmentos que contivessem apenas artefatos oculares, resultando na filtragem dos artefatos no domínio do tempo do EEG.

Gratton et al. (1983) publica um então novo método para lidar com os artefatos oculares utilizando gravações de EOG e de EEG e calculando um fator de propagação que descreve o relacionamento entre eles, para então subtrair o EOG do EEG. Os testes de Gratton e colegas mostraram que seu procedimento acentuava os ERPs e reduzia a diferença entre os ERPs obtidos com a interferência de diferentes graus de EOG. Assim como a abordagem de Quilter et al. (1977), um problema com esse método é que o sinal do EOG subtraído também está contaminado pelo EEG, o que pode levar à remoção de parte deste sinal.

Hellyar et al. (1995) leva em conta que o EOG muitas vezes contém sinais de origem cerebral, já que não há nenhum tipo de isolamento elétrico entre os eletrodos usados para capturá-lo e os eletrodos que capturam o sinal do EEG e que, portanto, os filtros usados para remover artefatos oculares podem não se comportar direito. Outra falha notada é a inabilidade das técnicas da época de distinguirem entre artefatos e oscilações anormais, sendo essa última uma informação importante em alguns diagnósticos e aplicações. Hellyar e colegas propuseram então um sistema inteligente de remoção de artefatos oculares baseado numa série de regras condicionais construídas com a ajuda de especialistas, que superava essas falhas.

Uma forma mais recente de lidar com a remoção de artefatos consiste da separação cega de fontes, que identifica os componentes que são atribuídos aos artefatos e reconstrói o sinal do EEG sem estes. O mais usado desses métodos é a análise de componentes independentes (*independent component analysis*, ICA). O método ICA separa cegamente a mistura de fontes independentes de sinal, forçando-as em componentes independentes (Fatourechhi et al., 2007). ICA já foi aplicada diversas vezes para remover artefatos de sinais de EEG (Jung et al., 2000; Vigário et al., 2000) mostrando inclusive que o ICA aumenta a força de sinais relacionados à atividade motora no ritmo  $\mu$  (Makeig et al., 2000). Uma vantagem de métodos de separação cega de fontes é que eles não precisam de artefatos de referência obtidos do sinal de EOG para funcionar (Fatourechhi et al., 2007).

A análise de componentes principais (*principal component analysis*, PCA) também já foi utilizada para a remoção de artefatos em EEG. PCA usa os auto vetores da matriz de covariância do sinal para transformar os dados para outro sistema de coordenadas e encontrar a projeção dos dados de entrada com a maior variância. Os componentes do sinal são então extraídos projetando o sinal nos auto vetores. Este método mostrou-se efetivo para remoção de artefatos em (Hsu, 2011; Lagerlund et al., 1997; Lins et al., 1993). Uma desvantagem da PCA, conforme apontado por Fattourehchi et al. (2007), é que este requer que os artefatos não sejam correlacionados com o sinal do EEG. Assim, foi demonstrado que a PCA não consegue separar completamente os artefatos oculares do sinal de EEG, principalmente quando a amplitude de ambos é similar.

Além desses, outros métodos como a transformada ondeleta (Nguyen et al., 2012; Browne e Cutmore, 2002), filtros adaptativos não lineares (He et al., 2004), análise da fonte do dipolo (Berg e Scherg, 1994), redes neurais de função de base radial (Saastamoinen et al., 1998), máquinas de vetor de suporte (Shoker et al., 2005) e outros métodos também já foram aplicados à remoção de artefatos.

### 3.4 Redução de dimensionalidade e Extração de Características

Para lidar com a alta dimensionalidade, muitos trabalhos incluem técnicas de redução de dimensionalidade e seleção de características, como o padrão espacial comum (*common spatial pattern*, CSP), análise de componentes independentes (*independent component analysis*, ICA), análise de componentes principais (*principal component analysis*, PCA) e outras (Onton et al., 2006; Mu e Wang, 2010; Sabeti et al., 2007; Valderrama et al., 2012; Doynov et al., 2008).

O objetivo da redução de dimensionalidade é reduzir o número de dimensões dos dados selecionando apenas características que são significativas ou úteis para o estágio de classificação, enquanto outros dados menos significativos e os ruídos são omitidos. As técnicas usadas para extração de características em sistemas BCI são relacionadas ao mecanismo neural usado no sistema. O algoritmo dos padrões espaciais comuns, por exemplo, foi desenhado especificamente para sistemas baseados na imagética motora e obtém ótimos resultados nessa situação, mas não é recomendado para BCIs baseados em outras características.

Um determinado exemplo pode contar um grande número de características, das quais muitas podem não ser relevantes. Existem diversas definições sobre o que torna uma determinada característica relevante (Blum e Langley, 1997). Em geral é aceito que uma característica é relevante se ela fornece informação que favorece a distinção entre exemplos de uma classe A para uma classe B, por exemplo.

A remoção de características irrelevantes, ou seleção das relevantes, é importante. Ao remover características irrelevantes reduz-se os problemas causados pela maldição da dimensionalidade e

reduz-se o nível de ruído incluído no sistema. Também, em geral, é preciso menor poder computacional para computar os exemplos usando algoritmos de aprendizado de máquina (Blum e Langley, 1997).

O uso de uma técnica de pré-processamento para melhorar o sinal do EEG antes da seleção de características mostra-se essencial na maioria das aplicações de EEG (Bashashati et al., 2007). Essas técnicas servem, principalmente, para transformar ou selecionar os canais de EEG mais relevantes. Uma das técnicas mais usadas no processamento de EEG e a mais usada para classificação de imagética motora é a dos padrões espaciais comuns (CSP), usado, por exemplo, por Satti et al. (2009) em uma tarefa de classificação de imagem-motora no sinal contínuo do EEG e por Zhang et al. (2012); Ang et al. (2012) e outros dez competidores em tarefas de classificação de imagética motora em EEG na *BCI Competition IV* (Tangermann et al., 2012).

O CSP detecta padrões no EEG a partir da incorporação de informações espaciais no sinal. Uma desvantagem do CSP é que o mesmo requer que o EEG seja capturado com uma densidade alta de eletrodos. O maior problema do CSP é, porém, sua sensibilidade a artefatos no EEG. Como as matrizes de covariância são usadas como base para calcular o filtro espacial e são estimadas com base em um número comparativamente pequeno de exemplos, um único exemplo contaminado por artefatos pode causar mudanças extremas nos filtros espaciais (Guger et al., 2000).

Características baseadas na frequência têm sido amplamente usadas no pré-processamento do sinal. Doynov et al. (2008), por exemplo, usam um filtro passa-baixa e um filtro espacial laplaciano após a remoção dos artefatos para acentuar as áreas de interesse de sua pesquisa.

Representações mistas de tempo-frequência que mapeiam um sinal unidimensional em uma função bidimensional de tempo e frequência são usadas para analisar o conteúdo espectral dos sinais que são variantes no tempo devido à característica não estacionária do EEG. Essas transformadas no domínio do tempo e da frequência mostraram-se mais eficazes que as transformadas de Fourier tradicionais (Bashashati et al., 2007). A maior parte desses métodos são baseados em algoritmos de transformada ondeleta. Lakany e Conway (2005) reportam que o uso da transformada ondeleta contínua para a representação tempo-frequência acarretou em melhorias significativas em seus resultados. Hsu (2011); Hsu e Sun (2009) também usam a transformada ondeleta contínua para classificação de imagética motora no sinal contínuo do EEG.

A análise de componentes principais (PCA) também está entre as técnicas mais usadas no pré-processamento do EEG. A PCA é usado para redução de dimensionalidade descartando dos dados as características que contribuem menos para a variância deste. A PCA também é utilizado para remoção de artefatos, conforme comentado na Seção 3.3. Um porém no uso da PCA para redução de dimensionalidade é que ele não é otimizado para a separação de classes e funciona melhor se os componentes tiverem uma distribuição gaussiana (Bashashati et al., 2007).

## 3.5 Classificação de eletroencefalogramas

É preciso identificar os sinais capturados pelo EEG para, por exemplo, traduzi-los em comandos para sistemas BCI. Isso tipicamente é feito por um algoritmo classificador que pode agir sobre um sinal pré-processado, com ou sem a remoção de artefatos, ou sobre um vetor de característica extraído numa fase anterior.

Lotte et al. (2007) citam que dentre os problemas existentes nessa tarefa de classificação, os dois principais são a maldição da dimensionalidade e o dilema do viés-variância. A quantidade de dados necessária para descrever as diferentes classes aumenta com a dimensionalidade dos vetores de características. Então, se o número de dados para treinamento é pequeno comparado com o tamanho do vetor de características, ou seja, não é pelo menos de cinco a dez vezes maior, o classificador provavelmente dará resultados pobres. Em sistemas BCI geralmente a dimensionalidade dos dados é alta e os conjuntos de treinamento são comparativamente menores, o que faz com que a maldição da dimensionalidade seja uma das maiores causas de preocupação na classificação de EEG.

Vários tipos de classificadores já foram usados para o processamento de sinais de EEG para o uso em sistemas BCI, como classificadores lineares, redes neurais, modelo oculto de Markov, classificadores de vizinhos mais próximos e combinações de classificadores.

Os classificadores lineares são algoritmos que usam funções lineares para distinguir classes, e são alguns dos mais populares algoritmos para aplicações de BCI, apesar dos problemas serem, em geral, não lineares (Lotte et al., 2007). Os dois classificadores lineares mais utilizados são a análise discriminante linear (*linear discriminant analysis*, LDA) e as máquinas de vetor de suporte (*support vector machine*, SVM).

A LDA usa hiperplanos para separar dados de diferentes classes. O algoritmo assume que haja uma distribuição normal dos dados e o hiperplano é obtido buscando a projeção que maximize a distância entre duas classes e minimize a variância interclasse. Em problema com mais de duas classes, uma estratégia normalmente usada é o “um contra o resto”, que consiste de separar cada uma das classes de todas as outras (Lotte et al., 2007). O baixo custo computacional, junto com resultados razoavelmente bons faz com que essa técnica seja popular para a classificação de EEG, sendo usada, por exemplo, por Doynov et al. (2008); Wilson e Fisher (1995).

A SVM também usa hiperplanos para identificar classes, mas o hiperplano selecionado é o que maximiza as margens, isto é, a distância entre os exemplos de treinamento mais próximos (Lotte et al., 2007). Esse classificador também já foi aplicado com sucesso no processamento de EEG diversas vezes (Garrett et al., 2003; Schlögl et al., 2005; Lima et al., 2010), incluindo a classificação de imagética motora em EEG contínuo (Hsu, 2011).

As redes neurais artificiais são também muito usadas em sistemas BCI. A rede neural mais utilizada é o perceptron multicamadas (*multi-layer perceptron*, MLP), que já foi utilizada na maioria das aplicações de BCI (Castellaro et al., 2002; Ubeyli, 2008; Mirowski et al., 2009). A MLP é com-

posta por várias camadas de neurônios, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, e trata-se de um aproximador universal, ou seja, quando composto por suficientes neurônios e camadas, ela é capaz de aproximar qualquer função contínua. Alguns dos problemas da MLP são sua susceptibilidade ao excesso de treinamento, perdendo a capacidade de generalizar, especialmente em casos com dados ruidosos e não estacionários como os do EEG, requerendo um processo de parametrização e treinamento cuidadosos (Lotte et al., 2007). Além da MLP, diversas outras redes neurais já foram aplicadas na classificação de EEG, como a rede de função de base radial e outras (Robert et al., 2002; Carpenter et al., 1992).

O conjunto-KIII também já foi aplicado várias vezes a sinais de EEG, incluindo detecção de padrões em EEG (Kozma e Freeman, 2001, 2002), de hipóxia (Hu et al., 2006b,a; Zhang et al., 2008) e a geração de sinais artificiais EEG para estudos (Myers e Kozma, 2011). Nenhuma aplicação foi encontrada durante a revisão bibliográfica que incluísse a classificação de imagética motora ou classificação do sinal contínuo de EEG utilizando os conjuntos-K.

Os modelos ocultos de Markov (*hidden Markov models*, HMM) são classificadores dinâmicos populares do campo do reconhecimento de voz. Um HMM é um tipo de autômato probabilístico que provê a probabilidade de observar uma determinada sequência de características. Os HMM são bons algoritmos para a classificação de séries temporais e foram aplicados na classificação de EEG (Dolezal et al., 2006), incluindo o sinal do EEG sem qualquer pré-processamento (Solhjo et al., 2005) e classificação do sinal contínuo do EEG (Obermaier et al., 2001).

Técnicas de modelagem autoregressiva também foram aplicadas com algum sucesso à classificação do EEG (Pardey et al., 1996), além do algoritmo  $k$ -vizinhos mais próximos, que consiste em selecionar a classe de acordo com a classe da maioria dos  $k$  vizinhos mais próximos à instância, usando uma medida de distância como a euclidiana, por exemplo (Khorshidtalab e Salami, 2011).

## 3.6 Considerações Finais

Neste Capítulo foi apresentada uma revisão bibliográfica sobre o processamento dos sinais de eletroencefalogramas. Foram descritas as características da tarefa de classificação e as dificuldades, os ruídos introduzidos pelos artefatos no EEG e a alta dimensionalidade, seguido da revisão bibliográfica das técnicas de remoção de artefatos e dos métodos de pré-processamento para seleção de características e redução de dimensionalidade usados para contornar esses problemas. Também foram descritos os algoritmos mais utilizados para a classificação de EEG, incluindo os utilizados para classificar imagética motora no EEG.





---

# Conjuntos-K


---

## 4.1 Considerações Iniciais

Os conjuntos-K de Freeman formam uma hierarquia de modelos de populações de neurônios que correspondem a uma abordagem mesoscópica (intermediária) entre a atividade microscópica dos neurônios individuais que redes neurais mais clássicas como o perceptron utilizam e a atividade macroscópica do cérebro (Kozma et al., 2007; Kiss e Érdi, 2002). A hierarquia dos modelos é construída a partir de uma unidade básica que representa uma população de milhares de neurônios, modelada por uma equação diferencial ordinária. A partir dessa unidade base as redes neurais de maior complexidade (Figura 4.1) são construídas.

Freeman desenvolve a teoria dos conjuntos-K sobre a ideia de que a atividade dinâmica observado no cérebro surge a partir de interações entre massas ou populações de neurônios. Dessa forma, agrupamentos de neurônios, e não neurônios individuais, são responsáveis pela cognição (Ilin, 2008).

Evidências para esta teoria surgem a partir de observações do bulbo olfatório, a região do córtex responsável pela captação de cheiros, onde é possível observar dinâmicas espaço-temporais complexas mesmo em repouso e que, durante a captação de um odor, se alteram de forma que torna possível identificar padrões específicos para classes de estímulos. Uma análise matemática sobre esse comportamento sugere que o bulbo olfatório possui uma variedade de variáveis de estado viajando entre as órbitas de um atrator caótico de muitas dimensões e que, ao ser estimulado, o espaço de estados sofre alterações que causam a convergência dessas variáveis de estado para determinadas regiões do atrator (ou asas do atrator, em referência a trajetória feita pelo atrator de Lorenz, que se assemelha às asas de uma borboleta) (Freeman, 1991; Ilin e Kozma, 2006).



**Figura 4.1:** Hierarquia dos conjuntos-K de redes neurais do conjunto-KO ao conjunto-KIV. Adaptado de Kozma et al. (2007).

O nome da hierarquia de modelos - conjuntos-K - é uma homenagem de Freeman para o físico Aharam Katzir-Katchalsky, morto no massacre de Lod Airport em 1972, e pioneiro na aplicação de princípios da termodinâmica em seres vivos, especialmente na relação entre agrupamentos de células. O trabalho de Freeman é uma consequência direta do de Katchalsky (Erwin e Freeman, 2008).

A seção 4.2 apresenta uma breve introdução a alguns conceitos fundamentais sobre sistemas dinâmicos, que são a base para a compreensão dos conjuntos-K. Na seção 4.3 é feita uma discussão sobre as observações feitas por Freeman em relação às dinâmicas observadas no cérebro com relação à percepção e cognição e que motivaram a criação dos conjuntos-K. A seção 4.4 da sequência, apresentando a motivação biológica das massas de neurônios que são modeladas pela rede neural. Na seção 4.5 as equações de base dos conjuntos-K são desenvolvidas a partir do modelo de neurônio básico que é generalizado para um modelo de massa de neurônio, o conjunto-KO, e a função de conversão entre os modos de pulso e ondas que descreve a interação entre diferentes populações. As seções seguintes descrevem os conjuntos-KI, KII, KIII e KIV, incluindo os procedimentos de treino e classificação utilizando o conjunto-KIII.

## 4.2 Sistemas Dinâmicos

Os conjuntos-K são modelos computacionais criados para representarem com certo grau de fidelidade a dinâmica observada no cérebro. Especificamente, o conjunto-KIII foi modelado para simular o sistema olfatório a partir da observação da atividade elétrica do cérebro usando EEG, e interpretado utilizando conceitos de sistemas dinâmicos e de sistemas de controle. O conjunto-KIII em si é uma rede neural altamente dependente do caos. Alguns dos conceitos básicos de sistemas dinâmicos necessários para a compreensão dos conjuntos-K são apresentados nesta seção.

Um sistema dinâmico consiste de um conjunto de estados possíveis e de uma regra que determina o estado atual do sistema em termos de estados passados. Considere uma sequência de observações de uma variável  $x_1(t), x_2(t), \dots, x_N(t)$  representando o estado de um modelo, onde o tempo  $t$  é uma variável independente e  $N$  é a ordem do sistema (Haykin, 1999). As dinâmicas de um sistema podem então serem descritas da seguinte forma

$$\frac{d}{dt}x_j(t) = f_j(x_j(t)), j = 1, 2, \dots, N \quad (4.1)$$

onde a função  $f_j(\cdot)$  é uma função de seu argumento.

Um sistema dinâmico em que a função  $f$  não dependa explicitamente de  $t$  é dito autônomo, e chamado de não autônomo caso contrário. Independente da forma da função  $f$ , o estado  $x(t)$  deve variar com o tempo  $t$ , pois de outra forma este seria constante. Dessa forma, um sistema dinâmico é definido como um sistema no qual o estado varia com o tempo (Haykin, 1999).

Uma forma interessante de se observar o espaço de estados é descrevendo-o como o movimento de um ponto em um espaço de estados  $N$  dimensional. Esse espaço pode ser o espaço euclidiano ou qualquer outra variedade diferenciável. O espaço de estados provê uma ferramenta conceitual importante para analisar as dinâmicas dos sistemas focando a atenção nas características globais do movimento em vez de aspectos detalhados das soluções numéricas da equação.

O espaço de estados é uma construção matemática com coordenadas ortogonais representando cada uma das variáveis necessárias para especificar um estado do sistema em um instante, como a velocidade e a posição. Os valores numéricos de todas as variáveis do sistema em um momento do tempo dão a descrição do estado do sistema nesse momento do tempo. A dinâmica do sistema, ou a evolução, é indicada traçando uma trajetória nesse espaço (Faure e Korn, 2001).

Em um determinado instante de tempo  $t$  o estado observado do sistema é representado por um ponto em um espaço  $N$ -dimensional. Mudanças no estado do sistema com o tempo  $t$  são representadas como uma curva no espaço de estados, com cada ponto na curva correspondendo a uma observação no tempo. Essa curva é chamada de trajetória ou órbita do sistema. Um ponto  $p$  é um ponto fixo se a função  $f(p) = p$  para todo  $p$ , ou seja, se  $p$  não varia. Se todos os pontos suficientemente próximos de um ponto  $p$  são atraídos para  $p$ ,  $p$  é chamado de sumidouro ou de um atrator de ponto fixo. Caso contrário, se todos os pontos próximos a  $p$  são repelidos de  $p$ , então  $p$  é chamado de fonte ou de ponto fixo repelente (Haykin, 1999; Alligood et al., 1997).

Caso haja uma órbita com ponto inicial  $p$  que após um mínimo de  $k$  pontos retorna ao ponto  $p$ , ou seja  $F^k(p) = p$ , e que  $k$  seja o menor inteiro possível, a órbita é chamada de órbita periódica de período  $k$ . Caso  $p$  seja um sumidouro para  $f^k$ , então a órbita é um sumidouro periódico ou atrator de ciclo limite e caso seja uma fonte, é uma fonte periódica ou um repelente periódico (Alligood et al., 1997). A vizinhança de um atrator para a qual os pontos são atraídos para este é chamada de bacia de atração do atrator.

Há ainda, além de atratores de ponto e atratores de ciclo limite, atratores de toro, com um formato mais complexo, lembrando uma rosca, com uma dinâmica quasi-periódica, ou seja, o atrator

possui ciclos quase periódicos, que aproximam-se da órbita mas nunca a repetem exatamente, e atratores caóticos ou estranhos. Atratores caóticos ou estranhos possuem uma dinâmica de caos determinístico, um tipo de dinâmica determinística mas com aparência aleatória. A predição em sistemas caóticos pode ser feita apenas para períodos curtos de tempo e, apesar do sistema ser confinado em um atrator, ele nunca repete exatamente o mesmo estado (Stam, 2005).

Existem algumas medidas para caracterizar as propriedades dos atratores. Uma delas é a dimensão do atrator. A dimensão de um atrator pode ser vista como uma medida do grau de liberdade ou complexidade de suas dinâmicas. Um atrator de ponto, por exemplo, tem dimensão zero. Um atrator de ciclo limite tem dimensão um. Um toro tem como dimensão um inteiro correspondente ao número de oscilações periódicas sobrepostas. Por fim, um atrator estranho tem dimensão fractal, não inteira, como por exemplo 2.16, que reflete a complexidade e geometria fractal do atrator estranho (Stam, 2005).

Um sistema dinâmico é chamado de multiestável se, em determinada configuração de parâmetros, o sistema possui mais de um atrator. Nessa situação, cada atrator ocupa sua própria região no espaço de estados com suas bacias de atração. Dessa forma, se o estado inicial do sistema cair dentro da bacia de atração de um certo atrator, o sistema evoluirá para esse atrator e permanecerá lá. Distúrbios externos fortes o bastante podem mover o sistema da bacia de um atrator para a de outro atrator. Num sistema multiestável o total de atratores coexistentes e suas bacias criam uma paisagem de atratores característicos para o conjunto de parâmetros que controla o sistema (McKenna et al., 1994; Stam, 2005). Mudanças nesses parâmetros de controle podem deformar suavemente a paisagem de atratores. Porém, em valores críticos dos parâmetros as mudanças, ou transições, podem ser súbitas e dramáticas na paisagem. Essas transições são chamadas de bifurcações e causam o desaparecimento e surgimentos de atratores.

O cérebro ou partes desse podem ser interpretadas como um sistema dinâmico caótico (Korn e Faure, 2003). As observações feitas por Freeman sugerem que o caos é essencial para a cognição e para o processamento biológico de informação (Freeman, 1987), e faz-se a suposição de que cérebros são organizados de forma que ocorra o surgimento de atratores caóticos que representem memórias, conceitos e ações. As dinâmicas não convergentes exibidas no EEG, por exemplo, seriam essenciais para o processamento de informações no cérebro. Os conjuntos-K buscam modelar essa atividade caótica observada, sendo capazes de reproduzir a dinâmica observada nos EEGs (Myers e Kozma, 2011).

## 4.3 Percepção e Cognição

O fato do cérebro ser capaz de perceber e reconhecer faces e odores familiares em instantes, mesmo diante de estímulos complexos e com grande variação de contexto, é uma das motivações por trás da criação dos conjuntos-K por Freeman.

Sabe-se que durante a inalação de um odor, as moléculas responsáveis pelo cheiro são capturadas por alguns dos muitos receptores especializados existentes nas passagens nasais. A excitação desses receptores pelas moléculas se propaga até o bulbo olfatório, onde o número de receptores excitados indica a intensidade do estímulo e a distribuição espacial indica o tipo. Esse estímulo é processado e codificado na forma de um padrão espaço-temporal de ativações no bulbo olfatório, que é então transmitido para outras partes do cérebro.

Freeman (1975) busca com sua pesquisa entender de que forma o cérebro é capaz de separar o estímulo de interesse de todos os outros muitos estímulos que existem em segundo plano, como todos os outros cheiros do ambiente por exemplo e, ainda, como o cérebro é capaz de generalizar sobre esses estímulos quando apenas alguns dos muitos receptores sensíveis são excitados a cada estímulo.

Experimentos com animais mostraram que cada neurônio no bulbo olfatório participa de alguma forma na geração da percepção de odores, de forma que a informação sobre o estímulo é carregada na forma de um padrão distinto de atividade que ocorre por toda a extensão do bulbo, e não apenas por um subconjunto de neurônios detectores de características.

A partir dessas observações, Freeman (1975) inicia a investigação da atividade coletiva dos neurônios em animais treinados, usando eletrodos dispostos em matrizes e inseridos cirurgicamente sobre a superfície do bulbo, de modo a permitir a observação do EEG durante a inspiração e expiração de odores familiares ou não, com cada canal do EEG refletindo a excitação média de massas locais de neurônios, com aumentos da amplitude das ondas indicando aumento na excitação e quedas representando inibição.

O EEG sempre oscila em indivíduos vivos. Em repouso, as oscilações são irregulares, mas quando ocorre uma inalação, uma explosão de oscilações ocorre no EEG e todas as ondas capturadas pelos eletrodos tornam-se mais regulares por alguns milissegundos, com as ondas normalmente tendo maior amplitude e frequência do que em repouso. Durante esse período é possível identificar uma forma de onda comum, que Freeman chama de onda portadora, com um padrão de subidas e descidas embutido no sinal. A amplitude média dessa onda não é idêntica em todo o conjunto, mas todas sobem e descem em quase sincronia (Freeman, 1991).

O padrão da onda portadora, porém, não identifica o odor. Esse padrão muda a cada vez que o animal inala, mesmo que seja o mesmo odor. Só é possível discernir o odor pelo padrão espacial de amplitude da onda portadora pelo bulbo.

Outra observação feita por Freeman é de que, quando treinados para reconhecer certos estímulos, a força da conexão entre certos neurônios aumenta na forma predita pela regra de Hebb. Esse reforço nas conexões ocorre precisamente entre as sinapses dos neurônios, ou entre as populações de neurônios, que são excitados simultaneamente (Freeman, 1992).

## 4.4 Modelo Biológico de Populações de Neurônios

A abordagem adotada por Freeman (1975) é a de que as interações entre populações de neurônios são responsáveis pelo funcionamento do cérebro. Freeman iniciou seus estudos sobre as populações de neurônios a partir de experimentos com EEG em animais, focando-se no bulbo olfatório. O bulbo olfatório é uma parte especializada do cérebro em que o estado estável está em relativo equilíbrio e que é relativamente independente de outras partes do cérebro para seu funcionamento, por ser um dos mais primitivos. Fisiologicamente, o bulbo olfatório é mais fácil de ser observado por estar isolado dos outros córtices.

Não é possível descrever todas as conexões entre todos os neurônios do cérebro. É possível, porém, representar o cérebro como que consistindo de conjuntos, ou populações, de neurônios com dinâmicas definidas e descrever as conexões entre essas populações. A motivação para os conjuntos-K é a de modelar comportamentos complexos do cérebro a partir da definição das conexões funcionais e observáveis entre populações neuronais (Freeman, 1975).

Uma série de suposições são feitas por Freeman (1975) para permitir a modelagem matemática das populações de neurônios do cérebro:

1. as conexões entre neurônios podem ser determinadas, ao menos o bastante para se conhecer uma média do disparo de pulsos pelos axônios dos neurônios e a variação de potenciais, capturada na forma de onda, no córtex;
2. a atividade macroscópica é distribuída de forma contínua no espaço em certas massas neuronais do cérebro, sendo possível definir um volume ou superfície grande o bastante para que o nível de atividade seja uma média sobre um conjunto de neurônios e pequeno o bastante para que a média seja válida sobre toda a superfície;
3. considera-se o tempo e escala de distância macroscópica como muito maior que o de neurônios individuais, de 0.5 a 5 ms na escala de neurônios individuais e até 100 ms na escala macroscópica;
4. deve ser possível descrever os estados macroscópicos de populações de neurônios interativas por meio de equações diferenciais sem que haja necessidade de referenciar explicitamente potenciais de ação, sinapses, períodos refratários e outras propriedades individuais de neurônios, porque a distribuição dessas tende a ser distribuída uniformemente na massa neural;
5. o nível de atividade de cada neurônio deve ser em média consistente com a média do conjunto de sua vizinhança.

A dinâmica dos conjuntos de neurônios pode se tornar excessivamente complexa, de forma que Freeman (1975) restringiu sua análise apenas aos conjuntos experimentalmente concebíveis. Os conjuntos são organizados em uma topologia hierárquica. Os níveis são designados KO, KI,

KII, KIII e assim por diante. Essa hierarquia funciona de forma que um agrupamento biológico de neurônios no nível de complexidade KII é designado uma massa (de neurônios) KII e é representado no modelo matemático por um conjunto-KII.

O nível mais básico da hierarquia, o KO, é qualquer conjunto de neurônios com cerca de  $10^4$  neurônios, embora possa variar de  $10^3$  a  $10^8$ , que possuam uma fonte comum de entrada e um tipo (excitatório ou inibitório) comum de saída (excitatório ou inibitório) e sem interconexões entre si, dentro do próprio conjunto. O KI é qualquer conjunto de neurônios com uma fonte de entrada em comum, um tipo comum de saída e uma densa interação entre os neurônios no conjunto. O tipo de saída do KI pode ser, novamente, positivo ou negativo. Já o KII é formado pela existência de densas interconexões entre dois KI, normalmente com sinais diferentes (um KI excitatório e um inibitório). No conjunto-KII, cada neurônio excitatório interage com outros neurônios excitatórios e inibitórios. Exemplos de massa de KII biológicas são encontradas interconectadas em várias partes do sistema olfatório, como o bulbo olfatório, o núcleo olfatório anterior e o córtex prepiriforme (Freeman, 1975).

## 4.5 Conjunto-KO: modelo não interativo de massa de neurônios

Essa seção é em sua maior parte baseada no trabalho seminal de Freeman publicado no livro “*Mass Action in the Nervous System*” de 1975 (Freeman, 1975), que definiu as bases para as dinâmicas de populações de neurônio e deu origem aos conjuntos-K.

Experimentalmente, a modelagem das populações de neurônios se inicia pelo monitoramento das entradas e saídas das populações. Freeman considera o potencial extracelular médio da população de neurônios, capturado por meio de um eletrodo posicionado sobre a população, como a saída do modelo. Esse potencial extracelular, a saída do modelo representado nas equações por um escalar  $v(t)$ , é contínuo e possui a forma de uma onda, da mesma forma que outros sinais capturados por eletrodos no EEG por exemplo. Como entrada é definido um escalar  $p(t)$  do modelo considera-se os pulsos elétricos emitidos pelas sinapses de outros neurônios, ou a função densidade dos pulsos representando o comportamento médio das entradas recebidas por uma conexão entre populações, e a conversão da saída em ondas  $v(t)$  para a entrada em pulsos  $p(t)$  das populações que recebem conexão desta é uma operação interna do neurônio definida por uma função  $Q(v(t))$ .

Os conjuntos-KI possuem um parâmetro adicional ao dos conjuntos-KO, chamado de ganho de retorno  $w$ . Esse ganho de retorno define a força da interação entre os neurônios do conjunto e sua densidade de atividade. Se a densidade de atividade é constante e não-zero, tem-se um ganho de retorno  $w = 1$ . Se a atividade for decrescente,  $w < 1$ , e caso seja crescente, o parâmetro de ganho é  $w > 1$ .

Biologicamente, um KI pode ser constituído por uma única massa de neurônios com alto grau de interconexão, ou, de forma equivalente, por dois conjuntos-KO conectados por meio de con-

xões bidirecionais com o mesmo sinal. Dessa forma, pode-se reduzir a complexidade do conjunto-KI no modelo para um ciclo de retorno entre dois conjuntos-KO, com o parâmetro  $w$  definindo a força ou peso das conexões entre os dois conjuntos-KO. De forma similar, pode-se reduzir a dinâmica de um conjunto-KII para a interação entre vários conjuntos-KO com conexões com sinais positivos e negativos.

A dinâmica média exibida por uma massa de neurônios não interativa como o KO é similar à encontrada em neurônios individuais. Freeman parte dessa observação para a construção de um modelo para massas neurais a partir da modelagem de um neurônio individual, utilizando conceitos de sistemas de controle. A modelagem é feita definindo a topologia das conexões funcionais e das variáveis de estado, depois pares de entrada e saída são dados e um domínio linear é estabelecido, com funções de base sendo escolhidas e aplicadas.

Freeman inicia a construção dos conjuntos-K pelo conjunto-KO, que modela uma massa de neurônios não interativos. A modelagem do sistema começa com a definição de uma entrada, que é simulada pelo uso de um choque extracelular para estimular os neurônios próximos ao conjunto-KI e ativar potenciais de ação  $p(t)$ . O choque é tratado como uma função de entrada descrita na forma de um impulso  $I\delta(t)$ , onde  $\delta(t)$  é o delta de Dirac <sup>1</sup>.

Para pequenos impulsos  $I$ , observa-se que o potencial extracelular  $v(t)$  permanece inalterado por um pequeno período de tempo  $T$  e então rapidamente aumenta até um pico e então retorna lentamente para sua base. A resposta a impulso de  $v(t)$  foi aproximada por Freeman usando dois termos, cada um correspondendo a uma fase (ascensão e decaimento do potencial extracelular) da resposta observada. A fase crescente representada pelo termo  $e^{-at}$  e a decrescente pelo termo  $e^{-bt}$ . A resposta a impulso dessa parte do neurônio é aproximada por:

$$v(t) = \begin{cases} \frac{ab}{b-a}(e^{-at} - e^{-bt}), & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (4.2)$$

onde  $a$  e  $b$  são duas constantes, que podem ser interpretadas como os atrasos ocorridos devido à natureza resistivo-capacitiva dos dendritos e da membrana dos neurônios, por exemplo, e que oram então aproximadas dos valores biológicos usando técnicas de regressão, para os valores  $a = 0,223 \pm 0,018$  e  $b = 0,716 \pm 0,089$ .

Uma equação diferencial ordinária é então derivada para a resposta a impulso.

A transformada de Laplace para  $v(t)$  é

$$V(s) = \frac{ab}{(s+a)(s+b)}. \quad (4.3)$$

<sup>1</sup>O delta de Dirac ( $\delta(t)$ ) é uma função matemática com as propriedades  $\delta(t) = 0, t \in \mathbb{R}, t \neq 0, \delta(t) = \infty, t = 0$  e  $\mathcal{L}_t[\delta(t)](s) = 1$  (Olver, 2010), comumente utilizado para representar impulsos.



Isolando o dividendo à direita

$$(s + a)(s + b)V(s) = ab \quad (4.4)$$

e aplicando a propriedade distributiva temos a equação

$$s^2V(s) + (a + b)sV(s) + abV(s) = ab \quad (4.5)$$

para a qual a transformada inversa de Laplace resulta na equação diferencial ordinária de segunda ordem correspondente:

$$\frac{d^2v(t)}{dt^2} + (a + b)\frac{dv(t)}{dt} + abv(t) = ab\delta(t) \quad (4.6)$$

, que representa o primeiro nível da hierarquia dos conjuntos-K.

As equações diferenciais definidas aproximam o modelo de neurônio médio e, de forma mais próxima, o comportamento médio de uma massa de neurônios não interativos como o conjunto-KO. As constantes  $a$  e  $b$  foram aproximadas por Freeman dos valores biológicos usando técnicas de regressão para os valores  $a = 0,223 \pm 0,018$  e  $b = 0,716 \pm 0,089$ .

### 4.5.1 Operação de conversão de ondas para pulsos

A conversão de atividades em modo de onda para pulsos no axônio, necessária para a modelagem da interação entre populações de neurônios, é feita por uma operação não linear  $Q(v)$ .

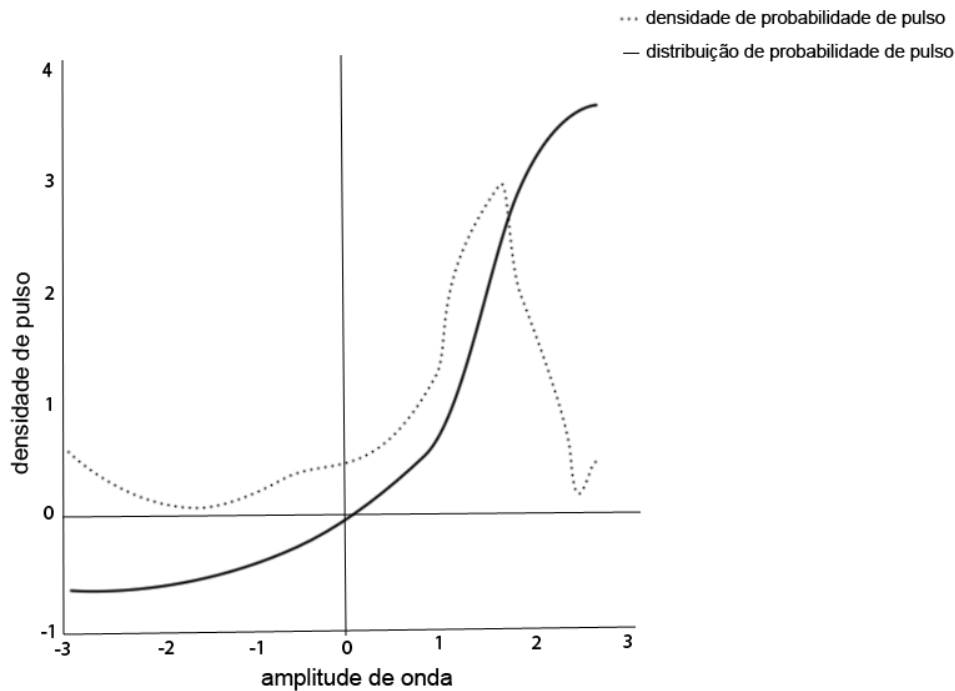
A função  $Q(v)$  foi derivada por Freeman (1979) experimentalmente por meio da análise das relações entre as ondas do EEG capturado  $v(t)$  e os pulsos  $p(t)$  capturados por microeletrodos. Freeman constrói um histograma a partir de suas observações, onde obtém como resultado a curva sigmoide assimétrica observada na figura 4.2.

Através da análise da relação entre os pulsos e o potencial elétrico em ondas  $v(t)$ , é feita a derivação da função não linear

$$\left\{ Q(v) = q_m \left( 1 - e^{-\frac{(e^v - 1)}{q_m}} \right) \right., \quad (4.7)$$

que corresponde a saída normalizada em modo de pulso de uma população de neurônios do nível conjunto-KO.


O valor do parâmetro  $q_m$  varia entre 1 e 14 para diferentes tipos de populações neurais biológicas e para diferentes estados do animal como dormindo, acordado ou excitado, por exemplo. O valor normalmente usado nos conjuntos-K é  $Q_m = 5$ , típico de animais acordados (Ilin e Kozma, 2006).



**Figura 4.2:** Curva sigmóide com a distribuição de probabilidade de pulso (linha sólida) obtida por Freeman (1979). Adaptado de Freeman (1979).

## 4.6 Conjunto-KI: modelo de interação entre massas

O próximo passo para a construção da hierarquia de modelos de populações de neurônios é o conjunto-KI. Os KI modelam a mais simples forma de interação entre populações de neurônios, representando populações que possuem interação interna com *feedback* positivo, ou seja, com o mesmo sinal. A modelagem dessa interação interna do conjunto-KI é feita através da conexão entre unidades de KO excitatórios, formando o  $KI_e$ , ou inibitórios,  $KI_i$ , conectados (Kozma et al., 2007). A figura 4.3 mostra a topologia resultante do conjunto-KI, modelado por dois conjuntos-KO e conexões.



**Figura 4.3:** Topologia do conjunto-KI com conexões de *feedback* excitatórias. Adaptado de Freeman (1975).

O conjunto-KI pode ser descrito pelo conjunto de equações diferenciais:

$$\begin{cases} \frac{d^2 v_{k_1}(t)}{dt^2} + (a+b) \frac{dv_{k_1}(t)}{dt} + abv_{k_1}(t) = abk_{21}Q(v_{k_2}, t) + I(t) \\ \frac{d^2 v_{k_2}(t)}{dt^2} + (a+b) \frac{dv_{k_2}(t)}{dt} + abv_{k_2}(t) = abk_{12}Q(v_{k_1}, t). \end{cases} \quad (4.8)$$

onde  $v_{k_1}(t)$  é a variável de estado e saída do conjunto-KO<sub>1</sub>,  $v_{k_2}(t)$  é a variável de estado e saída do conjunto-KO<sub>2</sub>,  $k_{12}$  é uma variável que representa a força da conexão do conjunto-KO<sub>1</sub> para o conjunto-KO<sub>2</sub> e  $k_{21}$  do KO<sub>2</sub> para KO<sub>1</sub>.  $I(t)$  é um estímulo externo que chega ao conjunto-KI através do primeiro conjunto-KO, que é integrada às entradas recebidas pelas outras conexões recebidas nos dendritos, e a função  $Q(v)$  descreve a transformação da saída de um conjunto-KO para a entrada do conjunto-KO seguinte.

O conjunto-KI tem um equilíbrio estável para entrada  $I \geq 0$  com  $\zeta k_{ij} = 1$  e apresenta uma queda monótona do valor de pico para  $k_{ij} < 1$ .

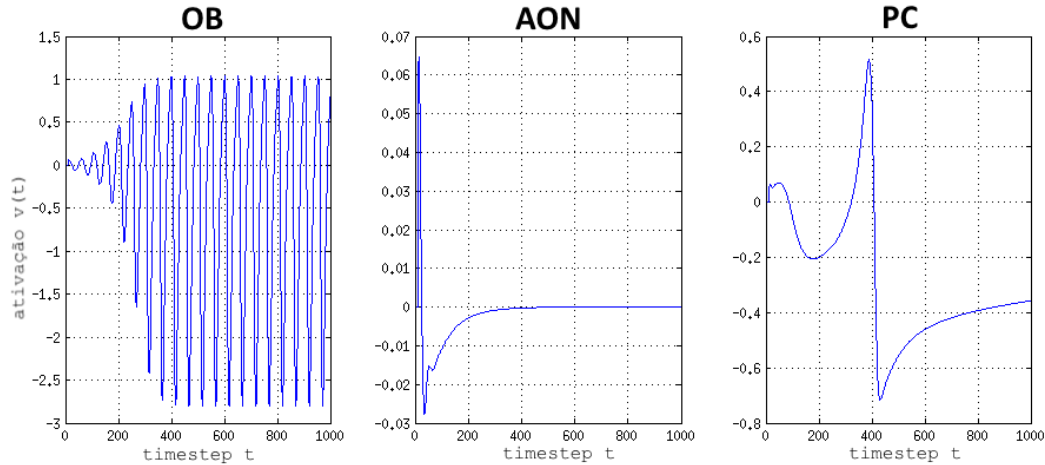
## 4.7 Conjunto-KII

Conjuntos-KII são formados por distribuições interativas de neurônios excitatórios e inibitórios. O KII é construído a partir de pelo menos dois KIs ou quatro KOs densamente conectados. O comportamento mais interessante do KII surge quando é construído por KIs ou KOs com polaridades inversas (Figura 4.5). As conexões do KII têm pesos fixos, e os KIIs formam osciladores quando essas conexões são configuradas (Kozma e Beliaev, 2004). Normalmente os conjuntos-KII são parametrizados para comportarem-se de forma similar às massas neurais KII biológicas. Existem três tipos de KII, baseados em sua trajetória de ativação, com atrator positivo, negativo ou zero (Kozma e Freeman, 1999). A parametrização do conjunto-KII pode ser feita utilizando o auxílio de ferramentas de análise de bifurcação, como feito na análise de (Ilin e Kozma, 2006, 2007).

As equações para o conjunto-KII são

$$\begin{cases} \frac{d^2 v_{k_1}(t)}{dt^2} + (a+b) \frac{dv_{k_1}(t)}{dt} + abv_{k_1}(t) = ab(-\zeta k_{ie}Q(v_{k_2}) + \zeta k_{ee}Q(v_{k_3}) - \zeta k_{ie}Q(v_{k_4})) + I(t) \\ \frac{d^2 v_{k_2}(t)}{dt^2} + (a+b) \frac{dv_{k_2}(t)}{dt} + abv_{k_2}(t) = ab(\zeta k_{ei}Q(v_{k_1}) + \zeta k_{ei}Q(v_{k_3}) - \zeta k_{ii}Q(v_{k_4})) \\ \frac{d^2 v_{k_3}(t)}{dt^2} + (a+b) \frac{dv_{k_3}(t)}{dt} + abv_{k_3}(t) = ab(\zeta k_{ee}Q(v_{k_1}) - \zeta k_{ie}Q(v_{k_2})) \\ \frac{d^2 v_{k_4}(t)}{dt^2} + (a+b) \frac{dv_{k_4}(t)}{dt} + abv_{k_4}(t) = ab(\zeta k_{ei}Q(v_{k_1}) - \zeta k_{ii}Q(v_{k_2})) \end{cases} \quad (4.9)$$

As características de cada KII não variam muito dentro de uma mesma região do cérebro, já que as dinâmicas observáveis se mantêm. Porém entre diferentes regiões o comportamento do conjunto pode variar significativamente, como por exemplo entre o núcleo olfatório anterior (AON), o bulbo olfatório (OB) e o córtex prepiriforme (PC), todos parte do sistema olfatório modelado pelo conjunto-KIII e que possuem comportamentos distintos, como pode ser visto na figura 4.4.



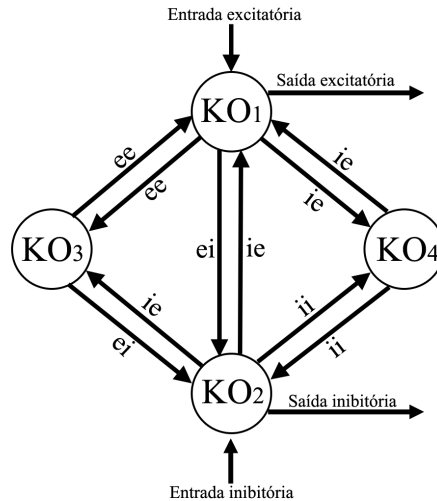
**Figura 4.4:** Simulação da resposta a impulso de três conjuntos-KII representando os modelos biológicos encontrados respectivamente no bulbo olfatório (OB), núcleo olfatório anterior (AON) e córtex prepiriforme (PC).

Dessa forma, existem “camadas” de conjuntos-KII interconectados no cérebro, formando algo como um nível intermediário entre o conjunto-KII e o conjunto-KIII. As conexões de *feedback* negativo  $k_{ei}$  e  $k_{ie}$  ocorrem apenas dentro de cada conjunto-KII. Conexões mutuamente inibitórias  $k_{ii}$  ocorrem com cada par de  $KO_{2,j}$  na camada, com os valores de  $k_{ii}$  sendo os mesmos para cada KII. Conexões excitatórias  $k_{ee}$  também ocorrem entre cada par de KII, mas o peso da conexão entre os conjuntos-KO de um KII para o outro pode variar individualmente para cada conexão.

Três tipos de interação ocorrem no conjunto-KII. A força ou peso da conexão dentro do conjunto- $KI_e$  é designada  $K_e$ , a do conjunto- $KI_i$  é designada  $K_i$ . Essas duas conexões constituem *feedback* positivo. A interação entre neurônios excitatórios e inibitórios constitui *feedback* negativo e é designada por  $K_n$ . Os valores desses pesos são determinados pelos valores obtidos pela aproximação dos lugares das raízes que mais aproximarem-se dos valores obtidos experimentalmente.

Uma série de conjuntos-KII conectados forma uma rede de KII. Nessa rede, o KO excitatório no topo de cada KII é conectado por meio de pesos laterais a todos os KO excitatórios dos outros KII na rede, e o mesmo ocorre para o KO inibitório mais inferior (Freeman et al., 1988). Os pesos das conexões excitatórias entre os KII são adaptados usando a regra de aprendizado hebbiana e os pesos inibitórios das conexões laterais são fixados e definidos por meio de medições fisiológicas (Principe et al., 2001).

As entradas são apresentadas como um vetor para uma rede de KII, que tende a formar padrões de oscilação. Quando um padrão de entradas conhecido é aplicado à rede após o treinamento, ela tende a exibir um padrão oscilatório reconhecível (Yao e Freeman, 1989). Redes de KII agem então como uma memória associativa, associando um padrão de entrada com padrões de oscilações da rede. Dessa forma, a saída da rede KII difere das obtidas com redes neurais usando modelos mais tradicionais porque ao invés de possuir saídas bem definidas, ela é representada de forma distribuída através da rede (Principe et al., 2001), de forma similar a uma rede de Hopfield.



**Figura 4.5:** Estrutura de um KII set com dois KO excitatórios (KOE) e dois KO inibitórios (KOi). As conexões entre os KO estão nomeadas como  $ee$ ,  $ei$ ,  $ie$  e  $ii$ , onde cada conexão possui um peso fixo definido. Adaptado de Li e Kozma (2003).

## 4.8 Conjunto-KIII

O conjunto-KIII é o primeiro nível dos conjuntos-K com possíveis aplicações práticas em aprendizado de máquina. Neste nível, os padrões espaço-temporais de atividade do modelo podem ser chamados de sinais neurais e são correlacionados aos estímulos externos recebidos pela rede. Em comparação com o modelo biológico, por exemplo, odores são representados por padrões espaço-temporais de atividade no bulbo olfatório da mesma forma que o conjunto-KIII busca representar as classes de entrada de seus estímulos em padrões espaço-temporais. A hipótese formulada por (Freeman, 1975) para o conjunto-KIII é que os sinais neurais existem em virtude da interação de neurônios em massa, que formam macroestados nos conjuntos-K de nível inferior.

O KIII é construído a partir de um conjunto de outras redes, com pelo menos três camadas formadas por conjuntos-KII e já foi utilizado com sucesso na detecção de faces (Carlos e Rosa, 2014; Zhang et al., 2006c), navegação de robôs (Harter, 2005), reconhecimento de dígitos falados (Li et al., 2007; Zhang et al., 2006a), classificação de estruturas em tecidos (Xiaomin et al., 2010), de chás (Yang et al., 2006) e de texto (Zhang et al., 2006b), predição de séries temporais (Kozma e Beliaev, 2004) e agrupamento (Kozma et al., 2013). Também já foi usado com sucesso para classificação de EEGs nos trabalhos de Kozma e Freeman (2001, 2002), em dois trabalhos de Hu (Hu et al., 2006b,a) e um de Zhang et al. (2008) na detecção de hipóxia, e na detecção de imagética motora (Piazzentin e Rosa, 2014).

A equação para o conjunto-KIII é descrita por

$$\frac{1}{ab} \left[ \frac{d^2 v_i(t)}{d^2 t} + (a + b) \frac{dv_i(t)}{dt} + abv_i(t) \right] = \sum_{j \neq i}^N [W_{ij} \times Q(v_j(t), q)] + I_i(t) \quad (4.10)$$

onde  $a = 0.22$  e  $b = 0.72$  são constantes temporais de populações biológicas de neurônios obtidas experimentalmente,  $v_i$  é a ativação da  $i$ -ésima população de neurônios,  $N$  é o número de populações no conjunto,  $I$  é o estímulo externo recebido,  $W$  é o vetor de pesos representando a força da conexão entre as populações  $i$  e  $j$ ,  $t$  é o tempo e  $Q(v)$  é a função de conversão de modo de ondas para pulso dada pela equação 4.7 (Ilin e Kozma, 2009).

O conjunto-KIII típico é baseado no sistema olfatório e é construído com base no mesmo, na figura 4.6 é mostrada uma representação do sistema olfatório e na figura 4.7 do modelo computacional conjunto-KIII.


A camada de conjuntos-KII OB (bulbo olfatório) recebe entradas excitatórias de um conjunto-KO, representando os receptores sensoriais, e transmite por excitação através do trato olfatório lateral (LOT) para a camada AON (núcleo olfatório anterior) e PC (córtex prepiriforme). A camada AON também transmite para a camada PG (periglomerular) por excitação e, também por excitação, para os conjunto-KO inibitórios da camada OB. A camada PC provê *feedback* negativo através de uma conexão excitatória para os conjuntos-KO inibitórios da camada AON e, por uma conexão longa que simula os neurônios de projeção do PC, para a camada OB. Os atrasos  $D_i$  são calculados através de medições das velocidades de condução e distância entre as estruturas. A saída do PC é através das células piramidais profundas C. A cada conexão é atribuído um peso  $w_{ij}$  e um sinal (+ para excitatório, – para inibitório) (Freeman, 1987).

O conjunto-KIII funciona como uma memória dinâmica capaz de memorizar e reconhecer padrões espaciais. Esse fato é compatível com a biologia do sistema olfatório, em que um grande número de receptores para odores particulares espalhados de forma não homogênea na mucosa, transmitem para o bulbo olfatório quando excitados durante uma fungada, causando o surgimento de padrões espaciais. Durante um período de aprendizado, um padrão é formado como resultado da coativação entre vários pares durante cada tentativa, de forma a ser uma generalização sobre a experiência.

Na ausência de estímulo, o sistema olfatório encontra-se em um estado espacialmente coerente de atividade basal de alta dimensionalidade, com uma atividade contínua e espontânea, da mesma forma observada a partir do instante  $t = 1000$  na figura 4.8.

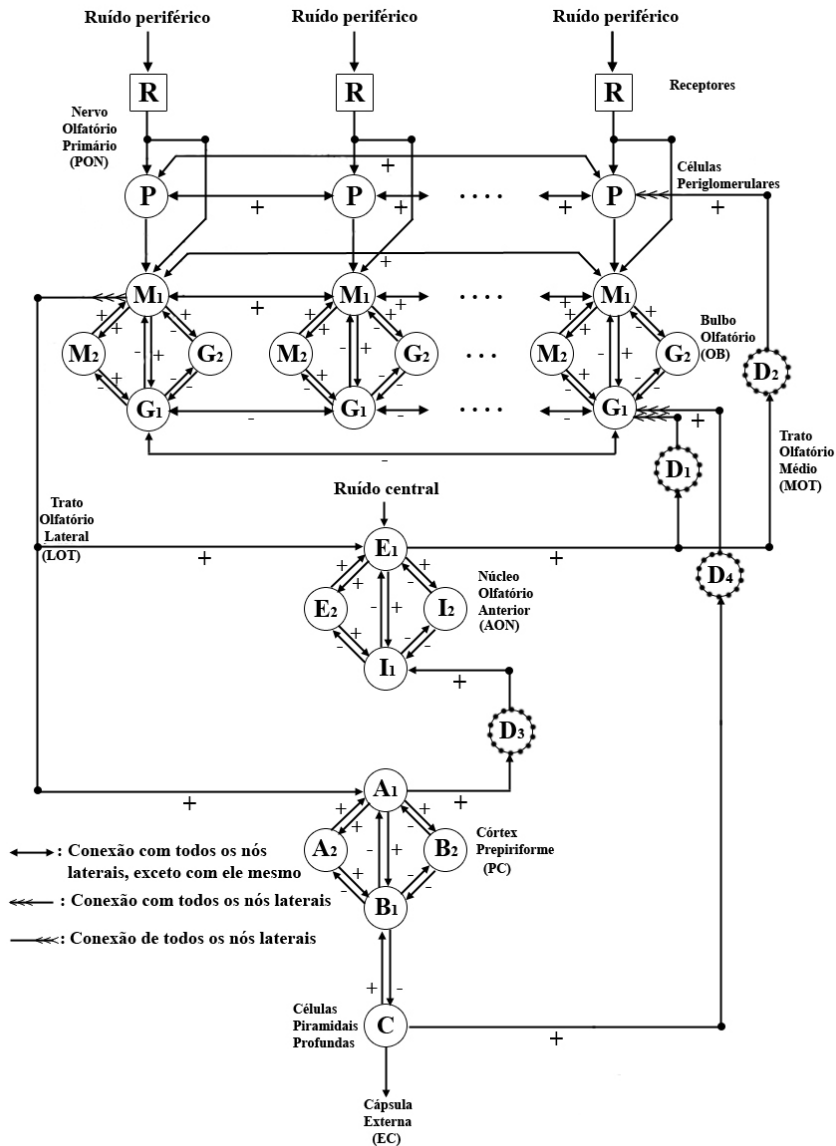
Esse estado de atividade basal é descrito como um atrator global aperiódico (caótico) por Freeman (1992). Quando recebe um estímulo externo, o sistema sai do estado basal para uma região da memória local, ou uma “asa” do atrator global caótico. O sistema então permanece nessa asa aproximadamente pelo tempo de duração do estímulo e retorna ao estado basal após o fim deste, num processo que tem uma duração de cerca de 200 ms.

Esse tipo de transição entre estados é chamado de itinerância caótica, algo proposto por Tsuda (2001) como uma classe universal de sistemas dinâmicos de alta dimensão. Nesses sistemas de alta dimensionalidade e com múltiplos estados, cada estado corresponde a um atrator mas, na ocorrência de uma instabilidade fraca, apenas um traço do atrator permanece no sistema, tornando-se uma “ruína” de atrator e fazendo com que direções instáveis apareçam na vizinhança, fenômeno relacionado aos atratores de Milnor (Korn e Faure, 2003). Atratores de Milnor podem possuir direções



**Figura 4.6:** Representação do sistema olfatório. O conjunto-KIII é baseado na estrutura do sistema olfatório. Adaptado de Principe et al. (2001).

instáveis e um sistema pode escapar delas como consequência a uma pequena perturbação, características encontradas em experimentos de Freeman (2000) por exemplo. Ainda, caso o sistema caótico seja desestabilizado por uma força suficientemente grande, o sistema move-se para um modo turbulento e muito ruidoso fazendo com que nesse caso não reste nenhum traço do atrator



**Figura 4.7:** Representação do conjunto-KIII. O conjunto-KIII é baseado na estrutura do sistema olfatório. Adaptado de Príncipe et al. (2001).

original (Tsuda, 2001), situação observada no conjunto-KIII quando há excesso de excitação ou de treinamento.


Caso a instabilidade não seja tão forte a ponto de destruir o atrator original, um estado intermediário entre ordem e desordem pode surgir com as dinâmicas de itinerância caótica, que indica uma transição correlacionada entre os estados. O estado do sistema antes da instabilidade corresponde a um atrator que não existe mais depois da instabilidade, porém um traço desse atrator original ainda existe, apesar das instabilidades em sua vizinhança. Esse traço do atrator desestabilizado é chamado de uma ruína de atrator. Nessa situação, em um sistema desestabilizado, existe de uma coleção de ruínas de atratores e órbitas conectando-os. Esse novo tipo de atrator é o que Tsuda chama de atrator itinerante (Tsuda, 2001).



A teoria de Tsuda se aplica ao funcionamento do conjunto-KIII. A memória da rede neural é definida como um atrator itinerante onde, durante o período de excitação o sistema converge para uma asa de atrator, com o treinamento da rede reforçando a órbita desse atrator, o que cria ou reforça uma “memória” do sistema, e a posterior recuperação da memória consiste de induzir, por meio de uma transição de estados, a convergência do sistema para a mesma asa de atrator (Kozma e Freeman, 2001). Essa convergência é identificável através do padrão espaço-temporal de modulação de amplitude que surge entre as unidades de conjuntos-KII que compõe o conjunto-KIII.

O comportamento caótico do conjunto-KIII é causado, principalmente, pela interação entre as três camadas de KII, que são conectadas por *feedback* positivo e negativo, que fazem surgir expoentes de Lyapunov positivos, zero e negativos nas equações (Freeman, 1975), criando uma interação complexa de convergência e divergência no sistema.

Para funcionar de forma adequada, o conjunto-KIII deve ser parametrizado para possuir dinâmicas iguais as encontradas no modelo biológico do sistema olfatório, em que foi inspirado. As frequências características de cada uma das três partes do sistema olfatório foram determinadas medindo a resposta média do tempo a um impulso, e foram ajustadas pela regulagem dos parâmetros dos pesos dos conjuntos-KII que compõe cada camada do conjunto (Kozma e Freeman, 2001). Partindo do estado estável zero, quando um impulso ou entrada é dado na entrada do sistema  $R$  e nenhum impulso adicional é dado, o sistema deve gerar atividade contínua, como na simulação mostrada na figura 4.8, e que possua as mesma propriedades estatísticas do EEG de animais em repouso.



**Figura 4.8:** Resposta ao impulso obtida das três camadas de um conjunto-KIII com tamanho de entrada  $n = 1$  obtida através da simulação dos conjuntos-K.

A otimização dos parâmetros do conjunto-KIII como simulador do sistema olfatório foi feita por Freeman e colaboradores em três passos. Primeiro, parâmetros que podem ser medidos ex-

perimentalmente, como os valores de taxa da membrana passiva e atrasos de condução, foram obtidos inicialmente por Freeman (1975). Dessa forma os parâmetros usados em redes de menor nível como *feedback* entre populações no conjunto-KII foram definidos experimentalmente. Em seguida, Chang e Freeman (1996) trabalharam na otimização dos parâmetros do conjunto-KIII analisando camadas individuais do sistema olfatório biológico, como o OB, AON e PC, com respeito aos potenciais médios dessas camadas no cérebro. Assim, as camadas do conjunto-KIII foram parametrizadas para possuírem potenciais evocados médios similares aos observados no cérebro. Chang et al. (1998b) usam técnicas de busca globais e locais para otimizar o conjunto-KIII para a geração de ruído  $1/f$ , com pico na faixa de frequência gama, similar ao observado no sistema olfatório biológico.

Os critérios utilizados para otimização dos parâmetros do conjunto-KIII são Freeman et al. (1997); Kozma e Freeman (2001):

1. o sistema deve apresentar oscilações estáveis e robustas, tendo um espectro de energia próximo ao tipo  $1/f$ , no estado basal;
2. oscilações quasi-periódicas com picos na faixa gama (40 - 100Hz) durante a excitação da rede, correspondendo às “rajadas” observadas no EEG durante a inalação;
3. formas de onda espacialmente coerentes entre todos os subconjuntos-KI excitatórios e entre todos os KI inibitórios da camada OB;
4. transição do estado de repouso para um dos estados de excitação em cerca de 10 ms a partir do recebimento de um impulso;
5. histogramas de amplitude no modo de pulso e modo de onda próximos a uma gaussiana;
6. médias e distribuições da saída dos conjuntos-KI excitatórios e inibitórios de cada conjunto-KII na camada OB na primeira metade da função sigmóide  $Q(v)$ ;
7. médias e distribuições da saída dos conjuntos-KI excitatórios e inibitórios de cada conjunto-KII na camada PC na segunda metade da sigmóide de  $Q(v)$ ;
8. médias próximas de ativação entre os conjuntos-KO<sub>i</sub> em cada conjunto-KII do sistema;
9. médias próximas entre todos os conjuntos-KI<sub>e</sub> da camada OB, independente da amplitude;
10. em cada conjunto-KII, a conexão mutuamente inibitória deve ter um peso maior que a excitatória ( $k_{ii} > k_{ee}$ );
11. a média dos atrasos das conexões entre camadas deve ser maior que a duração de meio ciclo da frequência característica do conjunto-KII receptor.

Dessa forma, seguindo os critérios definidos busca-se obter um conjunto-KIII estável. Freeman et al. (1997) definem um conjunto-KIII como estável se, dado estímulos iguais em diferentes intervalos de tempo, separados por períodos com outros estímulos ou repouso, a média e a amplitude das oscilações variem, no máximo, até 2 desvios padrões.

Apesar da otimização de parâmetros, as primeiras versões do conjunto-KIII sofriam com a aglomeração dos atratores formados durante a operação de percepção para conjuntos com dimensões altas, tornando-se muito sensível a pequenas mudanças nos parâmetros, com a instabilidade crescendo com o tamanho do conjunto de osciladores no sistema (Freeman et al., 1997). O cérebro exibe uma atividade de fundo robusta e estável, não tendo sua função afetada por pequenas perturbações no ambiente. No conjunto-KIII, porém, um número de pequenas perturbações devido à simulação numérica no sistema podia levar a mudanças de estado globais, tornando-o muito instável.

Isso ocorre porque o número de atratores aumenta dramaticamente no conjunto-KIII com o tamanho da rede. Já foi verificado que sistemas grandes usando mais de cem equações diferenciais ordinárias sofrem com o fenômeno de aglomeração de atratores, em que o tamanho das bacias de atração fica tão pequeno que se aproxima da precisão numérica da simulação, e torna-se sensível a mudanças muito pequenas no sistema, como os erros de arredondamento ocorridos durante os cálculos numéricos.

A ocorrência do problema de instabilidade no modelo foi abordada por Chang et al. (1998a) com a introdução de ruído para estabilizar o sistema. Dois pontos de introdução de ruído gaussiano foram introduzidos ao modelo, considerando o modelo biológico. Uma fonte foi introduzida nos receptores – entrada de estímulo externo – e na camada AON com média zero e desvio padrão parametrizável entre cerca de 1 a 5% do desvio padrão do sinal, conforme visto na Figura 4.7, representando do ponto de vista biológico, respectivamente, fontes de ruído periféricas e central no sistema olfatório (Kozma e Freeman, 2001).

### 4.8.1 Aprendizado no conjunto-KIII

O treinamento do KIII ocorre de forma não supervisionada e é feito por dois processos; a regra de aprendizado hebbiana, que é usada para adaptar o peso das conexões excitatórias entre os conjuntos-KII e um processo de habituação, onde os pesos das conexões são reduzidos aos poucos para introduzir um processo de esquecimento na rede, o que a torna mais resistente a ruídos nos dados. Esse processo ocorre nas conexões laterais excitatórias entre os KII da terceira camada (PC) (Kozma et al., 2007). Um terceiro processo de aprendizado consistindo da normalização da atividade dos nós para manter a estabilidade também pode ser incluído, mas normalmente esse processo é restrito à parametrização inicial do modelo e não é incluído no treinamento (Kozma e Freeman, 2001).

A regra de aprendizado hebbiana é baseada no trabalho de Donald Hebb de 1949 intitulado “*The Organization of Behavior: A Neuropsychological Theory*”, que também introduz a ideia

de uma população de neurônios. Neurônios têm conexões sinápticas mais fortes com neurônios da própria população do que comparados com neurônios de outras populações. Essas conexões são reforçadas como resultado de um estímulo externo. Sempre que dois neurônios são ativados simultaneamente, as conexões sinápticas entre eles são fortalecidas (Haykin, 1999).

A habituação é um processo automático que serve para filtrar estímulos irrelevantes, confusos, ambíguos e indesejados, reduzindo o impacto de ruídos do ambiente. O processo de habituação é implementado por meio da diminuição lenta e constante dos pesos. A taxa de decaimento do processo de habituação é escolhida para ser menor que a taxa usada pela regra da Hebb para atualizar o peso, de forma que apenas as conexões que não são reforçadas por essa decaiam (Ilin, 2008), o que está de acordo com os processos fisiológicos, onde a habituação ocorre automaticamente a não ser que seja revogada pelo reforço da conexão.

O processo de habituação no conjunto-KIII é dado pela equação

$$w(t + 1) = \rho w(t) \quad (4.11)$$

onde  $\rho$  é a taxa de decaimento e  $w$  é uma conexão lateral excitatória entre dois KO.

Hebb introduz o conexionismo e as ideias de plasticidade no sistema nervoso central: sinapses podem ser criadas e destruídas e pesos sinápticos mudam de valor, o que permite a aprendizagem, codificando novos conhecimentos e reforçando os existentes (Haykin, 1999).

Em sua forma mais simples, a hipótese de Hebb para o aprendizado é descrita como

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (4.12)$$

onde  $\Delta w_{kj}$  é o ajuste aplicado ao peso sináptico do neurônio  $k$  com o sinal pré-sináptico  $x_j$  e pós-sináptico  $y_k$  e com  $\eta$  sendo uma constante positiva que determina a taxa de aprendizado da regra (Haykin, 1999).

Nessa forma mais simples, a regra de Hebb faz com que ocorra um crescimento exponencial nos pesos sinápticos, que leva a saturação da conexão e perda da capacidade de armazenamento de informação da sinapse. A hipótese da covariância supera essa limitação substituindo os sinais pré e pós-sinápticos pela diferença desses para suas respectivas médias  $\bar{x}$  e  $\bar{y}$  sobre um determinado intervalo de tempo (Haykin, 1999):

$$\Delta w_{kj} = \eta (x_j - \bar{x})(y_k - \bar{y}) \quad (4.13)$$

Nos conjuntos-K a regra de Hebb é usada como meio de modificar a conexão entre populações mesoscópica de neurônios em vez de neurônios individuais (Ilin, 2008).

Como os conjuntos-K oscilam constantemente, a regra de Hebb deve sofrer modificações para ser aplicada ao modelo. Uma das modificações utilizadas consiste em calcular a ativação média durante um período de tempo  $T$  e então calcular o desvio padrão das oscilações sobre  $T$ ,  $\sigma$ . Con-

siderando  $\bar{\sigma}$  a amplitude de oscilações média do vetor de ativações  $\vec{\sigma}$  e  $w_{pq}$  o peso da conexão bilateral entre o  $p$ -ésimo e o  $q$ -ésimo KO, a conexão é reforçada:

$$w_{pq}(t+1) = w_{pq}(t) + \Delta w_{pq} \quad (4.14)$$

onde

$$\Delta w_{pq} = \begin{cases} \eta(\sigma_p - \bar{\sigma})(\sigma_q - \bar{\sigma}), & \text{se } \sigma_p > \bar{\sigma}, \sigma_q > \bar{\sigma} \\ 0, & \text{caso contrário.} \end{cases} \quad (4.15)$$

Como o aprendizado Hebbiano funciona localmente no espaço de estados, ele normalmente reforça a estabilidade dos padrões aprendidos, reforçando memórias em particular.

### 4.8.2 Classificação com o conjunto-KIII

A tarefa de classificação com o conjunto-KIII é dividida em quatro fases. Antes do início do treinamento, o conjunto-KIII deve ser parametrizado, inicializando os pesos sinápticos da rede com os valores obtidos experimentalmente (Chang e Freeman, 1996; Chang et al., 1998b) e atribuindo valores pequenos próximos a zero às ativações de cada conjunto-KO pertencente à rede.

Em seguida, na fase de treinamento, os padrões são apresentados um a um durante o chamado período ativo, usualmente de 50 a 200 milissegundos. Durante o período ativo, a série temporal das ativações, o padrão de oscilação, de cada unidade da camada PC é gravada e seu desvio padrão é calculado. A saída, então, é um vetor de desvio padrão da unidade excitatória superior dos KII da camada PC. O sistema entra em um período de relaxamento que dura de 150 a 300 milissegundos logo em seguida. Durante esse período, as modificações sinápticas hebbianas e o processo de habituação acontecem (Ilin, 2008).

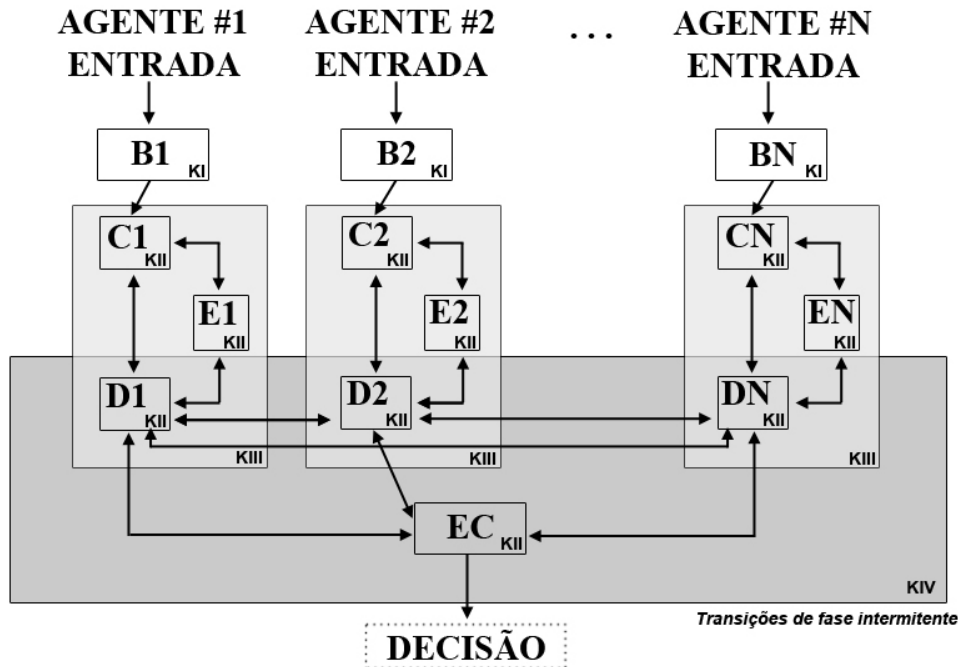
A próxima fase é a fase de rotulagem. Nessa fase os padrões usados durante o treinamento são novamente apresentados ao KIII. O vetor de saída então é lido e armazenado em uma tabela de referência, juntamente com o rótulo da classe, de forma a gravar a associação entre os padrões de oscilação e as classes do problema (Ilin, 2008).

Durante a fase de teste, cada padrão é apresentado ao sistema KIII. O vetor de saída então é lido e comparado com os armazenados na tabela de referência. O algoritmo mais utilizado para esta tarefa de comparação é o  $k$ -vizinhos mais próximos ( $k$ -nearest neighbors, KNN) (Kozma et al., 2007; Zhang et al., 2006a; Li et al., 2007) embora outros como a análise discriminante linear de Fisher também tenham sido usados (Ilin, 2008).

## 4.9 Conjunto-KIV

O KIV é formado pela interação entre três KIII conectados por meio da terceira camada de KIIs, sendo possível generalizar o modelo para mais unidades conforme visto na Figura 4.9 e

um extrator ou integrador, um KII, que detecta oscilações covariantes entre os diferentes KIII. O aprendizado no KIV ocorre no nível dos KIII (Kozma, 2008), com o integrador auxiliando a selecionar e conectar as características mais salientes entre os diversos KIII (Ilin e Kozma, 2009).



**Figura 4.9:** Diagrama de um conjunto-KIV. Adaptado de (Kozma et al., 2007).

É usado para modelar as interações no encéfalo frontal na tomada de decisões e geração de formas simplistas de comportamento intencional e provê uma plataforma biologicamente plausível para o estudo do comportamento cognitivo associado com aprendizado, com o ciclo ação-percepção, e com a formação de objetivos (Harter, 2006; Kozma, 2008). O conjunto-KIV é útil pela sua capacidade de integração de diferentes dados para tomada de decisões.

O KIV já foi aplicado no controle de robôs autônomos em problemas de navegação e testado com bons resultados em simulações de ambientes extraterrenos quanto a sua capacidade de evitar obstáculos, terrenos irregulares e buscar o menor caminho até o objetivo (Kozma e Freeman, 2009), reconhecimento de padrões entre diversos sensores (Ilin e Kozma, 2009) e na modelagem da dinâmica do cérebro para fins de estudo (Myers e Kozma, 2011).

## 4.10 Considerações Finais

Neste Capítulo foram apresentados os conjuntos-K de redes neurais. Os conjuntos-K são redes neurais biologicamente mais plausíveis inspirados na dinâmica do comportamento de populações mesoscópicas de neurônios e constituem uma hierarquia com vários níveis de complexidade cres-

cente. Os conjuntos-K têm sido aplicados a diversas tarefas, inclusive tarefas de classificação de EEG.





---

# Metodologia e Resultados

---

## 5.1 Considerações Iniciais

Neste Capítulo são apresentados a metodologia proposta para a classificação de imagética motora através do EEG e os resultados obtidos. A seção 5.2 descreve o simulador construído para os conjuntos-K e sua parametrização. Na seção 5.4 são apresentados os bancos de dados para testes e experimentos. Em seguida, na seção 5.5, as técnicas escolhidas para realizar o pré-processamento dos dados são descritas e justificadas. A aplicação dos modelos K para classificação e a avaliação dos resultados é discutida na seção 5.6.

## 5.2 Simulador para os conjuntos-K

Um simulador para os conjuntos-K de níveis KO até KIII foi construído e disponibilizado na linguagem Java (Piazentin, 2014) de forma a sanar algumas das deficiências encontradas no simulador disponível construído em Matlab desenvolvido por Beliaev et al. (2005), como defeitos que causam instabilidades na simulação, a falta de flexibilidade na parametrização do conjunto-KIII e o alto tempo computacional necessário para utilizar o simulador devido a decisões de projeto e da linguagem.

A linguagem Java foi escolhida por ser uma linguagem popular, multiplataforma, orientada a objetos e computacionalmente eficiente. O software desenvolvido em Java também permite fácil integração ao ambiente Matlab e outros.

A construção da hierarquia dos conjuntos-K segue um padrão em que os conjuntos-KI e KII são compostos pelas unidades básicas KO e as conexões entre estes. Cada conjunto-KO mantém um registro de todas as conexões que recebe, com seus respectivos pesos e atrasos. As equações diferenciais são resolvidas no simulador, para cada conjunto-KO, pelo método Runge-Kutta de segunda ordem.

Os conjuntos-KII, por sua vez, são utilizados para compor um nível intermediário que corresponde a uma camada de conjuntos-KII e o conjunto-KIII é composto por uma coleção de camadas interligadas de forma específica.

A construção modular do conjunto-KIII permite a flexibilidade para utilizar camadas de tamanho arbitrário, o que não era possível anteriormente, e permite que o treinamento e a captura da saída da rede ocorra em qualquer uma das camadas.

O conjunto-KIII construído no simulador pode ser parametrizado livremente. A configuração utilizada nos experimentos executados é apresentada a seguir. Os parâmetros dos conjuntos-K exibidos nas tabelas 5.1, 5.2 e 5.3 foram definidos através de buscas globais no sistema realizadas por Chang e Freeman (1996); Chang et al. (1998b); Beliaev et al. (2005), com o objetivo de otimizar o comportamento observável segundo os critérios definidos na seção 4.8.

A configuração padrão dos conjuntos-KII de cada camada é exibida na tabela 5.1.

**Tabela 5.1:** Pesos utilizados nos conjuntos-KII de cada camada do conjunto-KIII.


Pesos dos conjuntos-KII				
Camada	$w_{ee}$	$w_{ei}$	$w_{ie}$	$w_{ii}$
<b>1</b>	1.8	1.0	-2.0	-0.8
<b>2</b>	1.6	1.6	-1.5	-2.0
<b>3</b>	1.6	1.9	-0.2	-1.0

Os pesos das conexões laterais são inicialmente configurados com os valores definidos na tabela 5.2. Os valores da tabela 5.2 são utilizados para camadas com tamanho  $n = 1$ . Para camadas com tamanho  $n > 1$  o valor utilizado é  $\frac{w}{n-1}$ , onde  $w$  é o respectivo peso inibitório ou excitatório.

O treinamento nos conjuntos-K ocorre através da adaptação desses pesos segundo a regra de Hebb. A figura 5.1 mostra a evolução dos pesos na primeira camada de tamanho  $n = 12$  para um conjunto-KIII após 1000 exemplos de treinamento.


**Tabela 5.2:** Configuração padrão utilizada como valor inicial para os pesos laterais das três camadas do conjunto-KIII.

Pesos laterais		
Camada	excitatório	inibitório
<b>1</b>	0.15	-0.10
<b>2</b>	0.20	-0.20
<b>3</b>	0.15	-0.10



**Figura 5.1:** Evolução dos pesos laterais para um conjunto-KIII após 1000 ciclos de treinamento.

É importante observar que o excesso de treinamento pode causar instabilidades no conjunto-KIII por consequência do excesso de excitação do sistema, trazendo comportamentos e resultados indesejados. A Figura 5.2 ilustra o conjunto-KIII tendo o comportamento alterado devido ao excesso de excitação causado pelo incremento dos pesos das conexões.



**Figura 5.2:** Conjunto-KIII tendo o comportamento alterado devido ao excesso de excitação a partir do instante de tempo 2000.

Por fim, a descrição das conexões entre as três diferentes camadas de conjuntos-KII que compõem o conjunto-KIII são apresentadas na tabela 5.3. As conexões entre camadas possuem, além do peso, um atraso temporal. Dessa forma a saída no destino de uma conexão no tempo  $t$  com atraso temporal  $z$  sempre retorna o valor de ativação do nó de origem no tempo  $t - z$ .

As conexões são também definidas em relação à conexão entre os nós inibitórios ou excitatórios das camadas de conjuntos-KII. A conexão pode ser originada, portanto, a partir dos nós excitatórios ou inibitórios de uma camada e ser recebida pelos nós excitatórios ou inibitórios da camada de destino.

**Tabela 5.3:** Configuração das conexões entre camadas do conjunto-KIII.

Conexões entre camadas				
Camada de origem	Camada de destino	Tipo de conexão	Peso	Atraso
1	2	excitatório para excitatório	0.15	1
1	3	excitatório para excitatório	0.60	1
2	1	excitatório para excitatório	0.05	17
2	1	excitatório para inibitório	0.25	25
3	1	inibitório para inibitório	-0.05	25
3	2	excitatório para inibitório	0.20	25

Um período de ativação de 600 ciclos foi definido para a rede com 400 ciclos para o período de repouso. O período de ativação deve ter tamanho suficiente para que ocorra a transição de estados no conjunto-K e para que a rede se estabilize em um novo atrator. De forma similar, o período de repouso deve ser grande o bastante para que a rede retorne ao estado basal e estabilize.

O simulador construído foi validado por meio da observação e comparação do comportamento dos conjuntos com o do simulador construído por Beliaev et al. (2005) e pelo desempenho do simulador construído na tarefa de classificação de alguns conjuntos de dados públicos selecionados.

## 5.3 Agrupamento de dados sociais utilizando o conjunto-KIII

Foi desenvolvida uma aplicação de agrupamento de dados sociais utilizando o conjunto-KIII durante o período deste projeto. Apesar de não estar relacionado diretamente com a aplicação de classificação de imagética motora através do EEG, a tarefa de agrupamento de dados é um exemplo da aplicação da rede neural conjunto-KIII e dá sequência ao trabalho publicado em (Kozma et al., 2013).

Como o simulador dos conjuntos-K apresentado na seção 5.2 ainda estava em construção durante os experimentos iniciais, estes foram realizados utilizando o simulador de conjuntos-K construído em Matlab (Beliaev et al., 2005).

O método de agrupamento de dados proposto consiste da filtragem dos dados com o conjunto-KIII e posterior uso de um algoritmo de agrupamento. Os testes foram realizados usando dados de redes sociais da coleção de conjuntos de dados *Stanford Large Network Dataset Collection* consistindo de *ego-networks* das redes sociais Facebook e Google+.

Foram feitos testes com duas *ego-networks* do Facebook ( $fb_{107}$  e  $fb_{1684}$ ) e uma do Google+ ( $g_{plus}$ ). Os dados do Facebook são divididos em 26 categorias e os do Google+ em 6 categorias, incluindo cidade natal, sobrenome, universidade e emprego.

Um usuário na *ego-network* é representado por um vetor binário onde o tamanho do vetor é igual ao número total de valores para todas as categorias, resultando em vetores de alta dimensionalidade. A seleção de 9 características foi feita nos vetores de usuários usando o critério de máxima informação mútua (Basu et al., 2000).

O procedimento para execução dos experimentos consiste em selecionar as características para cada conjunto de dados e comparar, usando uma série de medidas de avaliação de performance e algoritmos de agrupamento, a performance do sistema usando dados filtrados com os conjuntos-K e dados sem esta filtragem.

São usados nove diferentes algoritmos de agrupamento no experimento (Brock et al., 2011; Datta e Datta, 2006; Dueck, 2009):

1. *Affinity Propagation* (AP): este método usa como entrada medidas de similaridade entre pares de dados;
2. *Unweighted Pair Group Method Average* (UPGMA): é um algoritmo hierárquico aglomerativo que junta pontos de dados e agrupamento usando uma medida de proximidade;
3. *Divisive Analysis Clustering* (DIANA): é um método hierárquico divisivo que inicia com todos os objetos em um único agrupamento e os divide até obter o agrupamento desejado;
4. *Agglomerative Nesting* (AGNES): este método funde sucessivamente pares de agrupamentos com maior semelhança até obter o agrupamento desejado;
5. *Mixture-model based* (MIX): neste algoritmo um modelo estatístico contendo uma quantidade finita de misturas de distribuições gaussianas, onde cada mistura representa um agrupamento, é ajustado aos dados;
6. *k-means*: é um método iterativo que minimiza a soma dos quadrados das classes dentro de um agrupamento para um determinado número de agrupamentos. É inicializado com um conjunto de centros de agrupamentos, onde cada objeto é posto no agrupamento mais próximo. Os centros são então atualizados e o processo é repetido até os centros estabilizarem;
7. *Partition Around Medoids* (PAM): é similar ao *k-means*, porém considerado mais robusto por utilizar pontos de dados como protótipos;
8. *Fuzzy C-Means* (FCM): realiza agrupamento nebuloso, onde cada objeto pode ser membro parcial de cada agrupamento;
9. *Self-Organizing Maps* (SOM): método não-supervisionado baseado em redes neurais e muito usado para visualizar dados em duas dimensões.

Para validação são utilizados oito diferentes critérios de avaliação divididos em três tipos: validação interna, externa e de estabilidade (Brock et al., 2011; Rendón et al., 2011; Xu e Wunsch, 2008). A avaliação de estabilidade mede a consistência de um novo agrupamento comparando-o com agrupamentos já obtidos. Avaliação interna considera apenas os dados e separação dos dados no agrupamento. Critérios externos comparam os resultados do agrupamento com uma estrutura especificada previamente.

Os métodos de avaliação são:

- Medidas de estabilidade:

1. *Average Distance between Means* (ADM): computa a distância média entre centros de agrupamentos, comparando o agrupamento baseado em todos os dados com o obtido quando uma única coluna é removida;
2. *Figure of Merit* (FOM): mede a média da variância dentro do agrupamento quando uma coluna de características é removida;
3. *Average Distance* (AD): corresponde à distância média entre objetos postos no mesmo agrupamento, com agrupamento baseado nos dados completos e nos dados com uma coluna removida;

- Medidas internas:

4. *Connectivity* (CONN): mede a qualidade do agrupamento pelo grau de conectividade entre os diferentes agrupamentos;
5. *1-Silhouette width* (1-SILH): o valor da silhueta mede o grau de confiança no agrupamento de um objeto em particular. A largura da silhueta é a média dos valores de silhueta de todos os objetos. Como a silhueta deve ser maximizada, adotou-se a diferença  $1 - \text{SILH}$ , que deve ser minimizada;

- Medidas externas:

6. *1-Purity* (1-PUR): a pureza foca na frequência da categoria mais comum em cada agrupamento, e é similar à entropia. Como a pureza deve ser maximizada, adotou-se a diferença  $1 - \text{PUR}$  que deve ser minimizada;
7. *Entropy* (H): a entropia mede a pureza dos rótulos de classe em cada agrupamento, de forma que se todos os rótulos consistirem de uma única classe, a entropia é 0, o melhor valor possível;
8. *1-Normalized Mutual Information index* (1-NMI): calcula a informação mútua normalizada entre o agrupamento obtido e o agrupamento esperado. Como a NMI deve ser maximizada, adotou-se a diferença  $1 - \text{NMI}$  que deve ser minimizada.

Os resultados são apresentados da seguinte forma; para a medida de avaliação  $i$ , algoritmo de agrupamento  $j$  e número de agrupamentos  $k$ , a razão entre os índices de saída por meio da filtragem com o conjunto-K  $\rho_{ijk}^K$  e sem filtragem com o conjunto-K  $\rho_{ijk}^\Phi$  é dada por:

$$r_{ijk} = \frac{\rho_{ijk}^K}{\rho_{ijk}^\Phi}. \quad (5.1)$$

A média de todas as razões para todos os números de agrupamentos é dada pela equação 5.2:

$$\bar{R}_{ij} = \frac{\sum_{k=1}^K r_{ijk}}{K} \quad (5.2)$$

onde  $K$  é o número total de agrupamentos, que varia de 2 a 20 nos experimentos.

A razão média  $\bar{R}$  para oito medidas de avaliação e para nove algoritmos de agrupamento aplicados aos três conjuntos de dados é dada na tabela 5.4. Para cada medida, valores menores representam melhor performance, de forma que valores de  $\bar{R}$  menores que 1.0 são favoráveis à filtragem com o conjunto-KIII.

Os resultados apresentados na tabela 5.4 mostram que a filtragem com o conjunto-KIII melhora o desempenho do agrupamento em 100% dos casos considerando as medidas de estabilidade, em 51.9% dos casos para medidas internas e em 44.4% dos casos para medidas externas. Em geral, em 67.1% dos casos o conjunto-KIII apresenta um resultado de agrupamento melhor, de acordo com as medidas de avaliação e dados utilizados.

## 5.4 Conjuntos de Dados

Os conjuntos de dados utilizados neste trabalho para a realização de experimentos são provenientes das competições *BCI Competition III* e *BCI Competition IV*, organizadas pelo grupo de pesquisa *Berlin Brain-Computer Interface* da Universidade de Medicina de Berlim (Blankertz et al., 2006; Tangermann et al., 2012).

As *BCI Competitions* são organizadas para incentivar o desenvolvimento de tecnologias em BCI provendo uma forma de validação das técnicas de análise e dados públicos para experimentos (Blankertz et al., 2006) e também como uma indicação da efetividade e popularidade dos métodos, como o uso quase onipresente do algoritmo dos padrões espaciais comuns na exploração da imagética motora (Tangermann et al., 2012). Cuidados devem ser tomados ao se comparar resultados com os da competição, já que há uma grande variância na quantidade de esforço despendida por cada competidor e os métodos de avaliação deixam uma margem para a sorte.

As *BCI Competitions* também cumprem o papel de disponibilizar bancos de dados públicos para que pesquisadores possam trabalhar com o processamento do sinal de EEG sem o custo inicial para se fazer a captura dos sinais necessários.

**Tabela 5.4:** Razão  $\bar{R}$  para os três conjuntos de dados sociais com 9 características selecionadas.

$fb_{107}$											
<i>kind</i>	<i>alg</i>										
		VM	<i>ap</i>	<i>upg</i>	<i>kme</i>	<i>dia</i>	<i>fcm</i>	<i>som</i>	<i>mix</i>	<i>pam</i>	<i>agn</i>
<i>stab</i>	AD	0.483	0.415	0.517	0.472	0.731	0.463	0.526	0.480	0.543	0.515
	ADM	0.000	0.260	0.479	0.293	0.357	0.230	0.315	0.186	0.192	0.257
	FOM	0.639	0.435	0.635	0.423	0.496	0.517	0.528	0.368	0.400	0.494
<i>int</i>	CONN	1.235	0.812	0.771	0.848	1.117	0.917	1.489	0.969	0.753	0.990
	1-SILH	0.862	1.082	0.979	1.422	4.179	0.938	2.206	2.225	1.688	1.731
<i>ext</i>	1-NMI	1.041	1.085	1.090	1.081	0.983	1.042	1.052	1.043	1.064	1.053
	1-PUR	1.029	1.056	1.060	1.065	0.985	1.021	1.031	1.034	1.042	1.036
	H	1.039	1.059	1.062	1.066	0.965	1.034	1.050	1.045	1.075	1.044

$fb_{1684}$											
<i>kind</i>	<i>alg</i>										
		VM	<i>ap</i>	<i>upg</i>	<i>kme</i>	<i>dia</i>	<i>fcm</i>	<i>som</i>	<i>mix</i>	<i>pam</i>	<i>agn</i>
<i>stab</i>	AD	0.603	0.302	0.408	0.353	0.611	0.625	0.568	0.398	0.361	0.470
	ADM	0.000	0.567	0.543	0.357	0.555	0.397	0.338	0.185	0.335	0.364
	FOM	0.748	0.336	0.509	0.339	0.460	0.614	0.503	0.282	0.337	0.459
<i>int</i>	CONN	0.820	0.659	0.621	0.683	1.363	1.376	1.555	0.834	0.659	0.952
	1-SILH	0.851	0.799	0.694	1.031	3.634	0.949	1.324	1.530	1.005	1.313
<i>ext</i>	1-NMI	1.029	1.002	0.994	0.989	0.957	1.019	0.986	0.999	1.017	0.999
	1-PUR	1.013	0.994	0.997	0.998	0.984	0.991	0.986	1.004	0.993	0.995
	H	1.021	0.967	0.971	0.976	0.958	1.009	0.990	1.001	0.998	0.988

$gplus$											
<i>kind</i>	<i>alg</i>										
		VM	<i>ap</i>	<i>upg</i>	<i>kme</i>	<i>dia</i>	<i>fcm</i>	<i>som</i>	<i>mix</i>	<i>pam</i>	<i>agn</i>
<i>stab</i>	AD	0.654	0.405	0.595	0.563	0.722	0.692	0.605	0.458	0.485	0.576
	ADM	0.000	0.442	0.747	0.724	0.402	0.569	0.071	0.251	0.636	0.427
	FOM	0.902	0.514	0.803	0.491	0.560	0.747	0.530	0.331	0.513	0.599
<i>int</i>	CONN	1.143	0.869	0.854	0.785	1.218	1.097	1.059	1.351	0.720	1.011
	1-SILH	0.849	1.152	0.942	0.880	2.793	0.849	1.216	1.184	0.759	1.180
<i>ext</i>	1-NMI	1.006	1.009	1.001	0.988	1.001	0.999	0.997	1.002	1.010	1.002
	1-PUR	1.007	0.989	0.982	0.978	0.968	0.973	0.983	0.993	1.004	0.986
	H	1.008	1.003	0.997	0.984	0.999	0.999	0.996	1.001	1.010	1.000

São de interesse para este trabalho os conjuntos de dados *I* da *BCI Competition IV* e os conjuntos de dados *IVb* e *IVa* da *BCI Competition III*.

Os conjuntos de dados *I* e *IVb* são destinados à tarefa de classificação do sinal contínuo do EEG sem nenhuma forma de sinalização nos dados anunciando o início de um evento. Há também o problema adicional de haver períodos em que o sujeito do experimento não tem intenção de controle, ou seja, não há imagética motora, períodos que o classificador deve identificar como em repouso. O conjunto de dados *IVa* disponibiliza exemplos individuais de imagética motora de duas classes distintas para serem classificados.



### 5.4.1 Conjunto de Dados I da BCI Competition IV

O conjunto de dados *I* da *BCI Competition IV* foi gravado exclusivamente para a competição. Quatro participantes saudáveis serviram como sujeitos do experimento. Foram selecionados para cada participante duas de três classes de imagética motora: mão esquerda, mão direita e pé (com o lado escolhido pelo indivíduo, ou os dois pés opcionalmente).

A gravação foi feita usando amplificadores *BrainAmp MR plus* (Brain Products HmmbH, Munique, Alemanha) e uma touca de eletrodos Ag/AgCl (EASYCAP GmbH). Sinais de 59 posições do EEG mais densamente distribuídos sobre a área sensório-motora foram medidos, filtrados com um passa-banda entre 0.05 e 200 Hz e então digitalizados a 1000 Hz com 16 bits ( $0.1 \mu\text{V}$ ) de acurácia (Tangermann et al., 2012).

A gravação foi dividida em uma sessão para a gravação dos dados de treino e outra para os dados de teste.

Os dados de treinamento foram gravados nas primeiras duas séries, setas apontando para a esquerda, direita ou para baixo foram apresentadas como sinais visuais em uma tela de computador. Os sinais foram exibidos por um período de 4 segundos durante o qual o sujeito foi instruído a executar a imagética motora sinalizada. Esses períodos foram intercalados com 2 segundos com a tela branca e 2 segundos com uma cruz de fixação sendo mostrada no centro da tela, que era sobreposta pelos sinais a seguir. Em cada série 50 testes de cada classe escolhida foram apresentados, totalizando 200 testes. A cada 15 testes eram feitas pausas de 15 segundos e uma pausa de 5 a 15 minutos foi feita entre as séries (Tangermann et al., 2012).

Em seguida foram feitas quatro séries de gravações para os dados de teste. Nessas séries o sinal para o início da imagética motora foi um estímulo acústico - as palavras esquerda (*left*), direita (*right*) e pé (*foot*) e o sinal para o fim da imagética motora foi a palavra pare (*stop*), com períodos variando em duração de 1,5 a 8 segundos. Períodos de tempo de 1,5 a 8 segundos entre os teste sem estímulos também foram dados, correspondendo ao estado de repouso (Tangermann et al., 2012). Os anúncios acústicos foram ditos com voz suave para evitar a contaminação do sinal sensório-motor com a invocação de estímulos acústicos.

Em cada série, 30 testes para cada classe foram gravados, resultando num total de 240 testes. Após cada 30 testes foram feitas pausas de 15 segundos para relaxamento, e pausas de 5 a 15 minutos entre as séries. O número de testes para cada condição não é necessariamente igual e devido ao projeto do experimento, há duas vezes mais períodos sem controle, de repouso, do que períodos de cada classe (Tangermann et al., 2012).

O efeito mais estável da imagética motora é uma modulação dos ritmos sensório-motores. Para as mãos, uma atenuação na amplitude dos ritmos sobre a área motora contralateral é esperada. O efeito da imagética dos pés é mais diverso e pode incluir, raramente, uma atenuação na área do córtex do pé ou um aumento da amplitude sobre as áreas da mão (Tangermann et al., 2012).

Houve 24 submissões para a competição usando esse conjunto de dados. O algoritmo vencedor foi o de Zhang et al. (2012), que usou o algoritmo CSP e um critério baseado em informação

mútua para selecionar características e uma rede neural RBF para classificá-las, obtendo erro médio quadrático de 0,382. O segundo colocado na competição utilizou CSP e SVM com erro médio quadrático de 0,383, enquanto um classificador que retorne sempre o estado de repouso teria um erro de em média 0,5 (Tangermann et al., 2012).

### 5.4.2 Conjunto de Dados IVb da BCI Competition III

O segundo conjunto de dados é o conjunto *IVb* da *BCI Competition III*. Esse conjunto de dados foi fornecido para a competição por *Franhofer FIRST, Intelligent Data Analysis Group e Charité University Medicine Berlin* (Blankertz et al., 2006).

O conjunto de dados foi gravado em um indivíduo saudável, sentado em uma cadeira confortável. Para a gravação foram utilizados amplificadores *BrainAmph* e uma capa de eletrodos de *Ag/AgCl* com 128 canais posicionados de acordo com o sistema 10/20. Sinais foram filtrados com um filtro passa-banda entre 0,05 e 200 Hz, amostrados a 1000 Hz e sub-amostrados para 100 Hz.

Foram realizadas sete sessões de gravação. As primeiras três sessões do conjunto de dados são dedicadas ao treino e os dados foram disponibilizados com os rótulos das classes para a competição. As quatro sessões restantes não continham rótulo algum e deveriam ser utilizadas para testes.

A gravação foi feita apresentando dicas visuais com duração de 3,5 segundos para o indivíduo que indicam uma de três classes de imagética motora: mão esquerda, pé direito e língua. A apresentação das dicas visuais foram intercaladas com períodos aleatórios de 1,75 até 2,25 segundos nos quais o indivíduo deveria relaxar. Nas sessões dedicadas para teste, não houve imagética da língua e o período de apresentação das dicas variou em duração de 1,5 até 8 segundos.

A avaliação planejada para o conjunto de dados consiste em prover como saída um número real entre -1 e 1 para cada ponto no tempo do sinal de teste, onde -1 corresponde à classe de imagética da mão esquerda, 1 à imagética do pé e 0 ao período de repouso.

### 5.4.3 Conjunto de Dados IVa da BCI Competition III

O conjunto de dados *IVa* possui a mesma origem do conjunto *IVb*. O objetivo desse conjunto é explorar a tarefa de classificação utilizando conjuntos pequenos de dados. A motivação para isso é que técnicas que necessitam de menor número de dados para treinamento também diminuem consideravelmente o tempo de calibração de um sistema BCI, melhorando a usabilidade do mesmo.

Dados de 5 indivíduos (*aa, al, av, aw, ay*) foram gravados, com 280 exemplos de imagética motora coletados para cada indivíduo. Destes, 140 pertencem à classe de imagética motora da mão direita e 140 à classe de imagética motora dos pés. A distribuição dos conjuntos entre teste e treinamento determinada pela competição é exibida na tabela 5.5.

**Tabela 5.5:** Distribuição dos dados de treino e teste no conjunto de dados IVa.

	<b>treino</b>	<b>teste</b>
<i>aa</i>	168	112
<i>al</i>	224	56
<i>av</i>	84	196
<i>aw</i>	56	224
<i>ay</i>	28	252

## 5.5 Pré-processamento

Uma fase de pré-processamento é aplicada ao sinal do EEG antes da classificação. O objetivo dessa fase é selecionar apenas as características do sinal mais significativas para a tarefa, reduzindo a dimensionalidade dos dados no processo para permitir que a classificação ocorra mais rapidamente e diminuindo os ruídos causados pelos artefatos do sinal. A técnica utilizada para isso é o algoritmo de padrão espacial comum (*common spatial pattern*, CSP), descrito na seção 5.5.1. O algoritmos dos padrões espaciais comuns com banco de filtros (*filter bank common spatial pattern*, FBCSP) descrito na seção 5.5.2, facilita a seleção de parâmetros para o CSP.

O FBCSP tem se mostrado muito efetivo na classificação de imagética motora em alguns trabalhos recentes (Ang et al., 2012; Tangermann et al., 2012). O CSP é um dos algoritmos mais usados e com os melhores resultados para o pré-processamento de imagética motora e conquistou as primeiras posições em várias modalidades da última *BCI Competition* (Tangermann et al., 2012).

### 5.5.1 Algoritmo dos Padrões Espaciais Comuns

O CSP é um método de filtragem espacial proposto em 1990 por Koles et al. (1990) especificamente para o uso em EEG. O sinal do EEG tem uma resolução espacial pobre devido à característica de condução de potencial no cérebro. Essa característica é especialmente problemática quando o sinal de interesse é fraco, como o ritmo  $\mu$  usado para detectar imagética motora, que possui a mesma frequência do ritmo  $\alpha$  que ocorre no córtex visual.

O CSP analisa séries temporais multivariadas baseadas em gravações de duas classes diferentes. O resultado da análise do CSP é uma matriz  $W \in \mathbb{R}^{C \times C}$ , onde  $C$  é o número de canais dos dados, que pode ser usada para projetar o sinal  $x(t) \in \mathbb{R}^C$  do espaço original para o espaço alternativo do CSP (Blankertz et al., 2008):

$$x_{CSP}(t) = W^T x(t) \quad (5.3)$$

onde cada coluna  $w_j \in \mathbb{R}^C$ ,  $j = 1, \dots, C$  é um filtro espacial.

Os filtros criados pelo CSP maximizam a variância do sinal espacialmente filtrado para uma classe enquanto a minimizam para a outra. O CSP é usado em sinais filtrados com passa-banda de forma a obter uma discriminação efetiva entre as imagéticas motoras caracterizadas pelos ERD e

ERS. Como o CSP é um algoritmo sensível a ruídos, uma seleção manual ou automática dos filtros passa-banda adequada é crucial para que se obtenha um bom resultado final.

O primeiro passo para a criação dos filtros espaciais é calcular a covariância  $R^+$  e  $R^-$  das duas populações ou classes  $+$  e  $-$ , respectivamente. Para cada época  $X \in \mathbb{R}^{C \times M}$ , onde  $C$  é o número de canais e  $M$  é o tamanho em amostras da época, é calculada uma estimativa da covariância espacial (Koles et al., 1990):

$$R = \frac{XX^T}{\text{traço}(XX^T)} \quad (5.4)$$

onde  $R \in \mathbb{R}^{C \times C}$  é a matriz de covariância para uma época.

A matriz de covariância da população  $R_p$ ,  $p = \{+, -\}$  é então computada:

$$R^p = \frac{1}{N^p} \sum_{i=1}^{N^p} R_i \quad (5.5)$$

onde  $N^p$  é o número de épocas na população  $p$ .

A análise do CSP é então feita através de diagonalização simultânea das duas matrizes de covariância

$$W^T R^+ W = \Lambda^+ \quad (5.6)$$

$$W^T R^- W = \Lambda^-$$

onde a escala de  $W \in \mathbb{R}^{C \times C}$  é limitada por  $\Lambda^+ + \Lambda^- = I$ .

Essa diagonalização pode ser obtida resolvendo o problema do autovalor generalizado (Blankertz et al., 2008)

$$R^+ w = \lambda R^- w \quad (5.7)$$

em que os autovetores  $w_j$ ,  $j = (1, \dots, C)$  constituem as colunas de  $W$  sendo, portanto, filtros espaciais, e  $\lambda_j^p = w_j^T R^p w_j$  os elementos diagonais de  $\Lambda^p$ ,  $p = \{+, -\}$ .

Note que  $\lambda_j^p \geq 0$  é a variância da população  $p$  no canal substituto no espaço do CSP e que  $\lambda_j^+ + \lambda_j^- = 1$ . Dessa forma, um valor maior de  $\lambda_j^+$ , próximo a 1, indica que o filtro espacial correspondente  $w_j$  resulta em alta variância para a população ou classe  $+$  e baixa variância para a população  $-$ . A matriz  $W$  é organizada de forma que as primeiras colunas contêm os filtros que maximizam a variância para  $R^+$  em ordem decrescente e  $R^-$  em ordem ascendente, criando pares de filtros  $(w_1, w_n), (w_2, w_{n-1}), \dots, (w_{n/2}, w_{n/2+1})$ . Esse contraste de variância é útil para a discriminação entre classes (Blankertz et al., 2008).

Os filtros espaciais gerados pelo CSP podem então ser usados para projetar o sinal do EEG num novo espaço filtrado

$$x_{CSP}(t) = W^T x(t). \quad (5.8)$$

É possível reduzir o número  $C$  de variáveis observadas da série multivariada selecionando apenas os  $k$  pares dos  $w_j$  filtros espaciais criados pelo CSP com os maiores e menores valores de  $\lambda_j^+$  para compor uma matriz  $W \in \mathbb{R}^{C \times k}$  e, dessa forma, reduzir a dimensão de  $x$  para  $x_{CSP} \in \mathbb{R}^{2k \times M}$ .

Ainda utilizando os filtros criados pelo CSP é possível extrair um vetor de valores  $z \in \mathbb{R}^{2k}$  que represente as características da série filtrada. Isso pode ser feito utilizando a energia do sinal filtrado de uma época (Zhang et al., 2012)

$$z = \int_1^M x_{CSP}(t) dt \tag{5.9}$$

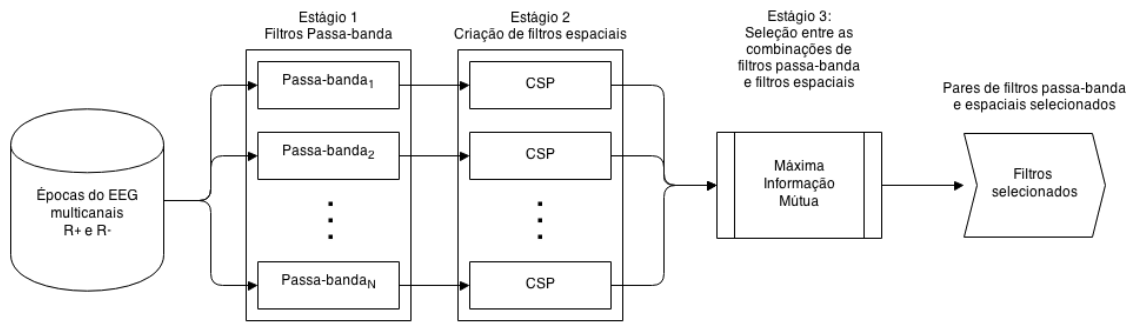
ou utilizando uma abordagem como a de Ang et al. (2012), utilizada neste trabalho:

$$z = \log \frac{\text{diag}(W^T x x^T W)}{\text{traço}(W^T x x^T W)}. \tag{5.10}$$

### 5.5.2 Padrão Espacial Comum com Banco de Filtros

Um dos problemas do CSP é a sensibilidade do algoritmo à seleção de um filtro passa-banda que isole corretamente a banda de frequência de interesse, e uma filtragem errada pode comprometer seriamente o desempenho final. O FBCSP é um algoritmo que se encarrega de realizar essa seleção de filtros automaticamente, tendo sido usado por (Zhang et al., 2012; Ang et al., 2012, 2008; Chin et al., 2009).

O algoritmo foi proposto por Ang et al. (2008) e possui três estágios para criação dos filtros. A Figura 5.3 ilustra o fluxo do algoritmo.



**Figura 5.3:** Algoritmo FBCSP. O algoritmo seleciona pares de filtros passa-banda e espaciais criados com o CSP seguindo o critério de máxima informação mútua.

O primeiro estágio consiste em uma série de tamanho  $N_{BP}$  filtros passa-banda com frequências distintas. Todas as épocas de cada população são filtradas e, em seguida, apresentadas ao algoritmo CSP para a geração de  $N_{CSP}$  filtros espaciais. Os filtros gerados pelo CSP são em seguida utilizados para extrair uma característica de cada época usando a equação 5.9 ou 5.10, por exemplo. Ao todo, são geradas  $N_{BP} \times N_{CSP}$  características no processo.

A seleção entre os filtros então é feita seguindo um critério de máxima informação mútua. Para cada vetor  $Z \in \mathbb{R}^{N_{\text{epocas}}}$  contendo as características processadas das épocas de ambas as populações para um determinado par de filtros passa-banda e espacial, e um vetor  $L \in \mathbb{Z}^{N_{\text{epocas}}}$  com valores de 1 até  $M_l$  contendo o rótulo de cada época, é calculada a informação mútua (Zhang et al., 2012)

$$I(Z, L) = H(Z) - H(Z|L) \quad (5.11)$$

onde

$$H(Z) = - \sum_{z \in Z} p(z) \log(p(z)) \quad (5.12)$$

e a entropia condicional  $H(Z|L)$  é

$$H(Z|L) = - \sum_{l=1}^{M_l} \int_z p(z, l) \log(p(a|z)) da \quad (5.13)$$

$$= - \sum_{l=1}^{M_l} M_l H(Z|l) P(l). \quad (5.14)$$

A informação mútua mede o quanto duas variáveis são mutuamente dependentes. Do ponto de vista da teoria da informação, a melhor característica é a que carrega a maior informação mútua sobre o rótulo  $L$  da classe. Dessa forma, são selecionados os  $k$  filtros correspondentes aos vetores  $Z$  que maximizem a informação mútua

$$\max_Z I(Z|L). \quad (5.15)$$

Como os filtros espaciais são organizados em pares em que cada um maximiza a variância para uma classe, quando um filtro espacial é selecionado sua contraparte também é incluída.


Os filtros selecionados são então aplicados às épocas do EEG, com as características extraídas de cada filtro agrupadas na forma de um vetor de características para cada época.

## 5.6 Classificação

O CSP é um algoritmo que permite a criação de filtros espaciais que maximizam o contraste entre duas populações ou classes diferentes. Há casos, porém, como os dos conjuntos de dados IVb da *BCI Competition III* e I da *BCI Competition IV*, em que a distinção deve ser feita entre três populações distintas (mão, pé e classe de repouso por exemplo). A maneira escolhida para contornar esta limitação é o pré-processamento em pares.

Dadas três diferentes populações  $X$ ,  $Y$  e  $Z$ , a etapa de pré-processamento é feita criando filtros individualmente para cada par de populações  $XY$ ,  $XZ$  e  $YZ$ . Em seguida os filtros criados para cada par são aplicados a todas as épocas de todas as populações e os vetores de características gerados são agrupados em um único vetor  $x_{teste}$  que é usado na etapa de classificação.

A preparação dos conjuntos de dados para o teste com sinal contínuo se inicia com a criação das épocas de cada classe, extraídas do subconjunto de teste e usadas para a criação dos filtros. Os subconjuntos de dados de treinamento são apresentados na forma de séries temporais multivariadas com duração de vários minutos. São providos índices contendo os instantes de apresentação da dica visual para realização da imagética e o tipo de imagética. A Figura 5.4 ilustra parte de uma das séries disponíveis.



**Figura 5.4:** Série temporal correspondente ao canal C4 do EEG, extraída do subconjunto de teste do indivíduo *a* do conjunto de dados I da *BCI Competition IV*.

As épocas são extraídas a partir da marcação da imagética motora no sinal. Conforme foi mencionado, a marcação indica o início da apresentação de uma dica visual com duração de 4 segundos durante o qual o indivíduo deve realizar a imagética. Uma janela de tempo é selecionada nesse período, que é extraída como uma época correspondendo a uma das populações. O limite superior da janela foi definido como 4 segundos e o limite inferior para a época foi determinado experimentalmente como de 1,5 segundos após a apresentação da dica.

O início da janela da tempo para a época com atraso é justificado pelo atraso cognitivo de cerca de 500 ms que existe para o cérebro tomar consciência da dica observada e de outros processos envolvidos na preparação do indivíduo para a imagética. Também foram realizados testes com os intervalos de janela de tempo com início entre 0,5, 1 e 2 segundos após a dica e limite superior entre 3 e 4 segundos, mas que resultarem em desempenho pior na classificação.

Foram usados sete filtros fase-zero Chebyshev Tipo II com ordem 4 no FBCSP, com os centros de frequência em 8, 9.75, 11.89, 14.49, 17.67, 21.53 e 26.25 e fator de qualidade *Q* de 1.33. O CSP foi configurado para retornar os dois pares de filtros espaciais mais relevantes em cada análise.

Esse processo resulta em 14 pares de combinações de filtros para cada par de populações, dos quais 2 pares são escolhidos seguindo o critério de máxima informação mútua.

O pré-processamento para um par de populações resulta, então, em um vetor de características de tamanho 4. O procedimento é repetido para os outros pares de populações e os vetores de características são concatenados resultando num vetor de 12 características para cada época do EEG.

As épocas extraídas para a criação dos filtros são usadas para o treinamento do conjunto-K e classificadores.

A extração de épocas para o conjunto de testes  $x_{teste}^k$  segue outra metodologia. Como não há indicações no sinal do início e fim das dicas apresentadas aos indivíduos o sistema deve apresentar uma saída para cada instante do EEG capturado, distinguindo corretamente entre os dois tipos

de imagética motora e o período de repouso durante toda a duração do sinal. As épocas são criadas com a mesma duração das extraídas para treino (2,5 segundos), com a janela de sinal usada sendo deslocada 0,5 segundo por vez. Isso implica em duas épocas criadas e, posteriormente, classificadas, por segundo.

### 5.6.1 Filtragem dos dados com o conjunto-KIII

Os conjuntos-K são utilizados como um filtro no sentido em que transformam os exemplos apresentados para a rede em um espaço formado por padrões de oscilação que, em teoria, devem permitir uma melhor separação dos dados. O conjunto-K foi configurado com os parâmetros apresentados na seção 5.2, com tamanho 12 nas camadas OB, AON e PC, mesmo tamanho da entrada apresentada à rede.

O treinamento dos conjuntos-K é feito utilizando o conjunto de dados  $x_{treino}$ . Um subconjunto  $x_{validacao}$  é extraído do conjunto  $x_{treino}$  e usado para validar o treinamento que segue de acordo com o algoritmo 1. No algoritmo apresentado, o procedimento `CriarKIII` corresponde à criação e inicialização para o estado basal da rede neural conjunto-KIII. `ExecutarKIII(X)` consiste em, dado um exemplo ou um vetor de exemplos X, executar um período ativo e um período de repouso para cada exemplo, retorno a ativação da rede no período ativo para cada exemplo em X apresentado. `TreinarKIII(KIII, exemplos)` executa o treinamento do conjunto-KIII KIII utilizando os exemplos apresentados e retornando como resultado da chamada da função a rede neural treinada por uma época com os exemplos.

`CriarClassificador` cria e inicializa um algoritmo classificador determinado, como o algoritmo KNN ou LDA, por exemplo. O algoritmo criado é utilizado na função `Classificar` para classificar os dados de entrada passados. O erro de classificação é calculado então por uma função `CalcularErro`.

O conjunto-KIII treinado é usado para processar os dados de treinamento  $x_{treino}$  e teste  $x_{teste}$ , resultando nos conjunto de dados processados  $x_{treino}^k$  e  $x_{teste}^k$ .

### 5.6.2 Classificadores

Seis classificadores são usados para prover a saída do sistema a partir dos dados processados com os conjuntos-K,  $x_{treino}^k$  e  $x_{teste}^k$ . Para comparar os resultados, os mesmos classificadores são utilizados com os dados sem os conjuntos-K,  $x_{treino}$  e  $x_{teste}$ .

Os classificadores utilizados são os  $k$ -vizinhos mais próximos ( $k$ -Nearest Neighbors, KNN), a *general regression neural network* (GRNN), a *time delay neural network* (TDNN), a máquina de vetor de suporte (*support vector machine*, SVM) e o modelo oculto de Markov (*hidden markov model*, HMM).



**Algoritmo 1:** Treinamento do conjunto-KIII.

**Saída:**  $k_{\text{erro minimo}}$  contendo o conjunto-KIII que resulta em menor erro para os dados de validação.

$k \leftarrow \text{CriarKIII}(\text{tamanho});$

$x_{\text{treino}}^k \leftarrow \text{ExecutarKIII}(x_{\text{treino}});$

$x_{\text{validacao}}^k \leftarrow \text{ExecutarKIII}(x_{\text{validacao}});$

$\text{classificador} \leftarrow \text{CriarClassificador}(x_{\text{treino}}^k, \text{rótulos}_{\text{treino}});$

$\text{rótulos}_{\text{predito}} \leftarrow \text{Classificar}(\text{classificador}, x_{\text{validacao}}^k);$

$\text{erro}_{\text{minimo}} \leftarrow \text{CalcularErro}(\text{rótulos}_{\text{predito}}, \text{rótulos}_{\text{validacao}});$

$k_{\text{erro minimo}} \leftarrow k;$

$n_{\text{sem melhora}} \leftarrow 0;$

**enquanto**  $n_{\text{sem melhora}} < \text{limite máximo de iterações sem diminuição do erro}$  **faça**

$k \leftarrow \text{TreinarKIII}(k, x_{\text{treino}});$

$x_{\text{treino}}^k \leftarrow \text{ExecutarKIII}(x_{\text{treino}});$

$x_{\text{validacao}}^k \leftarrow \text{ExecutarKIII}(x_{\text{validacao}});$

$\text{classificador} \leftarrow \text{CriarClassificador}(x_{\text{treino}}^k, \text{rótulos}_{\text{treino}});$

$\text{rótulos}_{\text{predito}} \leftarrow \text{Classificar}(\text{classificador}, x_{\text{validacao}}^k);$

$\text{erro} \leftarrow \text{CalcularErro}(\text{rótulos}_{\text{predito}}, \text{rótulos}_{\text{validacao}});$

**se**  $\text{erro} < \text{erro}_{\text{minimo}}$  **então**

$\text{erro}_{\text{minimo}} \leftarrow \text{erro};$

$k_{\text{erro minimo}} \leftarrow k;$

$n_{\text{sem melhora}} \leftarrow 0;$

**senão**

$n_{\text{sem melhora}} \leftarrow n_{\text{sem melhora}} + 1;$

**fim**

**fim**

**K-Vizinhos Mais Próximos (KNN)**

O KNN é um algoritmo simples e é a escolha padrão de classificador para os conjuntos-K. O KNN armazena os exemplos apresentados e, a cada vez que uma nova consulta é feita apresentando um exemplo de teste, o relacionamento entre o teste e os exemplos armazenados é examinado para determinar o rótulo do teste (Mitchell, 1997).

O KNN assume que todos os exemplos correspondem a pontos num espaço  $n$ -dimensional  $\mathbb{R}^n$  e os vizinhos de um exemplo são definidos em termos da distância euclidiana. Dessa forma um exemplo qualquer  $x$  pode ser descrito por um vetor de características  $(a_1(x), a_2(x), \dots, a_n(x))$ , onde  $a_r(x)$  denota o valor do  $r$ -ésimo atributo do exemplo  $x$ , então a distância entre dois exemplos  $x_i$  e  $x_j$  é definida como

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (5.16)$$

O algoritmo então consiste em, dado um exemplo  $x_q$  para ser classificado, calcular a distância entre  $x_q$  e cada exemplo  $x_1, \dots, x_m$ , selecionar destes exemplos os  $k$  com menor distância do

exemplo de consulta e retornar como resultado o rótulo da maioria desses  $k$  exemplos de treino (Mitchell, 1997).

### General Regressive Neural Network (GRNN)

As redes neurais GRNN e TDNN foram utilizadas em conjunto com um pré-processamento similar no trabalho vencedor da *BCI Competition* para o conjunto de dados I de Zhang et al. (2012).

A GRNN foi introduzida por Specht (1991), e é utilizada para estimar variáveis contínuas. A GRNN é similar às redes de função de base radial, com a principal diferença encontrada na camada de saída de rede.

A GRNN funciona da seguinte forma. A tarefa de regressão consiste em, dada uma variável dependente  $Y$  e uma independente  $X$ , computar o valor mais provável de  $Y$  para cada valor de  $X$  baseado em um número finito de medições de  $X$  conhecidas e associadas a valores de  $Y$ .  $X$  e  $Y$  são normalmente vetores e assume-se que  $Y$  é uma função de  $X$ . A GRNN aproxima o mapeamento feito por essa função expressando-o na forma de funções densidade.

A função densidade condicional de  $X$  e  $Y$  são aproximadas a partir dos dados de treino. A computação de uma saída  $\hat{Y}$  dado uma nova entrada  $\mathbf{X}$  é dada por

$$\hat{Y}(\mathbf{X}) = \frac{\sum_{i=1}^n Y_i e\left(-\frac{D(\mathbf{X}, X_i)^2}{2\sigma^2}\right)}{\sum_{i=1}^n e\left(-\frac{D(\mathbf{X}, X_i)}{2\sigma^2}\right)} \quad (5.17)$$

onde a função  $D$  define a distância entre dois exemplos

$$D(\mathbf{X}, X_i) = (\mathbf{X} - X_i)^T (\mathbf{X} - X_i), \quad (5.18)$$

$n$  é a quantidade de exemplos de treino e  $\sigma$  é chamado por (Specht, 1991) de parâmetro de suavização. Nos testes realizados neste trabalho, definiu-se o valor de  $\sigma$  como o desvio padrão dos exemplos de treinamento

$$\sigma = \text{std}(x_{\text{treino}}). \quad (5.19)$$

### Time-Delay Neural Network (TDNN)

A TDNN foi introduzida por (Waibel et al., 1989) e aplicada inicialmente para o reconhecimento de fonemas. Todas as conexões da TDNN são, de modo similar a rede perceptron multicamadas (MLP), do tipo *feedforward*. A principal diferença entre a TDNN e a MLP é que as entradas de qualquer neurônio  $i$  podem ser compostas da saída de neurônios não apenas no instante de tempo  $t$ , mas durante qualquer número  $d$  de instantes de tempo ( $t - 1, t - 2, \dots, t - d$ ) (Clouse et al., 1997).

A função de ativação para qualquer neurônio  $i$  num instante  $t$  na rede dá-se por:

$$y^t = h \left( \sum_{j=1}^{i-1} \sum_{k=0}^d y_j^{t-k} w_{ijk} \right) \quad (5.20)$$

onde  $y_i^t$  é a saída do neurônio  $i$  no instante  $t$ ,  $w_{ijk}$  é o peso da conexão entre os neurônios  $i$  e  $j$  no instante  $t - k$  e  $h$  é a função de ativação. O treinamento da rede TDNN é feito através do mesmo algoritmo de retro propagação de erro utilizado em MLP, com as derivadas dos erros sendo calculadas individualmente para cada  $w_{ijk}$ .

A TDNN foi configurada nos testes para utilizar exemplos dos últimos 4 segundos de EEG coletado.

### Máquina de Vetor de Suporte (SVM)

As SVMs começaram a ser estudadas em 1979, quando foram apresentadas por Vladimir Naumovich Vapnik (Burges, 1998). Uma SVM busca selecionar o hiperplano que maximiza as distâncias entre os exemplos no espaço euclidiano. Esse hiperplano pode ser linear ou não-linear usando uma função gaussiana como *kernel* como, por exemplo,

$$K(x_i, x_j) = \exp \left( \frac{-\|x_i - x_j\|^2}{2\sigma^2} \right). \quad (5.21)$$

onde  $\sigma$  é um fator de suavização e que é a função *kernel* utilizada com a SVM neste trabalho.

O treinamento da SVM consiste em, a partir dos exemplos de treinamento, determinar o hiperplano ótimo encontrando os multiplicadores de Lagrange  $\alpha_i$  que maximizem a função objetivo

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(x_i, x_j) \quad (5.22)$$

com as limitações de que  $\sum_{i=1}^N \alpha_i d_i = 0$  e  $0 \leq \alpha_i \leq C$  onde  $i = 1, 2, \dots, N$  e  $C$  é uma constante escalar definida pelo usuário (Haykin, 1999).

### Modelo Oculto de Markov (HMM)

O modelo oculto de Markov (HMM) é um processo estocástico duplo, onde um processo estocástico é oculto mas pode ser observado indiretamente através de outro conjunto de processos estocásticos que produzem uma série de observações (Rabiner e Juang, 1986).

Um HMM possui um número finito  $N$  de estados  $Q = \{q_1, q_2, \dots, q_N\}$  e, a cada instante de tempo  $T$ , ocorre uma transição de estado baseada em uma distribuição de probabilidade de transição  $A = \{a_{ij}\}$ ,  $a_{ij} = \Pr(q_j \text{ em } t + 1 | q_i \text{ em } t)$  que é dependente do estado anterior. A distribuição inicial dos estados é dada por  $\pi = \{\pi_i\}$ ,  $\pi_i = \Pr(q_i \text{ em } t = 1)$ .

Após cada transição, é produzida uma observação como um símbolo de saída dos  $M$  possíveis símbolos observáveis  $V = \{v_1, v_2, \dots, v_M\}$ , que depende da distribuição de probabilidade de observação do símbolo característico do estado atual  $j$  do sistema  $B = \{b_j(k)\}$ ,  $b_j(k) = \Pr(v_k t | q_j \text{ em } t)$ .

A notação compacta  $\lambda = (A, B, \pi)$  é usada pra representar o modelo. A criação do HMM consiste em, dada a sequência de observações  $O = O_1, O_2, \dots, O_T$ , e o modelo  $\lambda$ , estimar uma sequência de estados  $I = i_1, i_2, \dots, i_T$  e estimar os demais parâmetros do modelo  $\lambda$  para maximizar  $\Pr(O|\lambda)$ , onde  $\Pr(O|\lambda)$  é a probabilidade de observação da sequência no modelo. Existem vários processos para a estimação dos parâmetros do HMM, como o método Baum-Welch, por exemplo (Rabiner e Juang, 1986).

Para a tarefa de classificação, um HMM é treinado para identificar cada diferente rótulo dos exemplos. A classificação de um exemplo, onde um exemplo é um conjunto  $O$  de observações, ocorre apresentando-o para cada um dos HMMs treinados e definindo como rótulo o rótulo equivalente ao HMM que retorna o maior  $\Pr(O|\lambda)$  para o exemplo.

### 5.6.3 Avaliação

São utilizados como métricas de avaliação o erro médio quadrático, o coeficiente  $\kappa$  e a acurácia.

O erro médio quadrático (MSE) é usado para avaliar o resultado da classificação. O MSE é calculado por:

$$MSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (5.23)$$

onde  $N$  é o total de observações classificadas e  $x_i$  e  $\hat{x}_i$  são os vetores com as predições e os valores reais, respectivamente.

O coeficiente  $\kappa$  é também usado. O coeficiente  $\kappa$  é muito usado em pesquisas em BCI (Tangermann et al., 2012) por ser considerado mais apropriada que a medida de acurácia quando as classes não estão igualmente distribuídas (Schlögl et al., 2005). O coeficiente  $\kappa$  consiste em, a partir da matriz de confusão  $H$ , calcular a acurácia da classificação

$$p_0 = \frac{\sum_i H_{ii}}{N} \quad (5.24)$$

onde  $H_{ii}$  são os elementos da diagonal principal da matriz de confusão  $H$  e a chance de concordância esperada

$$p_e = \frac{\sum_i n_{oi} \times n_{io}}{N \times N} \quad (5.25)$$

onde  $N = \sum_i \sum_j H_{ij}$  é o número total de exemplos e  $n_{oi}$  e  $n_{io}$  são somas de cada coluna e linha, respectivamente. A estimativa do coeficiente  $\kappa$  então é calculada por:

$$\kappa = \frac{p_0 - p_e}{1 - p_e} \quad (5.26)$$

Para o conjunto de dados IVa a acurácia das predições é calculada. A acurácia é calculada a partir da matriz de confusão dos resultados pela equação:

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (5.27)$$

onde  $VP$  é o número de verdadeiro positivos,  $VN$  o número de verdadeiro negativo,  $FP$  o número de falso positivo e  $FN$  o número de falso negativo.

## 5.7 Resultados e Discussão

Nessa seção os resultados obtidos com os testes realizados seguindo a metodologia apresentada nas seções anteriores são apresentados e discutidos.

A tabela 5.6 exibe o erro médio quadrático para os subconjuntos de dados gravados com indivíduos reais do conjunto de dados I da *BCI Competition IV*. A tabela 5.7 exibe o coeficiente  $\kappa$  obtida para os mesmos dados. Os dados exibidos são a média e desvio padrão de testes realizados da seguinte forma. Os resultados sem os conjuntos-K são baseados em uma média de 100 testes. Os resultados obtidos com os conjuntos-K são baseados em 10 redes conjunto-KIII treinadas individualmente, para as quais os algoritmos de classificação foram executados 10 vezes para cada, totalizando também 100 testes. Os algoritmos também são comparados com relação ao resultado aleatório e ao resultado de uma saída constante zero.

É possível observar nos resultados que o uso do conjunto-KIII como um filtro adicional de pré-processamento dos dados não foi capaz de trazer ganhos na performance da classificação. De fato, nos subconjuntos  $a$ ,  $b$  e  $f$  os resultados obtidos ficaram aquém dos obtidos sem a filtragem com a rede neural.

Observa-se também que a TDNN é, das técnicas comparadas, a que obtém melhor resultado.

O mesmo resultado é observado nas tabelas 5.8 e 5.9 para os dados gerados artificialmente da *BCI Competition IV*, onde em média o uso do conjunto-KIII causou uma pequena piora no desempenho.

Os resultados obtidos para o conjunto de dados IVb da *BCI Competition III* e exibidos na tabela 5.10 são também consistentes com a observação de que o conjunto-KIII não ofereceu nenhuma melhoria de desempenho.

Os exemplos de treinamento para o conjunto IVa são discretos. Ou seja, os exemplos de treinamento e teste desse conjunto estão discriminados e, portanto, não há na tarefa de classificação a necessidade de avaliar o sinal completo utilizando uma janela móvel e cada exemplo pode pertencer a apenas uma das duas possíveis classes. O desafio proposto para esse conjunto de dados consistia em conseguir uma boa taxa de classificação com poucos exemplos de treinamento. Nota-se pelos resultados apresentados nas tabelas 5.11 e 5.12 que, apesar de uma das vantagens atribuídas aos conjuntos-K na literatura para essa situação em específico, não houve nenhuma vantagem clara na

**Tabela 5.6:** Erro médio quadrático obtido para os indivíduos *a*, *b*, *f* e *g* e média, para o conjunto de dados *I* da *BCI Competition IV*. Resultados menores indicam melhor desempenho. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjuntos de Dados					
	<b>a</b>	<b>b</b>	<b>f</b>	<b>g</b>	<b>média</b>
GRNN	0.399	0.465	0.454	0.443	0.440
<i>k</i> GRNN	0.402 ± 0.006	0.468 ± 0.009	0.453 ± 0.004	0.440 ± 0.005	0.441
TDNN	0.352 ± 0.008	0.427 ± 0.013	0.395 ± 0.007	0.415 ± 0.013	0.397
<i>k</i> TDNN	0.358 ± 0.009	0.448 ± 0.017	0.396 ± 0.006	0.413 ± 0.011	0.404
KNN	0.659	0.656	0.608	0.924	0.712
<i>k</i> KNN	0.695 ± 0.024	0.672 ± 0.021	0.629 ± 0.029	0.900 ± 0.028	0.724
SVM	0.594	0.629	0.552	0.833	0.652
<i>k</i> SVM	0.645 ± 0.027	0.643 ± 0.021	0.563 ± 0.018	0.772 ± 0.025	0.655
HMM	0.575 ± 0.054	0.790 ± 0.065	0.534 ± 0.043	0.734 ± 0.062	0.658
<i>k</i> HMM	0.598 ± 0.066	0.793 ± 0.056	0.562 ± 0.049	0.717 ± 0.062	0.668
RANDOM	1.164	1.183	1.157	1.188	1.178
ZERO	0.500	0.518	0.490	0.522	0.507

utilização do mesmo. Os resultados exibidos são uma média da validação do algoritmo usando a metodologia de validação cruzada *k-fold*, com  $k = 10$ .

Não foi possível observar nos testes realizados melhorias de desempenho com o uso do conjunto-KIII.

Os resultados obtidos e aqui apresentados correspondem a uma seleção da totalidade dos experimentos realizados. Em nenhum caso observado o uso dos conjuntos-K foi capaz de trazer ganhos na classificação de EEG. Esses resultados são contrastantes com outros resultados obtidos com os conjuntos-K em que os conjuntos-K trazem ganhos na classificação em três diferentes conjuntos de dados.

A hipótese levantada neste trabalho de que os conjuntos-K proporcionariam resultados de classificação superiores para imagética motora provou-se falsa nas circunstâncias testadas. Um número de razões podem ser exploradas para justificar tal resultado.

Primeiro, levanta-se a hipótese de que o método de pré-processamento utilizado possa ser inadequado para o uso com os conjuntos-K. Foram realizados testes com modificações no método de pré-processamento na tentativa de averiguar a validade dessa hipótese, sem resultados positivos.

O algoritmo de análise de componentes principais (PCA) foi utilizado em substituição ao CSP para redução de dimensionalidade. A seleção manual dos canais relevantes do EEG também foi feita, selecionando os canais C3, C4 e CZ para a classificação. Além disso, foram realizados testes sem a filtragem passa-banda do sinal do EEG. Em nenhum desses casos estudados obteve-se resultados superiores com o uso do conjunto-KIII comparando-o ao resultado sem a rede neural e nas mesmas condições. Foi notado, porém, diminuição considerável na performance geral da tarefa de classificação para as alterações citadas.

**Tabela 5.7:** Medida  $kappa$  obtida para os subconjuntos  $a$ ,  $b$ ,  $f$  e  $g$  e média, para o conjunto de dados  $I$  da *BCI Competition IV*. Resultados maiores indicam melhor desempenho. O prefixo  $k$  indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjunto de Dados					
	<b>a</b>	<b>b</b>	<b>f</b>	<b>g</b>	<b>média</b>
GRNN	0.240	0.220	0.252	0.279	0.247
$k$ GRNN	$0.239 \pm 0.008$	$0.223 \pm 0.008$	$0.242 \pm 0.006$	$0.281 \pm 0.010$	0.246
TDNN	$0.292 \pm 0.015$	$0.377 \pm 0.017$	$0.308 \pm 0.009$	$0.238 \pm 0.015$	0.304
$k$ TDNN	$0.281 \pm 0.015$	$0.351 \pm 0.018$	$0.296 \pm 0.009$	$0.240 \pm 0.018$	0.292
KNN	0.238	0.298	0.248	0.187	0.242
$k$ KNN	$0.218 \pm 0.010$	$0.295 \pm 0.010$	$0.227 \pm 0.007$	$0.195 \pm 0.012$	0.234
SVM	0.227	0.231	0.246	0.226	0.232
$k$ SVM	$0.237 \pm 0.009$	$0.242 \pm 0.015$	$0.243 \pm 0.007$	$0.234 \pm 0.010$	0.239
HMM	$0.245 \pm 0.036$	$0.291 \pm 0.039$	$0.272 \pm 0.025$	$0.202 \pm 0.027$	0.253
$k$ HMM	$0.236 \pm 0.041$	$0.296 \pm 0.033$	$0.263 \pm 0.029$	$0.210 \pm 0.030$	0.251
ZERO	0	0	0	0	0

Segundo, considera-se a possibilidade da performance obtida não ser ideal por falha na parametrização do conjunto-KIII. Variações na arquitetura do conjunto-KIII foram testadas como, por exemplo, o uso de ruído periférico, número de conjuntos-KII por camada nas combinações  $N-N-N$  e  $N-I-I$ , captura da saída na camada 1 ou camada 3 e treinamento exclusivamente na camada 1, camada 3 ou nas três camadas da rede neural.

O ruído periférico foi desativado nos testes pois seu uso não afetou de forma significativa o comportamento da rede ou a média dos resultados obtidos, porém causou um aumento significativo no desvio padrão dos resultados.

A escolha da captura da saída da rede na camada 1 ou camada 3 também não mostrou afetar significativamente os resultados obtidos. Atribui-se a essa observação o fato de que todas as camadas do conjunto-KIII estão conectadas por *feedback*, de modo que alterações no comportamento e distribuição espacial de ativações em uma camada ocorrem de forma similar nas outras camadas observadas.

A variação no tamanho das camadas nos padrões  $N-N-N$ , com  $N$  conjuntos-KII por camada e  $N-I-I$  com  $N$  conjuntos-KII na camada 1 e apenas 1 conjunto nas camadas 2 e 3 afetou os resultados dos testes. Observou-se que os resultados obtidos com camadas de tamanhos iguais são mais consistentes e a rede apresenta maior estabilidade e resistência ao excesso de excitação durante a fase de treinamento.

Da mesma forma, o treinamento do conjunto-KIII foi realizado apenas na camada 1 pois, quando executado simultaneamente nas três camadas do conjunto, a rede demonstrou uma tendência maior a desestabilizar e apresentar resultados inesperados. Há também uma dificuldade maior na parametrização da rede para treinamento em múltiplas camadas, pois se faz necessário definir uma taxa de treinamento  $\alpha$  individualmente em cada camada devido às diferenças na amplitude de ativação.

**Tabela 5.8:** Erro médio quadrático obtido para os subconjuntos *c*, *d* e *e* de dados artificiais e média dos resultados, para o conjunto de dados *I* da *BCI Competition IV*. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjuntos de Dados				
	<b>c</b>	<b>d</b>	<b>e</b>	<b>média</b>
GRNN	0.534	0.453	0.334	0.440
<i>k</i> GRNN	0.524 ± 0.005	0.476 ± 0.00	0.325 ± 0.002	0.442
TDNN	0.533 ± 0.005	0.320 ± 0.029	0.141 ± 0.005	0.331
<i>k</i> TDNN	0.514 ± 0.013	0.357 ± 0.029	0.141 ± 0.006	0.337
KNN	0.541	0.900	0.418	0.620
<i>k</i> KNN	0.536 ± 0.029	0.884 ± 0.078	0.436 ± 0.066	0.619
SVM	0.542	1.227	0.379	0.716
<i>k</i> SVM	0.644 ± 0.193	1.239 ± 0.258	0.417 ± 0.018	0.767
HMM	0.701 ± 0.091	0.548 ± 0.066	0.233 ± 0.094	0.494
<i>k</i> HMM	0.617 ± 0.076	0.604 ± 0.060	0.204 ± 0.056	0.475
RANDOM	1.206	1.150	1.166	1.174
ZERO	0.539	0.488	0.499	0.509

Os testes executados com os conjuntos-K não são exaustivos. De fato, devido ao grande número de parâmetros do conjunto-KIII e a sensibilidade do mesmo a variações nesses parâmetros, testes com diferentes configurações tornam-se custosos devido a necessidade da realização de buscas globais com múltiplas variáveis, razão pela qual, devido as limitações de tempo e escopo desse trabalho, foram utilizadas configurações para o conjunto-KIII existentes na literatura. Não se descarta a possibilidade de baixa performance dos conjuntos-K devido a limitações impostas pela configuração atual, que é relativamente sensível à quantidade de treino aplicável devido a problemas que ocorrem por excesso de excitação, conforme ilustrado na figura 5.2.

## 5.8 Considerações Finais

Neste capítulo foi apresentada a metodologia proposta para a classificação dos sinais motores no EEG, incluindo as técnicas de pré-processamento, a forma de classificação dos sinais e a avaliação dos resultados, e os resultados obtidos. Observou-se que os resultados estão abaixo do esperado e que não foi possível confirmar a hipótese levantada no trabalho.



**Tabela 5.9:** Coeficiente *kappa* para os subconjuntos *c*, *d* e *e* de dados artificiais e média dos resultados, para o conjunto de dados *I* da *BCI Competition IV*. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjuntos de Dados				
	<b>c</b>	<b>d</b>	<b>e</b>	<b>média</b>
GRNN	0.011	0.326	0.402	0.246
<i>k</i> GRNN	0.022 ± 0.008	0.285 ± 0.015	0.396 ± 0.005	0.234
TDNN	0.011 ± 0.003	0.400 ± 0.035	0.723 ± 0.010	0.378
<i>k</i> TDNN	0.039 ± 0.017	0.355 ± 0.030	0.718 ± 0.012	0.370
KNN	0.007	0.192	0.378	0.192
<i>k</i> KNN	0.017 ± 0.010	0.197 ± 0.026	0.353 ± 0.007	0.189
SVM	0	-0.062	0.403	0.114
<i>k</i> SVM	0.027 ± 0.024	0.016 ± 0.037	0.369 ± 0.008	0.137
HMM	0.050 ± 0.023	0.310 ± 0.061	0.625 ± 0.207	0.328
<i>k</i> HMM	0.056 ± 0.035	0.274 ± 0.041	0.683 ± 0.012	0.338
ZERO	0	0	0	0

**Tabela 5.10:** Erro médio quadrático e medida *kappa* para os conjuntos de dados IVb da *BCI Competition III*. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjunto de Dados IVb		
	MSE	KAPPA
GRNN	0.224	0.607
<i>k</i> GRNN	0.245 ± 0.004	0.569 ± 0.012
TDNN	0.196 ± 0.007	0.657 ± 0.012
<i>k</i> TDNN	0.207 ± 0.011	0.645 ± 0.018
KNN	0.348	0.544
<i>k</i> KNN	0.357 ± 0.023	0.532 ± 0.028
SVM	0.304	0.572
<i>k</i> SVM	0.333	0.537 ± 0.033
HMM	0.274 ± 0.027	0.618 ± 0.035
<i>k</i> HMM	0.275 ± 0.051	0.615 ± 0.073
RANDOM	1.3712	-0.002
ZERO	0.699	0

**Tabela 5.11:** Medida *kappa* para o Conjunto de Dados IVa da *BCI Competition III*. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjunto de Dados IVa					
	<b>aa</b>	<b>al</b>	<b>av</b>	<b>aw</b>	<b>ay</b>
KNN	0.283	0.473	0.622	0.982	0.952
<i>k</i> KNN	0.268 ± 0.045	0.521 ± 0.022	0.550 ± 0.042	0.984 ± 0.010	0.894 ± 0.041
SVM	0.248	0.542	0.571	0.991	0.920
<i>k</i> SVM	0.243 ± 0.035	0.535 ± 0.024	0.542 ± 0.024	0.986 ± 0.007	0.889 ± 0.010
GRNN	0.248	0.542	0.540	0.991	0.873
<i>k</i> GRNN	0.281 ± 0.029	0.584 ± 0.042	0.531 ± 0.027	0.986 ± 0.006	0.880 ± 0.009

**Tabela 5.12:** Acurácia para o Conjunto de Dados IVa da *BCI Competition III*. O prefixo *k* indica que a classificação ocorreu sobre os dados filtrados com o conjunto-KIII.

Conjunto de Dados IVa					
	<b>aa</b>	<b>al</b>	<b>av</b>	<b>aw</b>	<b>ay</b>
KNN	0.660	0.732	0.811	0.991	0.976
<i>k</i> KNN	0.651 ± 0.021	0.757 ± 0.011	0.775 ± 0.021	0.992 ± 0.005	0.947 ± 0.020
SVM	0.642	0.767	0.785	0.995	0.960
<i>k</i> SVM	0.640 ± 0.016	0.764 ± 0.012	0.771 ± 0.012	0.993 ± 0.003	0.944 ± 0.005
GRNN	0.642	0.767	0.770	0.995	0.936
<i>k</i> GRNN	0.657 ± 0.013	0.789 ± 0.021	0.765 ± 0.013	0.993 ± 0.003	0.940 ± 0.004

---

# Conclusões

---

## 6.1 Contribuições e Limitações

Uma das contribuições resultantes deste trabalho é o desenvolvimento do simulador para os conjuntos-K construído durante a realização deste trabalho que permite a realização de experimentos com maior flexibilidade e em menor tempo computacional que alternativas pré-existentes. Outra possível contribuição trata-se da revisão bibliográfica desenvolvida para os conjuntos-K, que tem a intenção de servir como referência para a compreensão dos mesmos, condensando o conhecimento existente na literatura que abrange desde a motivação para a construção dos conjuntos, seu desenvolvimento inicial e derivação do modelo, até o funcionamento e aplicação do conjunto-KIII. Também se obteve como resultado deste trabalho a aplicação do conjunto-KIII na tarefa de agrupamentos de dados, com resultados satisfatórios.

Uma contribuição esperada deste trabalho, a validação da hipótese de obtenção de bons resultados a partir da aplicação dos conjuntos-K para a melhoria da classificação de imagética motora, não foi confirmada pelos resultados obtidos. Uma das limitações deste trabalho se trata da averiguação das hipóteses levantadas quanto ao porque dos resultados obtidos. Dentre essas destaca-se a dificuldade na parametrização do conjunto-KIII e análise de seu espaço de estados durante o treinamento.

Com base nas limitações, propõe-se que em trabalhos futuros seja feita a investigação do comportamento do espaço de estados do conjunto-KIII durante o treinamento, considerando a criação de um método que permita avaliar se o treinamento dado à rede relativo a um conjunto de dados é adequado ou não e, se possível, averiguar a convergência da rede neural para diferentes asas de atrator durante o estímulo. Junto a isso, é interessante averiguar a hipótese do treinamento entre

unidades inibitórias no conjunto-KIII. A possibilidade de adaptação na força das conexões inibitórias não foi considerada na época de criação dos conjuntos-K, porém, sabe-se que essas sinapses sofrem mudanças durante o aprendizado (Korn e Faure, 2003).

A continuidade dos trabalhos desenvolvidos por Chang e Freeman (1996); Chang et al. (1998b); Beliaev et al. (2005) na busca por parâmetros que satisfaçam as condições desejadas para o conjunto-KIII também se torna interessante. Um método automático de busca por parâmetros e a simplificação do conjunto-KIII, com uma redução no número de parâmetros livres, pode aumentar as possibilidades da realização de otimizações de desempenho da rede e facilitar o estudo de seu comportamento.

## 6.2 Considerações Finais

Esta dissertação apresentou a aplicação dos conjuntos-K na tarefa de classificação de imagética motora. A aplicação dos conjuntos-K na tarefa de classificação de imagética foi desenvolvida. Foi dada ênfase no estudo e utilização da rede neural durante o projeto e um simulador para os conjuntos-K foi construído. Não foi possível validar a hipótese levantada no trabalho de que os conjuntos-K resultariam em ganho de performance na aplicação proposta, com os resultados obtidos não indicando diferença de performance significativa com o uso da rede neural.

# Referências

---

---

- ALLIGOOD, K. T.; SAUER, T. D.; YORKE, J. A. Chaos: An introduction to dynamical systems. 1997.
- 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, 2012.
- ANG, K. K.; CHIN, Z. Y.; ZHANG, H.; GUAN, C. Filter bank common spatial pattern (fbcs) in brain-computer interface. In: *Neural Networks, 2008. IEEE International Joint Conference on*, IEEE, 2008, p. 2390–2397.
- BABILONI, F.; CINCOTTI, F.; BIANCHI, L.; PIRRI, G.; R MILLÁN, J.; MOURIÑO, J.; SALINARI, S.; GRAZIA MARCIANI, M. Recognition of imagined hand movements with low resolution surface laplacian and linear classifiers. *Medical engineering & physics*, v. 23, n. 5, p. 323–328, 2001.
- BASHASHATI, A.; FATOURECHI, M.; WARD, R. K.; BIRCH, G. E. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *Journal of Neural Engineering*, v. 4, n. 2, p. R32–anR57, 2007.
- BASU, S.; MICCHELLI, C. A.; OLSEN, P. Maximum entropy and maximum likelihood criteria for feature selection from multivariate data. In: *Circuits and Systems, 2000. Proceedings. ISCAS 2000 Geneva. The 2000 IEEE International Symposium on*, IEEE, 2000, p. 267–270.
- BELIAEV, I.; ILIN, R.; KOZMA, R. Nonlinear neurodynamics tool for system analysis and application for time series prediction. In: *Systems, Man and Cybernetics, 2005 IEEE International Conference on*, IEEE, 2005, p. 1011–1016.
- BERG, P.; SCHERG, M. A multiple source approach to the correction of eye artifacts. *Electroencephalography and clinical Neurophysiology*, v. 90, n. 3, p. 229–241, 1994.

- BLANKERTZ, B.; MULLER, K.-R.; KRUSIENSKI, D. J.; SCHALK, G.; WOLPAW, J. R.; SCHLOGL, A.; PFURTSCHELLER, G.; MILLAN, J. R.; SCHRODER, M.; BIRBAUMER, N. The bci competition iii: Validating alternative approaches to actual bci problems. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, v. 14, n. 2, p. 153–159, 2006.
- BLANKERTZ, B.; TOMIOKA, R.; LEMM, S.; KAWANABE, M.; MULLER, K.-R. Optimizing spatial filters for robust eeg single-trial analysis. *Signal Processing Magazine, IEEE*, v. 25, n. 1, p. 41–56, 2008.
- BLUM, A. L.; LANGLEY, P. Selection of relevant features and examples in machine learning. *Artificial Intelligence*, v. 97, n. 1 - 2, p. 245 – 271, 1997.
- BRAGA, A.; CARVALHO, A.; LUDERMIR, T. *Redes Neurais Artificiais: Teoria e Aplicações*. 2 ed. LTC, 2007.
- BROCK, G.; PIHUR, V.; DATTA, S.; DATTA, S. clvalid, an r package for cluster validation. *Journal of Statistical Software (Brock et al., March 2008)*, 2011.
- BROWNE, M.; CUTMORE, T. Low-probability event-detection and separation via statistical wavelet thresholding: an application to psychophysiological denoising. *Clinical Neurophysiology*, v. 113, n. 9, p. 1403–1411, 2002.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, v. 2, n. 2, p. 121–167, 1998.
- BUZSAKI, G.; ANASTASSIOU, C. A.; KOCH, C. The origin of extracellular fields and currents – eeg, ecog, lfp and spikes. *Nature Reviews Neuroscience*, v. 13, n. 6, p. 407–420, 2012.
- CARLOS, L. F. M.; ROSA, J. L. G. Face recognition through a chaotic neural network model. In: *Neural Networks (IJCNN), 2014 International Joint Conference on*, IEEE, 2014, p. 859–863.
- CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps. *Neural Networks, IEEE Transactions on*, v. 3, n. 5, p. 698–713, 1992.
- CASTELLARO, C.; FAVARO, G.; CASTELLARO, A.; CASAGRANDE, A.; CASTELLARO, S.; PUTHENPARAMPIL, D.; SALIMBENI, C. F. An artificial intelligence approach to classify and analyse eeg traces. *Neurophysiologie Clinique/Clinical Neurophysiology*, v. 32, n. 3, p. 193 – 214, 2002.
- CHANG, H.-J.; FREEMAN, W. J. Parameter optimization in models of the olfactory neural system. *Neural Networks*, v. 9, n. 1, p. 1 – 14, 1996.

- CHANG, H.-J.; FREEMAN, W. J.; BURKE, B. C. Biologically modeled noise stabilizing neurodynamics for pattern recognition. *International Journal of Bifurcation and Chaos*, v. 08, n. 02, p. 321–345, 1998a.
- CHANG, H.-J.; FREEMAN, W. J.; BURKE, B. C. Optimization of olfactory model in software to give 1/f power spectra reveals numerical instabilities in solutions governed by aperiodic (chaotic) attractors. *Neural Networks*, v. 11, n. 3, p. 449 – 466, 1998b.
- CHIN, Z. Y.; ANG, K. K.; WANG, C.; GUAN, C.; ZHANG, H. Multi-class filter bank common spatial pattern for four-class motor imagery bci. In: *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE, IEEE, 2009*, p. 571–574.
- CLOUSE, D. S.; GILES, C. L.; HORNE, B. G.; COTTRELL, G. W. Time-delay neural networks: Representation and induction of finite-state machines. *Neural Networks, IEEE Transactions on*, v. 8, n. 5, p. 1065–1070, 1997.
- CROFT, R.; BARRY, R. Removal of ocular artifact from the eeg: a review. *Neurophysiologie Clinique/Clinical Neurophysiology*, v. 30, n. 1, p. 5 – 19, 2000.
- CURRAN, E. A.; STOKES, M. J. Learning to control brain activity: A review of the production and control of eeg components for driving brain–computer interface (bci) systems. *Brain and Cognition*, v. 51, n. 3, p. 326 – 336, 2003.
- DATTA, S.; DATTA, S. Methods for evaluating clustering algorithms for gene expression data using a reference set of functional classes. *BMC bioinformatics*, v. 7, n. 1, p. 397, 2006.
- DEVLAMINCK, D.; WYNS, B.; BOULLART, L.; SANTENS, P.; OTTE, G. Brain-computer interfaces: from theory to practice. In: *European Symposium on Artificial Neural Networks, 2009*, p. 415–424.
- DOLEZAL, J.; STASTNY, J.; SOVKA, P. Modelling and recognition of movement related eeg signal. In: *Applied Electronics, 2006. AE 2006. International Conference on*, 2006, p. 27 –30.
- DOYNOV, P.; SHERWOOD, J.; DERAKHSHANI, R. Classification of imagined motor tasks for bci. In: *Region 5 Conference, 2008 IEEE, 2008*, p. 1 –6.
- DUECK, D. *Affinity propagation: clustering data by passing messages*. Tese de Doutorado, University of Toronto, 2009.
- ERWIN, H.; FREEMAN, W. J. Freeman k-set. *Scholarpedia*, v. 3, n. 1, p. 3238, 2008.
- FARWELL, L. A.; DONCHIN, E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and clinical Neurophysiology*, v. 70, n. 6, p. 510–523, 1988.

- FATOURECHI, M.; BASHASHATI, A.; WARD, R. K.; BIRCH, G. E. Emg and eeg artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, v. 118, n. 3, p. 480 – 494, 2007.
- FAURE, P.; KORN, H. Is there chaos in the brain? i. concepts of nonlinear dynamics and methods of investigation. *Comptes Rendus de l'Académie des Sciences-Series III-Sciences de la Vie*, v. 324, n. 9, p. 773–793, 2001.
- FREEMAN, W. J. *Mass action in the nervous system*. 1 ed. Academic Press, 1975.
- FREEMAN, W. J. Nonlinear gain mediating cortical stimulus-response relations. *Biological Cybernetics*, v. 33, n. 4, p. 237–247, 1979.
- FREEMAN, W. J. Simulation of chaotic eeg patterns with a dynamic model of the olfactory system. *Biological Cybernetics*, v. 56, p. 139–150, 1987.
- FREEMAN, W. J. The physiology of perception. *Scientific American*, v. 264, n. 2, p. 78 – 85, 1991.
- FREEMAN, W. J. Tutorial on neurobiology: from single neurons to brain chaos. *International journal of bifurcation and chaos*, v. 2, n. 03, p. 451–482, 1992.
- FREEMAN, W. J. Mesoscopic neurodynamics: From neuron to brain. *Journal of Physiology-Paris*, v. 94, n. 5–6, p. 303 – 322, 2000.
- FREEMAN, W. J.; CHANG, H. J.; BURKE, B. C.; ROSE, P. A.; BADLER, J. Taming chaos: stabilization of aperiodic attractors by noise [olfactory system model]. *Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on*, v. 44, n. 10, p. 989 –996, 1997.
- FREEMAN, W. J.; YAO, Y.; BURKE, B. Central pattern generating and recognizing in olfactory bulb: A correlation learning rule. *Neural Networks*, v. 1, n. 4, p. 277 – 288, 1988.
- FRIEDRICH, E. V.; SCHERER, R.; NEUPER, C. Long-term evaluation of a 4-class imagery-based brain–computer interface. *Clinical Neurophysiology*, 2013.
- GARRETT, D.; PETERSON, D. A.; ANDERSON, C. W.; THAUT, M. H. Comparison of linear, nonlinear, and feature selection methods for eeg signal classification. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, v. 11, n. 2, p. 141–144, 2003.
- GIRTON, D.; KAMIYA, J. A simple on-line technique for removing eye movement artifacts from the eeg. *Electroencephalography and Clinical Neurophysiology*, v. 34, n. 2, p. 212 – 216, 1973.
- GOELZ, H.; JONES, R.; BONES, P. Continuous wavelet transform for the detection and classification of epileptiform activity in the eeg. In: *[Engineering in Medicine and Biology, 1999. 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc.] BMES/EMBS Conference, 1999. Proceedings of the First Joint*, 1999, p. 941 vol.2.



- GOTMAN, J.; SKUCE, D. R.; THOMPSON, C. J.; GLOOR, P.; IVES, J. R.; RAY, W. F. Clinical applications of spectral analysis and extraction of features from electroencephalograms with slow waves in adult patients. *Electroencephalography and Clinical Neurophysiology*, v. 35, n. 3, p. 225 – 235, 1973.
- GRATTON, G.; COLES, M. G.; DONCHIN, E. A new method for off-line removal of ocular artifact. *Electroencephalography and Clinical Neurophysiology*, v. 55, n. 4, p. 468 – 484, 1983.
- GUGER, C.; RAMOSER, H.; PFURTSCHELLER, G. Real-time eeg analysis with subject-specific spatial patterns for a brain-computer interface (bci). *Rehabilitation Engineering, IEEE Transactions on*, v. 8, n. 4, p. 447–456, 2000.
- HARTER, D. Evolving neurodynamic controllers for autonomous robots. In: *Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE International Joint Conference on*, 2005, p. 137 – 142.
- HARTER, D. Complex systems approaches to emergent goal formation in cognitive agents. In: *Neural Networks, 2006. IJCNN '06. International Joint Conference on*, 2006, p. 4966 – 4971.
- HASAN, B. A. S.; GAN, J. Q. Hangman bci: An unsupervised adaptive self-paced brain-computer interface for playing games. *Computers in biology and medicine*, 2012.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. Prentice Hall, 1999.
- HE, P.; WILSON, G.; RUSSELL, C. Removal of ocular artifacts from electro-encephalogram by adaptive filtering. *Medical and biological engineering and computing*, v. 42, n. 3, p. 407–412, 2004.
- HELLYAR, M.; IFEACHOR, E.; MAPPS, D.; ALLEN, E.; HUDSON, N. Expert system approach to electroencephalogram signal processing. *Knowledge-Based Systems*, v. 8, n. 4, p. 164–173, 1995.
- HSU, W.-Y. Continuous eeg signal analysis for asynchronous bci application. *International Journal of Neural Systems*, v. 21, n. 04, p. 335–350, 2011.
- HSU, W.-Y.; SUN, Y.-N. Eeg-based motor imagery analysis using weighted wavelet transform features. *Journal of Neuroscience Methods*, v. 176, n. 2, p. 310 – 318, 2009.
- HU, M.; LI, J.; LI, G.; FREEMAN, W. Analysis of early hypoxia eeg based on a novel chaotic neural network. In: KING, I.; WANG, J.; CHAN, L.-W.; WANG, D., eds. *Neural Information Processing*, v. 4232 de *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg, p. 11–18, 2006a.

- HU, M.; LI, J.; LI, G.; TANG, X.; FREEMAN, W. Normal and hypoxia eeg recognition based on a chaotic olfactory model. In: WANG, J.; YI, Z.; ZURADA, J.; LU, B.-L.; YIN, H., eds. *Advances in Neural Networks - ISNN 2006*, v. 3973 de *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg, p. 554–559, 2006b.
- ILIN, R. *Learning and parameterization of recurrent neural network arrays for brain models and practical applications*. Tese de Doutorado, University of Memphis, 2008.
- ILIN, R.; KOZMA, R. Stability of coupled excitatory–inhibitory neural populations and application to control of multi-stable systems. *Physics Letters A*, v. 360, n. 1, p. 66 – 83, 2006.
- ILIN, R.; KOZMA, R. Control of multi-stable chaotic neural networks using input constraints. In: *Neural Networks, 2007. IJCNN 2007. International Joint Conference on*, 2007, p. 2194–2199.
- ILIN, R.; KOZMA, R. Sensor integration in kiv brain model for decision making. In: *Neural Networks, 2009. IJCNN 2009. International Joint Conference on*, 2009, p. 1328 –1334.
- ISHII, R. P.; RIOS, R. A.; MELLO, R. F. Classification of time series generation processes using experimental tools: a survey and proposal of an automatic and systematic approach. *International Journal of Computational Science and Engineering*, v. 6, n. 4, p. 217–237, 2011.
- JUNG, T.-P.; MAKEIG, S.; WESTERFIELD, M.; TOWNSEND, J.; COURCHESNE, E.; SEJNOWSKI, T. J. Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. *Clinical Neurophysiology*, v. 111, n. 10, p. 1745 – 1758, 2000.
- KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M.; ET AL. *Principles of neural science*, v. 4. McGraw-Hill New York, 2000.
- KAWANABE, M.; VIDAURRE, C.; SCHOLLER, S.; MULLER, K.-R. Robust common spatial filters with a maxmin approach. In: *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE, IEEE*, 2009, p. 2470–2473.
- KHORSHIDTALAB, A.; SALAMI, M. J. E. Eeg signal classification for real-time brain-computer interface applications: A review. In: *Mechatronics (ICOM), 2011 4th International Conference On*, 2011, p. 1 –7.
- KISS, T.; ÉRDI, P. Mesoscopic neurodynamics. *Biosystems*, v. 64, n. 1–3, p. 119 – 126, 2002.
- 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.
- KORN, H.; FAURE, P. Is there chaos in the brain? ii. experimental evidence and related models. *Comptes Rendus Biologies*, v. 326, n. 9, p. 787 – 840, 2003.

- KOZMA, R. Intentional systems: Review of neurodynamics, modeling, and robotics implementation. *Physics of Life Reviews*, v. 5, n. 1, p. 1 – 21, 2008.
- KOZMA, R.; AGHAZARIAN, H.; HUNTSHERGER, T.; TUNSTEL, E.; FREEMAN, W. Computational aspects of cognition and consciousness in intelligent devices. *Computational Intelligence Magazine, IEEE*, v. 2, n. 3, p. 53 –64, 2007.
- KOZMA, R.; BELIAEV, I. Time series prediction using chaotic neural networks: case study of ijcnncats benchmark test. In: *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on*, 2004, p. 1609 – 1613 vol.2.
- KOZMA, R.; FREEMAN, W. A possible mechanism for intermittent oscillations in the kiii model of dynamic memories - the case study of olfaction. In: *Neural Networks, 1999. IJCNN '99. International Joint Conference on*, 1999, p. 52 –57 vol.1.
- KOZMA, R.; FREEMAN, W. Chaotic resonance-methods and applications for robust classification of noisy and variable patterns. *International journal of bifurcation and chaos in applied sciences and engineering*, v. 11, n. 6, p. 1607–1630, 2001.
- KOZMA, R.; FREEMAN, W. J. Classification of eeg patterns using nonlinear dynamics and identifying chaotic phase transitions. *Neurocomputing*, v. 44–46, n. 0, p. 1107 – 1112, computational Neuroscience Trends in Research 2002, 2002.
- KOZMA, R.; FREEMAN, W. J. The kiv model of intentional dynamics and decision making. *Neural Networks*, v. 22, n. 3, p. 277 – 285, goal-Directed Neural Systems, 2009.
- KOZMA, R.; ROSA, J. L. G.; PIAZENTIN, D. R. M. Cognitive clustering algorithm for efficient cybersecurity applications. In: *Neural Networks, 2013. IJCNN 2013. International Joint Conference on*, 2013.
- LAGERLUND, T. D.; SHARBROUGH, F. W.; BUSACKER, N. E. Spatial filtering of multichannel electroencephalographic recordings through principal component analysis by singular value decomposition. *Journal of Clinical Neurophysiology*, v. 14, n. 1, p. 73–82, 1997.
- LAKANY, H.; CONWAY, B. Classification of wrist movements using eeg-based wavelets features. In: *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, 2005, p. 5404 –5407.
- LANGE, F. P.; ROELOFS, K.; TONI, I. Motor imagery: A window into the mechanisms and alterations of the motor system. *Cortex*, v. 44, n. 5, p. 494 – 506, 2008.
- LI, G.; ZHANG, J.; FREEMAN, W. Mandarin digital speech recognition based on a chaotic neural network and fuzzy c-means clustering. In: *Fuzzy Systems Conference, 2007. FUZZ-IEEE 2007. IEEE International*, 2007, p. 1 –5.

- LI, H.; KOZMA, R. A dynamic neural network method for time series prediction using the kiii model. In: *Neural Networks, 2003. Proceedings of the International Joint Conference on*, 2003, p. 347 – 352 vol.1.
- LIMA, C. A.; COELHO, A. L.; EISENCRAFT, M. Tackling eeg signal classification with least squares support vector machines: A sensitivity analysis study. *Computers in Biology and Medicine*, v. 40, n. 8, p. 705 – 714, 2010.
- LINS, O. G.; PICTON, T. W.; BERG, P.; SCHERG, M. Ocular artifacts in eeg and event-related potentials i: Scalp topography. *Brain topography*, v. 6, n. 1, p. 51–63, 1993.
- LODDER, S. S.; PUTTEN, M. J. Quantification of the adult eeg background pattern. *Clinical Neurophysiology*, v. 124, n. 2, p. 228 – 237, 2013.
- LOTTE, F.; CONGEDO, M.; LÉCUYER, A.; LAMARCHE, F.; ARNALDI, B. A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of Neural Engineering*, v. 4, n. 2, p. R1, 2007.
- MAKEIG, S.; ENGHOFF, S.; JUNG, T.-P.; SEJNOWSKI, T. J. A natural basis for efficient brain-actuated control. *Rehabilitation Engineering, IEEE Transactions on*, v. 8, n. 2, p. 208–211, 2000.
- MCKENNA, T.; MCMULLEN, T.; SHLESINGER, M. The brain as a dynamic physical system. *Neuroscience*, v. 60, n. 3, p. 587–605, 1994.
- MICHEL, C. M.; MURRAY, M. M.; LANTZ, G.; GONZALEZ, S.; SPINELLI, L.; PERALTA, R. G. Eeg source imaging. *Clinical Neurophysiology*, v. 115, n. 10, p. 2195 – 2222, 2004.
- MILLÁN, J. On the need for on-line learning in brain-computer interfaces. In: *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on*, IEEE, 2004, p. 2877–2882.
- MIROWSKI, P.; MADHAVAN, D.; LECUN, Y.; KUZNIECKY, R. Classification of patterns of eeg synchronization for seizure prediction. *Clinical Neurophysiology*, v. 120, n. 11, p. 1927 – 1940, 2009.
- MITCHELL, T. *Machine learning*. 1997.
- MIZUHARA, H. Cortical dynamics of human scalp eeg origins in a visually guided motor execution. *NeuroImage*, v. 62, n. 3, p. 1884 – 1895, 2012.
- MORETTIN, P. A.; TOLOI, C. M. *Time series analysis and its applications: with r examples*. Edgard Blucher, 2004.
- MU, Z.; WANG, P. Feature extraction of eeg based on data reduction. In: *Computer and Communication Technologies in Agriculture Engineering (CCTAE), 2010 International Conference On*, 2010, p. 275 –277.

- MUNZERT, J.; LOREY, B.; ZENTGRAF, K. Cognitive motor processes: the role of motor imagery in the study of motor representations. *Brain research reviews*, v. 60, n. 2, p. 306–326, 2009.
- MYERS, M.; KOZMA, R. Modeling normal/epileptic brain dynamics with potential application in titration therapy. In: *Neural Networks (IJCNN), The 2011 International Joint Conference on*, 2011, p. 3085–3092.
- NGUYEN, H.-A. T.; MUSSON, J.; LI, F.; WANG, W.; ZHANG, G.; XU, R.; RICHEY, C.; SCHNELL, T.; MCKENZIE, F. D.; LI, J. Eeg artifact removal using a wavelet neural network. *Neurocomputing*, v. 97, n. 0, p. 374–389, 2012.
- NUNEZ, P.; SRINIVASAN, R. *Electric fields of the brain: The neurophysics of eeg*. Oxford University Press, 2006.
- OBERMAIER, B.; GUGER, C.; NEUPER, C.; PFURTSCHELLER, G. Hidden markov models for online classification of single trial eeg data. *Pattern recognition letters*, v. 22, n. 12, p. 1299–1309, 2001.
- OLVER, F. W. *Nist handbook of mathematical functions*. Cambridge University Press, 2010.
- ONTON, J.; WESTERFIELD, M.; TOWNSEND, J.; MAKEIG, S. Imaging human eeg dynamics using independent component analysis. *Neuroscience and biobehavioral reviews*, v. 30, n. 6, p. 808–822, 2006.
- PARDEY, J.; ROBERTS, S.; TARASSENKO, L. A review of parametric modelling techniques for eeg analysis. *Medical Engineering & Physics*, v. 18, n. 1, p. 2–11, 1996.
- PENNY, W. D.; ROBERTS, S. J.; CURRAN, E. A.; STOKES, M. J.; ET AL. Eeg-based communication: a pattern recognition approach. *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, p. 214–215, 2000.
- PETSCHÉ, H.; POCKBERGER, H.; RAPPELSBERGER, P. On the search for the sources of the electroencephalogram. *Neuroscience*, v. 11, n. 1, p. 1–27, 1984.
- 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.
- PFURTSCHELLER, G.; JR., A. S.; NEUPER, C. Event-related synchronization (ers) in the alpha band: an electrophysiological correlate of cortical idling: A review. *International Journal of Psychophysiology*, v. 24, n. 12, p. 39–46, 1996.
- PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, v. 89, n. 7, p. 1123–1134, 2001.

- 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, 1997.
- PFURTSCHELLER, G.; SILVA, F. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, v. 110, n. 11, p. 1842–1857, 1999.
- PIAZENTIN, D. ksets: Release 1.0. 2014.  
Disponível em: <http://dx.doi.org/10.5281/zenodo.12288>
- PIAZENTIN, D.; ROSA, J. L. G. Motor imagery classification for brain-computer interfaces through a chaotic neural network. In: *Neural Networks (IJCNN), 2014 International Joint Conference on*, IEEE, 2014, p. 4103–4108.
- PRINCIPE, J.; TAVARES, V.; HARRIS, J.; FREEMAN, W. Design and implementation of a biologically realistic olfactory cortex in analog vlsi. *Proceedings of the IEEE*, v. 89, n. 7, p. 1030 –1051, 2001.
- QUILTER, P.; MCGILLIVRAY, B.; WADBROOK, D. The removal of eye movement artefact from the eeg signals using correlation techniques. In: *Random Signal Analysis, IEEE Conference Publication*, 1977, p. 93–100.
- RABINER, L.; JUANG, B.-H. An introduction to hidden markov models. *ASSP Magazine, IEEE*, v. 3, n. 1, p. 4–16, 1986.
- RENDÓN, E.; ABUNDEZ, I.; ARIZMENDI, A.; QUIROZ, E. M. Internal versus external cluster validation indexes. *International Journal of computers and communications*, v. 5, n. 1, p. 27–34, 2011.
- ROBERT, C.; GAUDY, J.-F.; LIMOGE, A. Electroencephalogram processing using neural networks. *Clinical Neurophysiology*, v. 113, n. 5, p. 694–701, 2002.
- RUSSELL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. Prentice Hall, 2010.
- SAASTAMOINEN, A.; PIETILÄ, T.; VÄRRI, A.; LEHTOKANGAS, M.; SAARINEN, J. Waveform detection with rbf network–application to automated eeg analysis. *Neurocomputing*, v. 20, n. 1, p. 1–13, 1998.
- SABETI, M.; BOOSTANI, R.; KATEBI, S.; PRICE, G. Selection of relevant features for eeg signal classification of schizophrenic patients. *Biomedical Signal Processing and Control*, v. 2, n. 2, p. 122 – 134, 2007.
- SANEI, S.; CHAMBERS, J. *Eeg signal processing*. John Wiley & Sons, 2007.

- SATTI, A.; COYLE, D.; PRASAD, G. Continuous eeg classification for a self-paced bci. In: *Neural Engineering, 2009. NER '09. 4th International IEEE/EMBS Conference on*, 2009, p. 315–318.
- SCHLÖGL, A.; LEE, F.; BISCHOF, H.; PFURTSCHELLER, G. Characterization of four-class motor imagery eeg data for the bci-competition 2005. *Journal of Neural Engineering*, v. 2, n. 4, p. L14, 2005.
- SHOKER, L.; SANEI, S.; CHAMBERS, J. Artifact removal from electroencephalograms using a hybrid bss-svm algorithm. *Signal Processing Letters, IEEE*, v. 12, n. 10, p. 721–724, 2005.
- SHUMWAY, R. H.; STOFFER, D. S. *Time series analysis and its applications: with r examples*. Springer, 2010.
- SOLHJOO, S.; NASRABADI, A. M.; GOLPAYEGANI, M. R. H. Classification of chaotic signals using hmm classifiers: Eeg-based mental task classification. In: *Proceedings of the European Signal Processing Conference*, 2005.
- SPECHT, D. F. A general regression neural network. *Neural Networks, IEEE Transactions on*, v. 2, n. 6, p. 568–576, 1991.
- STAM, C. Nonlinear dynamical analysis of eeg and meg: Review of an emerging field. *Clinical Neurophysiology*, v. 116, n. 10, p. 2266 – 2301, 2005.
- STOYVA, J.; KAMIYA, J. *Biofeedback and self-control: An aldine annual on the regulation of bodily processes and consciousness*. Aldine, 1972.
- TANGERMANN, M.; MÜLLER, K.-R.; AERTSEN, A.; BIRBAUMER, N.; BRAUN, C.; BRUNNER, C.; LEEB, R.; MEHRING, C.; MILLER, K. J.; MUELLER-PUTZ, G.; NOLTE, G.; PFURTSCHELLER, G.; PREISSEL, H.; SCHALK, G.; SCHLÖGL, A.; VIDAURRE, C.; WALDERT, S.; BLANKERTZ, B. Review of the bci competition iv. *Frontiers in Neuroscience*, v. 6, n. 55, 2012.
- TOWNSEND, G.; GRAIMANN, B.; PFURTSCHELLER, G. Continuous eeg classification during motor imagery-simulation of an asynchronous bci. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, v. 12, n. 2, p. 258–265, 2004.
- TSUDA, I. Toward an interpretation of dynamic neural activity in terms of chaotic dynamical systems. *Behavioral and Brain Sciences*, v. 24, n. 05, p. 793–810, 2001.
- UBEYLI, E. D. Wavelet/mixture of experts network structure for eeg signals classification. *Expert Systems with Applications*, v. 34, n. 3, p. 1954 – 1962, 2008.

- VALDERRAMA, M.; ALVARADO, C.; NIKOLOPOULOS, S.; MARTINERIE, J.; ADAM, C.; NAVARRO, V.; QUYEN, M. L. V. Identifying an increased risk of epileptic seizures using a multi-feature eeg-ecg classification. *Biomedical Signal Processing and Control*, v. 7, n. 3, p. 237 – 244, 2012.
- VALLABHANENI, A.; WANG, T.; HE, B. Brain—computer interface. *Neural Engineering*, p. 85–121, 2005.
- VIGÁRIO, R.; SARELA, J.; JOUSMIKI, V.; HAMALAINEN, M.; OJA, E. Independent component approach to the analysis of eeg and meg recordings. *Biomedical Engineering, IEEE Transactions on*, v. 47, n. 5, p. 589–593, 2000.
- WAIBEL, A.; HANAZAWA, T.; HINTON, G.; SHIKANO, K.; LANG, K. J. Phoneme recognition using time-delay neural networks. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, v. 37, n. 3, p. 328–339, 1989.
- WHITTON, J. L.; LUE, F.; MOLDOFSKY, H. A spectral method for removing eye movement artifacts from the eeg. *Electroencephalography and Clinical Neurophysiology*, v. 44, n. 6, p. 735 – 741, 1978.
- WILSON, G. F.; FISHER, F. Cognitive task classification based upon topographic eeg data. *Biological Psychology*, v. 40, n. 12, p. 239 – 250, 1995.
- 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, 2002.
- XIAOMIN, B.; XIAOQING, N.; YAMING, W.; YANJIANG, Z. Recognition of fabric structures based on improved olfactory neural network. In: *Artificial Intelligence and Computational Intelligence (AICI), 2010 International Conference on*, 2010, p. 325 –328.
- XU, R.; WUNSCH, D. *Clustering*, v. 10. John Wiley & Sons, 2008.
- YANG, X.; FU, J.; LOU, Z.; WANG, L.; LI, G.; FREEMAN, W. Tea classification based on artificial olfaction using bionic olfactory neural network. In: WANG, J.; YI, Z.; ZURADA, J.; LU, B.-L.; YIN, H., eds. *Advances in Neural Networks - ISNN 2006*, v. 3972 de *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg, p. 343–348, 10.1007/11760023\_50, 2006.
- YAO, Y.; FREEMAN, W. Pattern recognition in olfactory systems: modeling and simulation. In: *Neural Networks, 1989. IJCNN., International Joint Conference on*, 1989, p. 699 –704 vol.1.
- ZHANG, H.; GUAN, C.; ANG, K. K.; CHIN, Z. Y. Learning discriminative patterns for self-paced eeg-based motor imagery detection. *Frontiers in Neuroscience*, v. 6, n. 7, 2012.



- ZHANG, J.; LI, G.; FREEMAN, W. Application of novel chaotic neural networks to mandarin digital speech recognition. In: *Neural Networks, 2006. IJCNN '06. International Joint Conference on*, 2006a, p. 653 –658.
- ZHANG, J.; LI, G.; FREEMAN, W. Application of novel chaotic neural networks to text classification based on pca. In: CHANG, L.-W.; LIE, W.-N., eds. *Advances in Image and Video Technology*, v. 4319 de *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg, p. 1041–1048, 2006b.
- ZHANG, J.; LIU, X.; LI, R.; MA, Z.; LI, G. Improved kiii model and its application. In: *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on*, 2008, p. 2218 –2220.
- ZHANG, J.; LOU, Z.; LI, G.; FREEMAN, W. Application of a novel neural network to face recognition based on dwt. In: *Biomedical Robotics and Biomechatronics, 2006. BioRob 2006. The First IEEE/RAS-EMBS International Conference on*, 2006c, p. 1042 –1046.