

Universidade Federal do Rio Grande
Modelagem Computacional

Análise de Sinais Cerebrais Utilizando Árvores de Decisão

Josimara de Ávila Silveira

Rio Grande, 24 de maio de 2013

Universidade Federal do Rio Grande
Modelagem Computacional

Análise de Sinais Cerebrais Utilizando Árvores de Decisão

Josimara de Ávila Silveira

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional, como requisito parcial à obtenção do título de Mestre em Modelagem Computacional.

Orientador(a): Prof^a. Dr^a. Diana Francisca Adamatti

Co-orientador(a): Prof^a. Dr^a. Fernanda Antoniolo Hammes de Carvalho

Rio Grande, 24 de maio de 2013

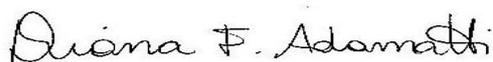
JOSIMARA DE ÁVILA SILVEIRA

ANÁLISE DE SINAIS CEREBRAIS UTILIZANDO ÁRVORES DE DECISÃO

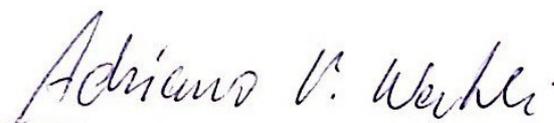
Dissertação apresentada ao Programa de Pós Graduação em Modelagem Computacional da Universidade Federal do Rio Grande -FURG, como requisito parcial para obtenção do Grau de Mestre. Área concentração: Modelagem Computacional.

Aprovada em 27/03/2013

BANCA EXAMINADORA



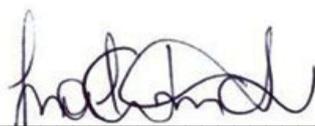
Prof.^a Dra. Diana Francisca Adamatti
Orientadora - FURG



Prof. Dr. Adriano Velasque Werhli
FURG



Prof.^a Dra. Silvia Silva da Costa Botelho
FURG



Prof.^a Dra. Ana Trindade Winck
UFSM

Rio Grande -RS
2013

Dedico este trabalho aos meus pais que sempre me apoiam
por mais estranhas que pareçam minhas ideias.

AGRADECIMENTOS

Aos meus pais, José Vilmar e Mara Gleci, por sempre apoiarem minhas decisões e acreditarem em mim e no meu sucesso mais que eu mesma.

Ao meu irmão, Vitor, que me fez rir e aguentou o meu estresse nestes últimos anos que moramos juntos a quilômetros de distância do restante da família.

À minha cunhada, Inanja, que, junto com meu irmão, me deu o sobrinho mais lindo do mundo, por sua amizade e palavras de incentivo.

À minha orientadora, Prof^a. Dr^a. Diana Francisca Adamatti, pelas ideias, pela disponibilidade em esclarecer dúvidas e mostrar o caminho correto, pelos trabalhos que desenvolvemos juntas ao longo dos últimos anos e principalmente por dividir seu conhecimento e suas vivências comigo, incentivando e encorajando sempre.

À minha co-orientadora, Prof^a. Dr^a. Fernanda Antoniolo Hammes de Carvalho, pela sua colaboração nesse trabalho, por me passar um pouco do seu conhecimento e esclarecer muitas dúvidas na área de neurociência e pela disponibilidade do equipamento para a coleta dos sinais cerebrais.

Aos meus primos, grandes amigos desde o início da vida, Junior, David, Tafarel e Marlucci, e à minha dinda Maria Regina, pela sua amizade, pelo entusiasmo ao me ouvir falar de meus projetos, pelas conversas sobre o que fazer no futuro, e pelas festas, risos, e momentos felizes.

Às amigas, Juliana, Sabrina, Andressa, Fernanda e Rosiane, colegas do curso de Administração, que se preocupam e estão sempre oferecendo ajuda nos estudos e realização de trabalhos, pelos encontros descontraídos, carinho e amizade.

Aos amigos e colegas do mestrado, Leonardo e Felipe, que me acompanham desde a graduação, com quem estudei bastante durante a realização das disciplinas do curso, pelo seu apoio e amizade.

À Alexandra Maiato, por sua grande colaboração na coleta de dados, dividindo comigo seu conhecimento quanto à burocracia desse processo, e pelas horas divertidas de trabalho no CEAMECIM, onde realizamos a coleta.

Aos sujeitos que se disponibilizaram durante vários dias para que os seus sinais cerebrais fossem coletados, sempre com bom humor e paciência.

Aos meus amigos e familiares que de alguma forma me ajudaram a chegar até aqui, me apoiando, incentivando e acreditando nas minhas ideias.

Aos professores Diana, Adriano, Emanuel, Danúbia, Alessandro e Leonardo, com quem exerci atividade de tutoria, devido a bolsa CAPES\REUNI. À CAPES\REUNI pela bolsa de mestrado.

RESUMO

Este trabalho propõe um estudo de sinais cerebrais aplicados em sistemas BCI (Brain-Computer Interface - Interfaces Cérebro Computador), através do uso de Árvores de Decisão e da análise dessas árvores com base nas Neurociências. Para realizar o tratamento dos dados são necessárias 5 fases: aquisição de dados, pré-processamento, extração de características, classificação e validação.

Neste trabalho, todas as fases são contempladas. Contudo, enfatiza-se as fases de classificação e de validação. Na classificação utiliza-se a técnica de Inteligência Artificial denominada Árvores de Decisão. Essa técnica é reconhecida na literatura como uma das formas mais simples e bem sucedidas de algoritmos de aprendizagem. Já a fase de validação é realizada nos estudos baseados na Neurociência, que é um conjunto das disciplinas que estudam o sistema nervoso, sua estrutura, seu desenvolvimento, funcionamento, evolução, relação com o comportamento e a mente, e também suas alterações.

Os resultados obtidos neste trabalho são promissores, mesmo sendo iniciais, visto que podem melhor explicar, com a utilização de uma forma automática, alguns processos cerebrais.

Palavras-chaves: Sistemas BCI (Interface Cérebro Computador), Árvores de Decisão, Neurociência.

ABSTRACT

This work proposes a study on brain signals applied to BCI (Brain-Computer Interface) systems, through the use of Decision Trees and the analysis of these trees based on Neuroscience. To treat the data, this system must execute five stages: data acquisition, preprocessing, feature extraction, classification and validation.

In this work, all phases are executed. However, it emphasizes the classification and validation phases. In the classification, it uses the Artificial Intelligence technique called Decision Trees. This technique is known in the literature as one of the most successful and simpler learning algorithms. The validation phase is based on studies performed in Neuroscience, which is a set of disciplines that study the nervous system, its structure, its development, operation, evolution, behavior and relationship with the mind, and also your changes.

The results of this study are promising, even initials, since they can better explain, with the use of an automated way, some brain processes.

Keywords: BCI (Brain Computer Interface) Systems, Decision Trees, Neuroscience.

Lista de Figuras

1.1	Etapas que compõem a metodologia de trabalho.	4
2.1	Áreas cerebrais [Lent, 2001].	7
2.2	Hemisférios do cérebro	8
2.3	As áreas motoras corticais estão representadas em tons de azul	11
2.4	Componentes funcionais e <i>loops</i> de <i>feedback</i> em um sistema de interface cérebro-computador.	16
2.5	Trabalho experimental utilizado para testar um <i>loop</i> fechado de controle de BCI através de movimentos de macacos.	18
2.6	Colocação de eletrodos para aquisição de sinais de forma não-invasiva usando um eletroencefalograma (EEG).	23
2.7	Etapas de processamento necessário para converter a intenção do usuário a partir do sinal bruto na ação do dispositivo.	24
2.8	Diferentes bandas de sinal presente no sinal EEG.	24
2.9	Evidências de eventos relacionados à dessincronização (ERD) e eventos relacionados à sincronização (ERS), fenômenos antes e após o início do movimento	28
2.10	Componente ERP P300.	30
2.11	Diferentes SCP transmitindo sinais de intenções diferentes.	31
2.12	Potencial Neuronal.	32
2.13	Árvore de decisão para decidir jogar ou não uma partida de tênis.	42
4.1	Etapas da realização do trabalho e o <i>software</i> utilizado em cada uma delas.	52
4.2	<i>Headset</i> de coleta de dados <i>Epoc</i>	54

LISTA DE FIGURAS

4.3	Eletrodos utilizados no <i>Epoc</i> , no padrão internacional “10-20”.	54
4.4	Suíte <i>Expressiv</i> do sistema Emotiv, que mostra o avatar dando um <i>feedback</i> para o usuário [Szafir, 2009]	55
4.5	Suíte <i>Affectiv</i> do sistema Emotiv, que mostra o estado emocional do usuário [Szafir, 2009].	56
4.6	Suíte <i>Cognitiv</i> do sistema Emotiv, que mostra um cubo que obedece aos comandos do usuário [Szafir, 2009].	57
4.7	Telas do <i>software</i> EEGLAB	59
4.8	Exemplos de instâncias do banco de dados.	60
4.9	Telas do <i>software</i> WEKA	61
5.1	Árvore 1: primeiro sujeito, no primeiro dia.	66
5.2	Árvore 2: primeiro sujeito, no segundo dia.	67
5.3	Árvore 3: primeiro sujeito, no terceiro dia.	68
5.4	Árvore 4: primeiro sujeito, no quarto dia.	69
5.5	Árvore 5: segundo sujeito, no primeiro dia.	71
5.6	Árvore 6: segundo sujeito, no segundo dia.	72
5.7	Árvore 7: segundo sujeito, no terceiro dia.	73
5.8	Árvore 8: segundo sujeito, no quarto dia.	74
5.9	Árvore 9: terceiro sujeito, no primeiro dia.	76
5.10	Árvore 10: terceiro sujeito, no segundo dia.	77
5.11	Árvore 11: terceiro sujeito, no terceiro dia.	78
5.12	Árvore 12: terceiro sujeito, no quarto dia.	79

Lista de Tabelas

2.1	Conjunto de instâncias para tomada de decisão.	42
2.2	Matriz de Confusão do exemplo " <i>jogar tênis</i> ".	46
4.1	Áreas cerebrais, eletrodos e funções correspondentes.	63
5.1	Taxas de acerto do sujeito 1 para os 4 dias de coleta	65
5.2	Caminhos presentes na árvore do sujeito 1 no primeiro dia.	66
5.3	Caminhos presentes na árvore do sujeito 1 no segundo dia.	68
5.4	Caminhos presentes na árvore do sujeito 1 no terceiro dia.	68
5.5	Caminhos presentes na árvore do sujeito 1 no quarto dia.	70
5.6	Taxas de acerto do sujeito 2 para os 4 dias de coleta	70
5.7	Caminhos presentes na árvore do sujeito 2 no primeiro dia.	71
5.8	Caminhos presentes na árvore do sujeito 2 no segundo dia.	72
5.9	Caminhos presentes na árvore do sujeito 2 no terceiro dia.	73
5.10	Caminhos presentes na árvore do sujeito 2 no quarto dia.	74
5.11	Taxas de acerto do sujeito 3 para os 4 dias de coleta	75
5.12	Caminhos presentes na árvore do sujeito 3 no primeiro dia.	76
5.13	Caminhos presentes na árvore do sujeito 3 no segundo dia.	77
5.14	Caminhos presentes na árvore do sujeito 3 no terceiro dia.	78
5.15	Caminhos presentes na árvore do sujeito 3 no quarto dia.	80

Conteúdo

Resumo

Abstract

Lista de Figuras

Lista de Tabelas

1	Introdução	1
1.1	Objetivos	3
1.2	Metodologia	4
1.3	Organização do Texto	5
2	Embasamento Teórico	6
2.1	Neurociências	6
2.1.1	Controle Motor	6
2.1.2	Memória de Procedimentos	10
2.1.3	Imaginética Motora	13
2.2	Sistemas BCI	14
2.2.1	Componentes de um Sistema BCI	14
2.2.2	Técnicas de Captura de Sinais Cerebrais	17
2.2.3	Extração de características e Tradução	22
2.3	Aprendizado de Máquina e Árvores de Decisão	39
2.3.1	Indução de Árvores de Decisão	40
2.3.2	Validação das Árvores de Decisão	45

3	Estado da Arte em Sistemas BCI	47
4	Materiais e Métodos	52
4.1	Aquisição dos Dados	52
4.1.1	Emotiv Epoc	53
4.2	Pré-processamento dos Sinais e Extração de Características	57
4.2.1	EEGLAB	58
4.3	Classificação	59
4.3.1	WEKA e Algoritmo J48	61
4.4	Validação	62
5	Análise dos Dados Obtidos	64
5.1	Análise dos Dados do Sujeito 1	64
5.2	Análise dos Dados do Sujeito 2	70
5.3	Análise dos Dados do Sujeito 3	75
5.4	Discussão sobre os resultados obtidos	80
6	Conclusão	83
	Bibliografia	90

Capítulo 1

Introdução

As interfaces homem-máquina, como teclado e mouse nos computadores, joystics e câmeras nos videogames, são comumente utilizados pela maioria da população. No entanto há uma parcela da população que pode necessitar de outras maneiras para interagir com equipamentos eletroeletrônicos, devido a problemas de saúde ou acidentes que levem a paralisias severas, impedindo a utilização de interfaces comuns. O desenvolvimento de Interfaces Cérebro Computador (BCI - *Brain-Computer Interface*) tem o intuito de prover essa comunicação sem a necessidade da utilização de movimentos musculares.

Os sistemas BCI permitem um método de comunicação baseado na atividade neural gerada pelo cérebro, não dependendo da realização dos movimentos musculares que os comandos cerebrais geram. No caso de pessoas com paralisias severas, e que não tem o cérebro comprometido, a atividade neural para realizar um movimento é gerada, mas não chega aos músculos correspondentes ou esses músculos estão fracos para obedecer tais comandos [Vallabhaneni et al., 2005].

A atividade neural utilizada num sistema BCI pode ser acessada utilizando técnicas invasivas ou não-invasivas. O objetivo de tais sistemas não é determinar a intenção de uma pessoa espionando sua atividade cerebral, mas fornecer um novo canal de saída para seu cérebro, o que exige um controle adaptativo e voluntário do usuário [Wolpaw et al., 2000].

Sistemas BCI apresentam grande potencial no auxílio a pessoas com deficiência. Existem várias interfaces projetadas para pessoas com mobilidade condicionada (Wickelgren, 2003 *apud* [Vallabhaneni et al., 2005]). A maioria desses sistemas, no entanto, utiliza algum tipo de controle muscular, como o movimento da cabeça, pescoço, olhos, ou de outros

músculos faciais.

Observa-se que, embora exigindo apenas a atividade cerebral, os sistemas BCI utilizam sinais gerados voluntariamente pelo usuário. Interfaces com base na atividade cerebral involuntária, como a gerada durante um ataque epiléptico, utilizam muitos dos mesmos componentes e princípios dos sistemas BCI, mas não estão incluídos neste campo.

A pesquisa em sistemas BCI tem avançado rapidamente, especialmente nos últimos 20 anos. Há dezenas de grupos de pesquisa ativos em todo o mundo envolvidos no desenvolvimento de tecnologia BCI. Embora os sistemas BCI tenham emergido da teoria para a realidade em aplicações comerciais, o campo ainda é potencialmente inexplorado para pesquisa.

As Neurociências estudam o funcionamento, desenvolvimento e estrutura do sistema nervoso. Comumente tratada como um ramo da biologia, vem se tornando uma ciência interdisciplinar, colaborando com campos como a medicina, educação, química, computação, entre outros. O controle motor, a imaginação de movimento, a capacidade de memorizar ações, o automatismo na realização de ações e o aprendizado são conceitos explicados pelas neurociências que estão extremamente relacionados ao estudo de sistemas BCI. Sabe-se que determinadas regiões cerebrais estão relacionadas com funções desempenhadas pelo cérebro e a observação da ativação dessas regiões podem ajudar a explicar processos de realização de movimentos, de aprendizado e de memorização.

Árvores de decisão (ADs) são classificadores que adotam uma estrutura de árvore condicional, onde cada nó especifica um teste a ser realizado em um único atributo [Duda et al., 2002, Mitchell, 1997, Alpaydin, 2010].

ADs são ferramentas para classificação e previsão. Elas fornecem regras que explicam o comportamento do sistema a ser modelado, além de fornecer um modelo de classificação. Uma das características mais importantes das árvores de decisão é que as regras inferidas através delas são de fácil interpretação.

Aplicar árvores de decisão no âmbito de sistemas BCI é uma abordagem pouco apresentada, alguns trabalhos discutem esse tipo de aplicação utilizando vetores de características extraídas dos sinais cerebrais de imaginação motora [Koprinska, 2010, Aparna et al., 2010]. No entanto, a metodologia apresentada neste trabalho não envolve a criação de vetores de características. A literatura pesquisada não apresenta trabalhos

similares.

O algoritmo J48 foi adotado para a geração das ADs. A escolha se deve ao fato do J48 ser uma derivação do C4.5 [Quinlan, 1993], o mais conhecido e amplamente usado algoritmo para árvores de decisão, oferecida numa versão gratuita pela Universidade de Waikato da Nova Zelândia.

Esta dissertação apresenta a utilização de Árvores de Decisão para a classificação de tarefas de imaginação do movimento das mãos a partir de sinais cerebrais coletados de forma não invasiva com o equipamento Emotiv EPOC. Exibe uma análise, no âmbito da neurociência, dos eletrodos presentes nos ramos das ADs relacionando-os com processos cerebrais relativos as regiões onde os eletrodos estão posicionados no couro cabeludo.

Considerando a taxa atual de desenvolvimento, o avanço da proliferação de tecnologia BCI requer um aumento no número de pessoas e recursos envolvidos. O desenvolvimento dessa área necessita do aumento da cooperação entre diferentes áreas, como ciência da computação, neurociência, engenharia, psicologia, imagens médicas, etc. Estabelecer equipes de pesquisa multidisciplinar é essencial.

1.1 Objetivos

O objetivo geral desta dissertação é realizar uma análise de sinais cerebrais para sistemas BCI utilizando árvores de decisão.

Os objetivos específicos são:

1. Coletar sinais cerebrais de alguns indivíduos, utilizando o equipamento *Epoc* da *Emotiv*(Seção 4.1.1);
2. Realizar o pré-processamento dos sinais coletados;
3. Aplicar ADs para a classificação das tarefas de imaginação do movimento das mãos;
4. Analisar as ADs, com base na neurociência, caracterizando-as e identificando possíveis semelhanças e diferenças.

1.2 Metodologia

A metodologia utilizada para atingir os objetivos propostos nesse trabalho é dividido em 5 etapas como mostrado na Figura 1.1 e explicado a seguir.

Etapa 1 O primeiro passo é a aquisição dos dados. Foram coletados sinais cerebrais de 3 sujeitos utilizando o *Epoc* da *Emotiv*(Seção 4.1.1).

Etapa 2 A segunda etapa consiste no pré-processamento dos dados. Nessa etapa a ferramenta utilizada foi o EEGLAB (Seção 4.2.1). Na etapa de pré-processamento, os dados são organizados para a utilização no algoritmo de ADs. Foram selecionados os sinais dos 14 eletrodos e adicionadas etiquetas referentes a cada tarefa.

Etapa 3 A terceira etapa consiste na extração de características relevantes dos sinais cerebrais já processados. Neste trabalho, a extração de características foi realizada separando as faixas de frequência dos sinais (ver Seção 2.2.3).

Etapa 4 A classificação das tarefas de imaginação do movimento das mãos é a quarta etapa. Foi utilizada a técnica de Inteligência Artificial de Árvores de Decisão para classificar os dados provenientes da etapa anterior. Os dados obtidos foram divididos, uma parte para treinamento e outra para validação. Essa divisão se deu de forma automática pelo *software* WEKA(Seção 4.3.1), que através da validação cruzada (Seção 2.3.2) separa os conjuntos de dados e retorna as taxas de erro, acerto e matriz de confusão, entre outras variáveis.

Etapa 5 A quinta etapa consiste na validação do método de classificação. Neste trabalho, além da verificação das taxas de acerto, um especialista na área de neurociências colaborou na avaliação dos dados obtidos.

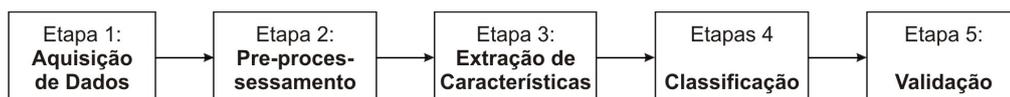


Figura 1.1: Etapas que compõem a metodologia de trabalho.

1.3 Organização do Texto

O texto está dividido em 5 Capítulos, sendo que o Capítulo 1 apresenta a Introdução, os Objetivos e a Metodologia adotada.

O Capítulo 2 apresenta os principais conceitos sobre Sistemas BCI, Aprendizado de Máquina e Árvores de Decisão, e Neurociências.

O Capítulo 3 apresenta o Estado da Arte em sistemas BCI, trabalhos a nível nacional e internacional, bem como a aplicação deste tipo de dados utilizando ADs.

O Capítulo 4 apresenta os Materiais e Métodos utilizados neste trabalho.

O Capítulo 5 mostra os Resultados encontrados, bem como a análise destes resultados, baseados na Neurociência.

O Capítulo 6 finaliza este trabalho apresentando as Conclusões e Trabalhos Futuros.

Também encontra-se em anexo um CD com todos os dados obtidos nesse trabalho.

Capítulo 2

Embasamento Teórico

2.1 Neurociências

2.1.1 Controle Motor

As Neurociências, conjunto das disciplinas que estudam pelos mais variados métodos o sistema nervoso, sua estrutura, seu desenvolvimento, funcionamento, evolução, relação com o comportamento e a mente, e também suas alterações, define coordenação motora como a capacidade de produzir a contração dos músculos de forma orquestrada, resultando em um movimento biologicamente adequado ao contexto. A realização de um movimento emerge à medida que o sujeito usa parâmetros dinâmicos complexos, com esquemas ou representações motoras construídas pela associação de informações geradas em diferentes áreas do cérebro. Lent (2008) lembra que:

“Apesar dessas divisões, o sistema nervoso é integrado. Isso significa que ele funciona integralmente, mediante a cooperação e a interação entre seus diferentes elementos [...]” [Lent, 2008].

Do ponto de vista anatômico, o cérebro humano está dividido em dois hemisférios, direito e esquerdo, os quais são simultaneamente separados e conectados pelo corpo caloso, estrutura constituída por densos feixes de axônios (porções terminais dos neurônios, células que ligadas entre si, conduzem os impulsos nervosos através de sinapses) que promove a comunicação entre ambos. As dobraduras características nesses hemisférios são

denominadas giros ou circunvoluções, estando separados por sulcos ou fissuras. Em cada hemisfério temos os seguintes componentes: um tálamo, um hipocampo, uma amígdala, gânglios basais, um córtex cerebral e quatro lobos (córtex): occipital, parietal, temporal e frontal (Figura 2.1). O lobo occipital é fundamentalmente envolvido com o sentido da visão, o parietal abarca as informações advindas do sentido do tato e da percepção somatosensorial, os lobos temporais processam dados auditivos e os lobos frontais são essenciais para planejamento de ações cognitivas e movimento.

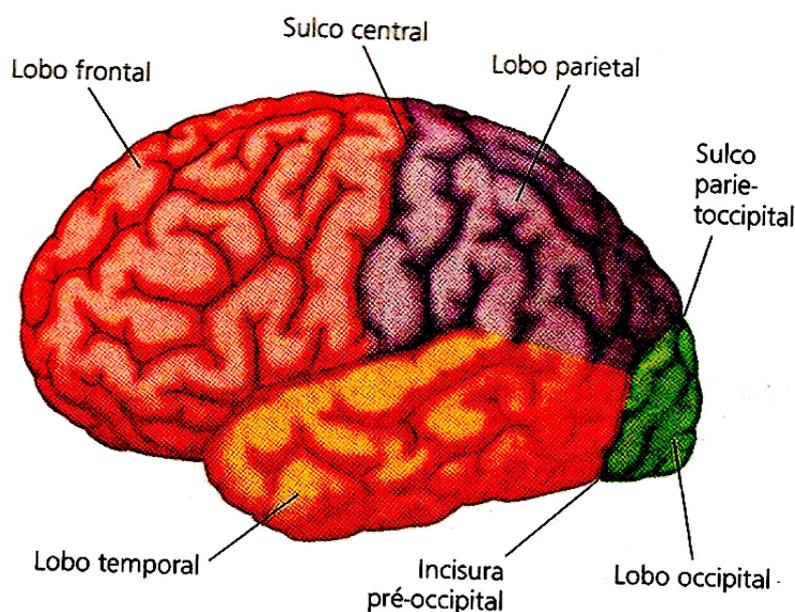


Figura 2.1: Áreas cerebrais [Lent, 2001].

Nos lobos frontais, a última porção é denominada córtex motor primário e está envolvida na execução de movimentos. O restante é chamado de córtex pré-frontal e, ocupando cerca de 30% do cérebro humano, sendo importantíssimo para o comportamento racional, pois é nele que se processam as informações sensoriais que nos permitem perceber os estímulos, lidar com as informações e emoções, planejar ações e entender e emitir comportamentos adequados [Ratey, 2002, Gazzaniga and Heatherton, 2005, Lent, 2008].

Experimentos revelaram que as especialidades dos hemisférios podem ser bem diferentes (Figura 2.2), mas que raramente essa especialização significa exclusividade funcional. Exemplificando: o hemisfério esquerdo controla a fala em mais de 95% dos seres humanos, entretanto, é a prosódia do hemisfério direito que confere à fala nuances afetivas essenciais para a comunicação interpessoal. Enquanto o esquerdo é melhor na realização mental de

cálculos matemáticos, no comando da escrita e na compreensão da leitura, o hemisfério direito é melhor na percepção de sons musicais e no reconhecimento de faces. O hemisfério esquerdo participa também do reconhecimento de faces, mas sua especialidade é nominá-las, ou melhor, identificar quem é o dono de cada face (sobretudo se for o próprio indivíduo). Já o hemisfério direito é especialmente capaz de identificar categorias gerais de objetos e seres vivos (livros, cães), mas é o esquerdo que detecta as categorias específicas. O hemisfério direito é melhor na detecção de relações espaciais, particularmente as relações métricas, quantificáveis, aquelas que são úteis para o nosso deslocamento no mundo como o cálculo da distância que se está do carro da frente. O hemisfério esquerdo não deixa de participar dessa função, mas está envolvido no reconhecimento de relações espaciais categoriais, qualitativas (acima de, abaixo de, dentro, fora ...) [Lent, 2001].

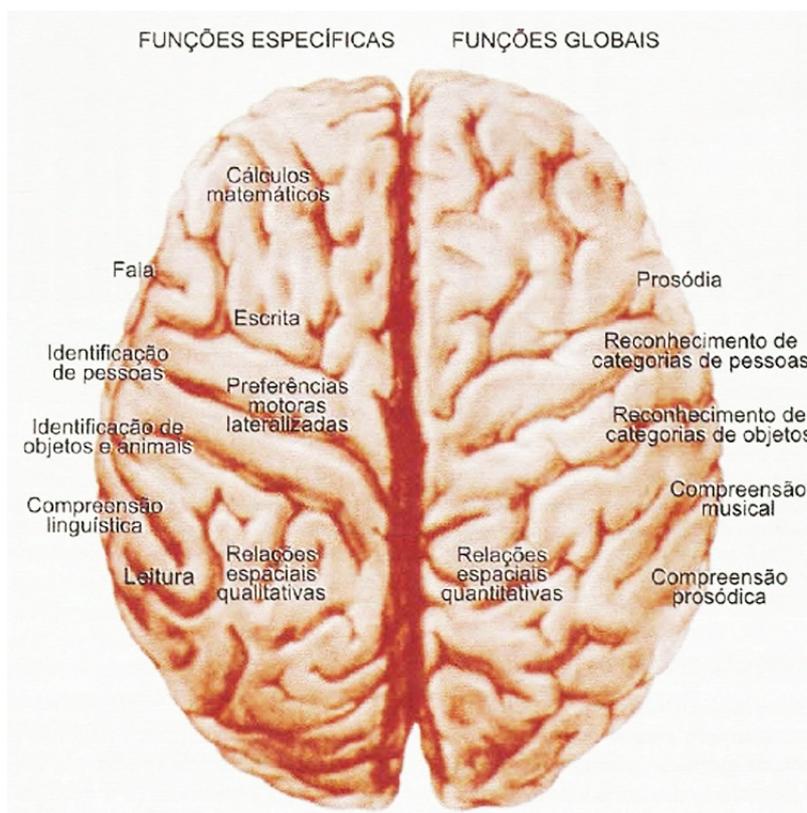


Figura 2.2: Os hemisférios são especializados, o que significa que participam das mesmas funções de modo diferente. O conceito de especialização superou o conceito antigo de dominância, pelo qual um dos hemisférios faria tudo; sendo o outro apenas uma “reserva técnica” coadjuvante[Lent, 2001].

Uma dificuldade para o estudo da determinação neurobiológica das assimetrias comportamentais é que elas são suscetíveis a influências ambientais, destacando-se as possibilidades de treinamento para executar ações diversas. Um bom exemplo são os jogadores de futebol, que podem ser treinados a utilizar os dois pés para chutar, embora originalmente prefiram utilizar um deles [Lent, 2001].

Estudos sugerem que o planejamento, a correção e a execução dos movimentos estão inscritos em redes neurais que incluem o córtex pré-frontal, o córtex motor primário, o córtex pré-motor, a área motora suplementar, o córtex parietal, o córtex cingulado, o cerebelo e os núcleos da base, além de núcleos talâmicos, núcleos do tronco encefálico e a medula espinhal. A experiência individual, a integridade das redes formadas por essas regiões, bem como a complexidade do movimento influenciam o modo como essas regiões são ativadas. Além disso, as redes neurais (ou circuitos cerebrais) são plásticos, isto é, são capazes de se modificar com o aprendizado ou após lesões. Esses grupos neurais estão envolvidos também na codificação dos aspectos representacionais dos movimentos tais como o reconhecimento, a predição e o aprendizado de ações por meio de observação e a capacidade de simular mentalmente os movimentos [Lent, 2008, Gazzaniga et al., 2006].

Como salientado, o córtex motor primário e o córtex pré-motor estão ambos localizados no lobo frontal, uma das partes mais avançadas do cérebro, a qual também é responsável pelas funções executivas (FEs). As FEs são uma série de processos cognitivos especializados que permitem ao indivíduo perceber estímulos do ambiente e responder adequadamente, uma vez que ao envolver a percepção, a atenção e a memória de trabalho, planificam as ações, ocorrendo a seleção e inibição de respostas [Ratey, 2002, Squire and Kandel, 2003]. Ao serem responsáveis por organizar as capacidades perceptivas, mnésica e práxicas em determinado contexto são essenciais para o planejamento motor, pois esse envolve ter uma ideia sobre o que fazer, organizar uma ação e finalmente executá-la.

O córtex motor recebe, de forma convergente, informações de outras áreas do cérebro e as usa para planejar movimentos, exercendo o controle direto de determinados movimentos. Embora o córtex sensorial, localizado logo atrás da área motora primária, constitua uma significativa fonte de informações para o córtex motor, grande soma de dados flui também para as áreas motoras acerca de nossos pensamentos, experiências passadas,

emoções e memórias armazenadas, contribuindo com significado, profundidade e complexidade para os movimentos e ações. “Novas ações são planejadas usando o conhecimento de informações sensoriais, e as experiências passadas e sensações que as acompanham” [Ratey, 2002].

Conforme Lent [Lent, 2001], uma área motora deve: (1) projetar e receber de outras regiões motoras; (2) provocar distúrbios motores quando lesada; (3) provocar movimentos quando estimulada e (4) possuir atividade neural e fluxo sanguíneo aumentados precedendo e acompanhando a execução de movimentos pelo próprio indivíduo ou quando observa o movimento de terceiros.

As regiões corticais envolvidas nesse processo são mostradas na Figura 2.3. Podem-se considerar quatro grandes áreas motoras no córtex cerebral: a área motora primária (M1), que ocupa o giro pré-central do lobo frontal e relaciona-se com o comando dos movimentos voluntários; a área motora suplementar (MS), que se localiza rostral e dorsalmente a M1; a área pré-motora (PM), que se situa rostral e lateralmente a M1, e a área motora cingulada (MC), posicionada na face medial do córtex, logo acima do corpo caloso. MS e PM estão mais relacionadas com o planejamento dos movimentos voluntários, que com o comando de sua execução, e MC parece participar dos movimentos que tem conotação emocional. Apesar de que cada área, com exceção de M1, apresentar subdivisões com funções distintas, as áreas corticais estão interconectadas, apresentando inclusive conexões com outras regiões corticais em ambos os hemisférios, como a área somestésica primária (S1) e as áreas associativas dos lobos parietal e frontal. É importante ressaltar também que todas elas projetam para regiões motoras subcorticais e contribuem para o feixe corticoespinhal. M1, representa o "alto comando motor", isto é, a região de onde surgem os comandos para os movimentos voluntários, aqueles que vão superpor-se aos reflexos, às reações posturais, à locomoção e aos movimentos de orientação sensoriomotora [Lent, 2001, Gazzaniga et al., 2006].

2.1.2 Memória de Procedimentos

Como bem salienta Ratey [Ratey, 2002], adquirir numerosos repertórios motores é essencial para a sobrevivência, sendo que movimento, memória e aprendizagem estão estreitamente interligados. O aprendizado, como resultado de uma experiência, reflete uma

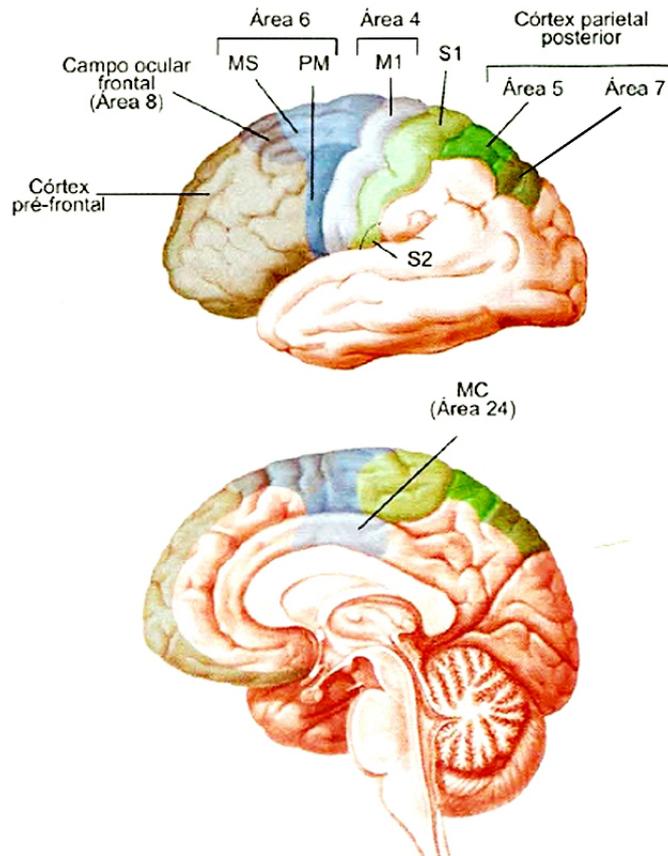


Figura 2.3: As áreas motoras corticais estão representadas em tons de azul. As áreas representadas em tons de verde conectam-se com as primeiras, mas não são consideradas partes do sistema motor. O desenho de cima ilustra a face lateral do hemisfério esquerdo, e o desenho de baixo ilustra a face medial do hemisfério direito. Todas as áreas representadas, entretanto, existem em ambos os hemisférios. Abreviaturas no texto. Os números referem-se à classificação citoarquitetônica de Brodmann [Lent, 2001].

alteração relativamente permanente no comportamento dos organismos. Aprender envolve usar a memória, ou melhor, a capacidade de adquirir, reter e armazenar informações para mais tarde as reconhecer e poder aplicar [Kolb and Whishaw, 2002].

As representações mentais criadas e resgatadas via memória caracterizam traços de memória, o qual envolve a habilidade de recordar ou reconhecer experiências anteriores. Assim, a memória pode ser considerada o substrato orgânico para que ocorra a aprendizagem, pois permite que as informações fiquem armazenadas e sejam utilizadas. Segundo Izquierdo [Izquierdo, 2002] “A memória é o processo pelo qual aquilo que é aprendido persiste ao longo do tempo”.

Segundo Gazzaniga, Ivry e Mangun [Gazzaniga et al., 2006] a codificação, o armazenamento e a evocação constituem as principais etapas da aprendizagem e da memória. Na codificação ocorre o processamento da nova informação, envolvendo duas fases: aquisição (registro de informações) e consolidação (cria a representação da informação através do tempo). Desses dois processos emerge o armazenamento, isto é, a criação e manutenção do registro permanente. A evocação se refere ao resgate da informação para gerar comportamentos.

Interessa destacar que mecanismos cerebrais envolvidos na aprendizagem e na memória, inclusive na sua evocação, estão associados aos processos neuropsicológicos como atenção, percepção, motivação e pensamento, de forma que caso ocorram perturbações em qualquer um deles, a aprendizagem e a memória, tendem a ser indiretamente afetadas.

Izquierdo [Izquierdo, 2002], tomando como referência a duração, considera três tipos de memória. A memória de trabalho é extremamente curta, dura de 1 a 3 minutos, tendo como objetivo fundamental, “[...] comparar as informações que chegam constantemente ao cérebro e compará-las com as demais memórias, declarativas ou procedurais, de curta ou longa duração”. A memória de curta duração é um “alojamento temporário” da memória principal enquanto essa ainda não foi formada, utilizada pelo cérebro enquanto o processo de consolidação não está finalizado, não sendo extinta ao longo de 4 a 6 horas. Após esse intervalo é substituída pela memória de longa duração, a qual sofre grande influência das emoções e da motivação.

Para o referido autor, uma segunda classificação advém do conteúdo das memórias. Registros de fatos, eventos ou conhecimentos são memórias declarativas. Dentre essas, existem memórias episódicas (referentes a eventos que participamos ou assistimos) e semânticas (envolvem conhecimentos gerais). As memórias procedurais ou de procedimentos surgem de nossas capacidades ou habilidades motoras ou sensoriais. Quando considerado a maneira como as memórias são adquiridas, as memórias implícitas são geradas de maneira mais ou menos automática, enquanto que as explícitas sofrem plena intervenção da consciência e são mais suscetíveis as emoções, ansiedade e estados de ânimo.

A memória de procedimentos ou procedural trata dos hábitos, habilidades e regras, algo que muitas vezes memorizamos sem sentir e utilizamos sem tomar consciência. Durante a aprendizagem de uma nova tarefa, muitos circuitos específicos do córtex frontal

são ativados, mas diante de reprodução repetida em um razoável número de vezes, os padrões adquirem estabilidade e o comportamento torna-se automático, não demandando mais atenção consciente. É um procedimento que, “arquivado” na memória adquire grande solidez e durabilidade [Ratey, 2002].

Desse modo, diante da regularidade da sequência de movimentos, o desempenho de um indivíduo na realização de um movimento que não era habitual para si melhora gradativamente. Entretanto, se questionado se sabe o que fez seu desempenho melhorar, provavelmente dirá que não sabe. Ou seja, aprendeu, mas não tomou consciência de como o fez. As habilidades motoras empregadas com finalidade de atingir objetivos resultam de memórias implícitas, isto é, não requerem atenção, acontecem automaticamente, sem ter a consciência de estar lembrando de algo e sem esforço deliberativo. Aprende-se andar de bicicleta e amarrar os sapatos treinando muitas vezes. Depois, simplesmente realiza-se esses comportamentos sem raciocinar sobre quais movimentos devemos fazer a cada momento [Lent, 2001].

Posner e Raichle [Posner and Raichle, 2001] preconizam que “A prática no desempenho de qualquer tarefa diminui o número de redes neurais necessárias para a realizar”. Nesse momento, a utilização de redes de atenção é reduzida e outros percursos são reorganizados.

De acordo com Ratey [Ratey, 2002], pode-se converter memórias implícitas (no caso o movimento aprendido, como andar de bicicleta) em memórias explícitas e isso muda a localização da memória no cérebro. Quando aprende-se algum ato motor precisamos estar envolvidos ativamente, isto é, trata-se de uma aprendizagem explícita, na qual há uma grande ativação das FEs. Ao dominarmos a tarefa não precisamos relembrar ativamente o que fazer. Assim, “Uma pessoa capaz de dominar sequências motoras cada vez mais intrincadas pode estar envolvida num movimento complexo e ter, no entanto, um tranquilo córtex frontal”, pois esse não está mais tão atento na realização do movimento e está mais disponível para observar e realizar ajustes.

2.1.3 Imaginética Motora

O sistema motor é responsável pela produção e codificação dos aspectos representacionais do movimento, como, por exemplo, a capacidade de simular mentalmente uma determinada ação. Os mesmos mecanismos envolvidos na execução são utilizados na simulação

mental, mas sem realmente se mover. Ao recriar usam as mesmas regiões do cérebro que teria usado para executar o movimento, tratando-se de um processo cognitivo usado pelas áreas responsáveis pelo movimento real [Ratey, 2002, Lent, 2008].

Conforme Lent [Lent, 2008], a imaginética motora é definida como um processo dinâmico no qual o sujeito acessa o plano motor de uma dada ação e acompanha ativamente o seu desdobramento. Segundo o autor, estudos demonstram a existência de acentuado paralelismo entre imaginação e execução de movimento, sendo as características temporais da simulação mental de um movimento, extremamente similares a sua execução, de modo que o tempo gasto na imaginação de uma caminhada a um determinado alvo é similar ao gasto na realização de tal ação. A imaginética motora também modula o sistema nervoso autônomo. Durante a simulação de movimentos observa-se, por exemplo, aumento da frequência cardíaca proporcional à carga de exercício imaginado, mesmo que não haja evidência eletromiográfica ou metabólica de atividade muscular.

2.2 Sistemas BCI

2.2.1 Componentes de um Sistema BCI

Após a apresentação de trabalhos de Hans Berger em 1929 sobre um dispositivo que mais tarde veio a ser conhecido como eletroencefalograma (EEG), que poderia gravar potenciais elétricos gerados pela atividade cerebral, houve especulação de que talvez equipamentos pudessem ser controlados usando esses sinais. Durante muito tempo, isto foi apenas uma especulação.

Como revisado por Wolpaw [Wolpaw et al., 2000], 40 anos mais tarde, na década de 1970, os pesquisadores foram capazes de desenvolver sistemas de controle primitivo baseados na atividade elétrica cerebral. A agência norte-americana *Defense Advanced Research Projects Agency* (DARPA), envolvida no desenvolvimento das primeiras pesquisas relacionadas ao surgimento da Internet, financiou pesquisas voltadas para o desenvolvimento de dispositivos biônicos que ajudassem os soldados daquele país. As primeiras pesquisas, conduzidas por George Lawrence, eram focadas no desenvolvimento de técnicas para melhorar o desempenho dos soldados em tarefas que tinham altas cargas mentais. Sua pesquisa produziu uma grande quantidade de descobertas sobre os métodos de auto-regulação cognitiva

e *biofeedback*, mas não produziu qualquer dispositivo utilizável [Vallabhaneni et al., 2005].

A DARPA expandiu seu foco para um campo mais geral de biocibernética com o objetivo de explorar a possibilidade de controlar dispositivos através do processamento computadorizado em tempo real de qualquer sinal biológico. O laboratório de BCI da UCLA (Universidade da Califórnia, Los Angeles), dirigido por Jacques Vidal¹, apontou evidências de que potenciais visualmente-evocados poderiam ser usados como um canal de comunicação eficaz o suficiente para controlar um cursor através de um labirinto bidimensional (Vidal, 1977 *apud* [Vallabhaneni et al., 2005]).

Trabalhos realizados por grupos como o de Vidal provaram que os sinais de atividade cerebral podem ser usados para comunicar eficazmente a intenção do usuário. Também criou uma separação clara entre os sistemas utilizando a atividade EEG e aqueles que usaram a atividade EMG (eletromiograma) gerados a partir de terminações nervosas musculares ou movimentos dos músculos faciais. Trabalhos posteriores apresentaram outras técnicas de captura da atividade neural utilizadas em sistemas BCI além do EEG [Vallabhaneni et al., 2005].

Os sistemas BCI desenvolvidos atualmente são ferramentas que podem ajudar os usuários a se comunicar e realizar atividades cotidianas, embora apresentem um sucesso limitado e ainda se encontrem principalmente em ambientes de pesquisa. Os principais utilizadores do sistema BCI são indivíduos com leve a grave deficiência muscular. Os sistemas BCI também têm sido desenvolvidos para usuários com certas deficiências mentais como o autismo e ainda para pessoas que não apresentam nenhuma deficiência, principalmente como entretenimento na indústria de jogos.

O trabalho de Mason e Birch (2003) *apud* [Vallabhaneni et al., 2005] apresentou um modelo geral para sistemas BCI, sobre o qual um vocabulário universal poderia ser desenvolvido e diferentes sistemas deste tipo poderiam ser comparados.

O objetivo de um sistema BCI é permitir que o usuário interaja com um dispositivo. Esta interação é ativada através de uma variedade de componentes funcionais intermediários, sinais de controle e *loops de feedback*, conforme detalhado na Figura 2.4. Componentes funcionais intermediários desempenham funções específicas na conversão de intenções em ação. Por definição, isto significa que o usuário e o dispositivo também são partes

¹<http://www.cs.ucla.edu/vidal/vidal.html>

integrantes de um sistema BCI. A interação também é possível através de *loops de feedback* que servem para informar, a cada componente do sistema, o estado de um ou mais componentes.

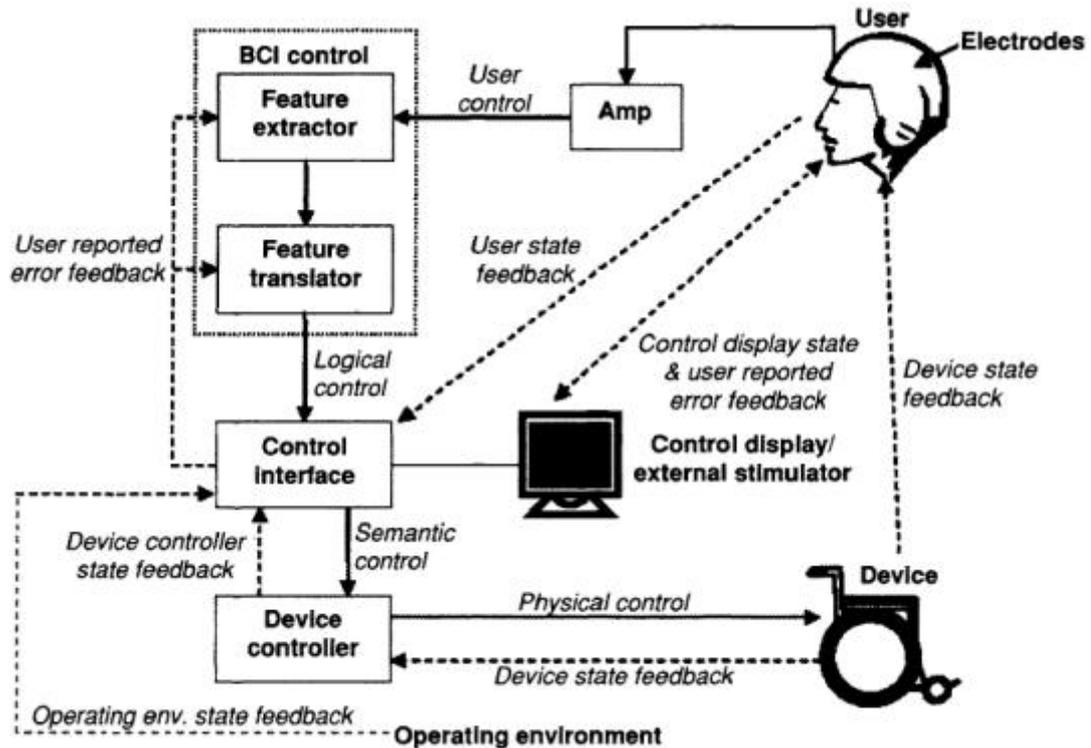


Figura 2.4: Componentes funcionais e *loops de feedback* em um sistema de interface cérebro-computador. A atividade do cérebro do usuário é medida pelos eletrodos e depois amplificada. O extrator de característica transforma sinais brutos em vetores de características relevantes, que são classificados em controles lógicos por um tradutor. A interface de controle converte os controles lógicos em controles semânticos que são passados para o controlador de dispositivo. O controlador de dispositivo muda os controles semânticos em comandos específicos que são executados pelo dispositivo. Dessa forma, o sistema BCI pode converter a intenção do usuário em ação do dispositivo [Vallabhaneni et al., 2005].

2.2.2 Técnicas de Captura de Sinais Cerebrais

Técnicas Invasivas

Os dispositivos BCI “mais puros” usam implantes corticais, ou seja eletrodos são implantados dentro do crânio do paciente. Os exemplos mais conhecidos são a matriz de Utah e a matriz de Michigan, em homenagem as instituições em que os conjuntos de sensores foram desenvolvidos. A matriz de Utah compreende uma matriz de 8x8 ou 10x10 eletrodos que são inseridos diretamente no córtex. Com base na organização colunar do córtex, por exemplo em relação à sensibilidade de orientação, o objetivo é traduzir a separação espacial de “pensamentos” individuais no córtex em sinais discretos para formar um padrão na matriz de eletrodos. Os dois exemplos mais famosos para este tipo de dispositivo BCI invasivo são o *BrainGate* para controle de cadeira de rodas e caso de Matt Nagle, um paraplégico que aprendeu a controlar um braço biônico apenas pelo poder do cérebro [Schuette, 2010].

O lado negativo dos dispositivos BCI invasivos são os efeitos a longo prazo, como a possibilidade de desenvolver doença de Alzheimer e sintomas neurodegenerativos que são tratados com diferentes graus de sucesso por revestimento dos eletrodos.

Uma experiência notável foi realizada por Nicolelis e Chapin (2002) *apud* [Vallabhaneni et al., 2005] em macacos, para controlar um braço robótico em tempo real através da atividade elétrica de um neurônio motor registrada por microfios ligados a esse neurônio. Vários parâmetros de controle motor puderam ser capturados, incluindo a direção do movimento da mão, força de aperto, velocidade, aceleração, posição tridimensional, etc. Estes foram obtidos a partir dos fluxos paralelos de atividade neuronal por modelos matemáticos. Neste sistema, os macacos aprendem a produzir os movimentos complexos das mãos em resposta a estímulos sensoriais arbitrários. Os macacos poderiam explorar um *feedback* visual para julgar por si mesmos se o robô poderia imitar os movimentos das suas mãos. A Figura 2.5 apresenta esse sistema (Nicolelis, 2003 *apud* [Vallabhaneni et al., 2005]).

Uma abordagem menos invasiva tem sido aplicada a pacientes epiléticos para o planejamento cirúrgico, no qual um conjunto de eletrodos são inseridos na região subdural próximo ao córtex. Esse procedimento é chamado de electrocorticograma (ECoG). Ele-

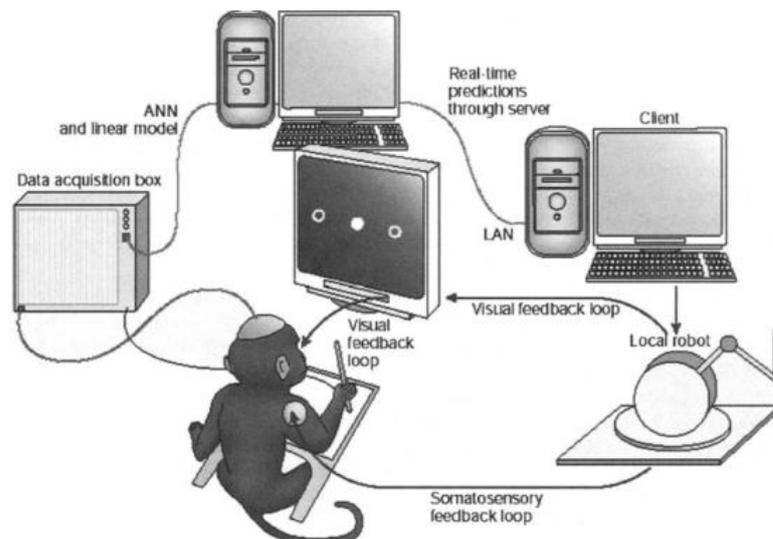


Figura 2.5: Trabalho experimental utilizado para testar um *loop* fechado de controle de BCI através de movimentos de macacos. Conjuntos de microfios implantados são usados para capturar a atividade extracelular de populações de neurônios em várias regiões do córtex motor. Modelos lineares e não-lineares, em tempo real, são usados para extrair comandos de controle motor de sinais brutos de atividade cerebral. As saídas destes modelos são utilizadas para controlar os movimentos de um braço robótico. Por exemplo, enquanto um modelo pode fornecer um sinal de velocidade para mover o braço do robô, um outro modelo, de modo paralelo, pode extrair um sinal de força que pode ser usado para permitir que uma garra segure um objeto durante um movimento do braço. Sinais táteis artificiais e *feedback* visual são usados para informar ao animal sobre o desempenho de um braço robótico controlado por sinais derivados do cérebro. O *feedback* visual é fornecido usando um cursor que se move em uma tela de vídeo para informar o animal sobre a posição do braço do robô no espaço. O *feedback* tátil artificial é entregue por uma série de pequenos elementos que vibram, ligado ao braço do animal. Este dispositivo tátil é usado para informar o animal sobre o desempenho da pinça do braço robótico (se a pinça encontrou um objeto no espaço, ou se a pinça aplicou força suficiente para segurar um objeto)[Vallabhaneni et al., 2005].

trodos subdurais estão mais próximos de estruturas neuronais das camadas cortical superficial do que de eletrodos colocados no couro cabeludo como no eletroencefalograma (EEG). Estima-se que eletrodos no couro cabeludo representam a atividade elétrica espa-

cialmente média sobre uma área cortical de, pelo menos, vários centímetros quadrados. Vários eletrodos subdurais podem ser colocados em uma área desta dimensão tal que cada um desses eletrodos mede a atividade bioelétrica espacialmente média de uma área menor do que vários centímetros quadrados. As vantagens de gravações subdural incluem gravação a partir de fontes menores de “atividade sincronizada”, maior relação sinal-ruído do que a de gravações couro cabeludo, e maior capacidade de gravar e estudar a atividade do ritmo *gama* (acima de 30 Hz), pois este ritmo é gerado pela rápida oscilação de conjuntos de células composto por um pequeno número de neurônios. Consequentemente, a atividade *gama* é caracterizada por flutuações de pequena amplitude que não são facilmente gravadas com eletrodos no couro cabeludo (Pfurtscheller *et al.*, 2003 *apud* [Vallabhaneni *et al.*, 2005]).

Técnicas invasivas causam significativa quantidade de desconforto e risco para o paciente. Pesquisadores as usam em seres humanos só se trarão melhoria considerável em termos de funcionalidade sobre métodos não-invasivos. A maioria das pesquisas iniciais, portanto, é realizada em animais, especialmente macacos e ratos. Pesquisas com esses animais tem levado ao rápido desenvolvimento da microeletrônica, que permite gravar atividades eletrofisiológicas de um pequeno grupo de neurônios, ou mesmo um único neurônio. Esse tipo de tecnologia permite amostragem simultânea e confiável de 5-20 neurônios, distribuídos em várias áreas corticais de primatas pequenos, por um período de alguns anos (Wessberg *et al.*, 2000 *apud* [Vallabhaneni *et al.*, 2005]).

A vantagem de técnicas invasivas é a alta resolução espacial e temporal que pode ser alcançada, pois gravações podem ser feitas a partir de neurônios individuais com taxas de amostragem muito altas. Sinais gravados de forma intracraniana poderiam obter mais informações e permitir respostas mais rápidas, o que pode levar à diminuição requisitos de treinamento e atenção (Sanchez *et al.*, 2004 *apud* [Vallabhaneni *et al.*, 2005]). Várias questões, no entanto, têm que ser consideradas (Lauer *et al.*, 2000 *apud* [Vallabhaneni *et al.*, 2005]).Primeiro, a estabilidade a longo prazo do sinal ao longo de dias e anos é difícil de alcançar. O usuário deve ser capaz de gerar consistentemente o sinal de controle confiável, sem a necessidade de retornos frequentes. Segundo é a questão da plasticidade cortical após uma lesão medular. Foi levantada a hipótese de que o córtex motor passa por reorganização após uma lesão da medula espinhal, mas o grau é

desconhecido (Brouwer and Hopkins-Rosseel, 1997 *apud* [Vallabhaneni et al., 2005]). Finalmente, se uma neuroprótese que requer um estímulo para o membro com deficiência é usada, este estímulo vai também produzir um ruído significativo sobre o couro cabeludo, que pode interferir com o sinal de interesse. Nesses casos, os sistemas BCI devem ser capazes de detectar com precisão e remover estes ruídos.

Também é necessário desenvolver uma melhor compreensão dos princípios pelos quais conjuntos neurais codificam informação sensorial, motora e cognitiva (Isaacs *et al.*, 2000; Nicoletis, 2001; Serruya *et al.*, 2002 *apud* [Vallabhaneni et al., 2005]). No caso do controle motor, por exemplo, as áreas do cérebro dos primatas que estão envolvidas são bem conhecidas e até mesmo as propriedades fisiológicas de neurônios individuais localizados nestas áreas têm sido bem estudados. Pouco se sabe, no entanto, sobre como o cérebro faz uso desta informação a partir dos neurônios, para gerar os movimentos. No projeto de controle de movimento, portanto, mais estudo é necessário para desenvolver um método que pode eficientemente decodificar os sinais gerados pelos neurônios motores para um que dispositivo artificial possa imitar o movimento pretendido.

Experimentos clássicos em primatas, por exemplo, têm demonstrado que parâmetros fundamentais de controle motor emergem pela ativação coletiva de grandes populações de neurônios distribuídos no córtex motor primário. Para calcular uma direção precisa de movimento do braço, por exemplo, o cérebro pode ter que realizar o equivalente a um “voto” neuronal ou, em termos matemáticos, um somatório de vetores da atividade desses neurônios mais ou menos afinados. Isto implica que, para obter os sinais motores necessários para controlar um dispositivo artificial, que imite esse braço, é necessário obter a atividade de muitos neurônios simultaneamente, assim como projetar algoritmos que são capazes de extrair sinais de controle motor a partir destes conjuntos. Vários modelos bem estabelecidos, tais como regressão linear, população de vetores e redes neurais têm sido aplicados com sucesso para lidar com grandes quantidades de dados neurais e estimar a trajetória dos movimentos (Wessberg *et al.*, 2000, Taylor *et al.* , 2002, Serruya *et al.*, 2003 *apud* [Vallabhaneni et al., 2005]). Mas esses sinais e modelos estão longe de fornecer uma gama completa de movimentos que um braço pode produzir (Donoghue, 2002 *apud* [Vallabhaneni et al., 2005]).

Como mencionado anteriormente, as experiências com seres humanos até agora têm

sido limitadas. Atualmente, somente alguns pacientes com deficiências graves têm recebido implantes de eletrodos. Em alguns casos, o sucesso tem sido limitado, com alguns pacientes capazes de se comunicar de forma textual a uma taxa de apenas três letras por minuto (Mussa-Ivaldi e Miller, 2003 *apud* [Vallabhaneni et al., 2005]). Mais avanços em microeletrodos, no entanto, são necessários para obter gravações estáveis durante um longo prazo, ou seja, mais de 1 ano.

Além das áreas de pesquisas referidas acima, o foco em minimizar o número de células necessárias para gravações simultâneas obtendo um sinal útil, bem como o fornecimento de *feedback* para o sistema nervoso através da estimulação elétrica utilizando eletrodos, também é essencial para um uso generalizado de técnicas invasivas em humanos.

Técnicas Não-invasivas

Existem muitos métodos não-invasivos para medir a atividade cerebral. Técnicas não invasivas reduzem o risco para os usuários, uma vez que não requerem cirurgia ou fixação permanente de eletrodos. Técnicas como a tomografia computadorizada (CT - *Computerized Tomography*), tomografia por emissão de pósitrons (PET - *Positron Electron Tomography*), tomografia computadorizada por emissão de fóton único (SPECT - *Single-Photon Emission Computed Tomography*), ressonância magnética (MRI - *Magnetic Resonance Imaging*), ressonância magnética funcional (fMRI - *functional Magnetic Resonance Imaging*), magnetoencefalografia (MEG - *Magnetoencephalography*) e eletroencefalografia (EEG - *electroencephalography*) têm sido os métodos utilizados para medir a atividade do cérebro de forma não invasiva.

A eletroencefalografia, no entanto, é o método mais utilizado na aquisição de sinal BCI. EEG tem uma alta resolução temporal, capaz de medir a atividade a cada milésimo de segundo. Aparelhos modernos de EEG também tem uma resolução espacial razoável com sinais, de até 256 de eletrodos ao mesmo tempo.

A praticidade no uso de EEG em laboratório e em ambientes do mundo real é um dos principais pontos positivos dessa técnica. Os dispositivos são portáteis e os eletrodos podem ser facilmente colocados no couro cabeludo do usuário, simplesmente vestindo uma touca. Além disso, aparelhos de EEG tem sido usados em numerosos campos desde a sua criação. Portanto, as técnicas e tecnologia de aquisição de sinal através deste método

foram padronizadas.

Muitos sistemas BCI baseados em EEG utilizam uma disposição dos eletrodos no escalpo sugerida pelo sistema internacional 10-20, conforme detalhado na Figura 2.6. Para uma melhor resolução espacial, também é comum o uso de uma variante do sistema 10-20, que preenche os espaços entre os eletrodos com eletrodos adicionais (Malmivuo e Plonsey, 1995 *apud* [Vallabhaneni et al., 2005]).

2.2.3 Extração de características e Tradução

O estudo de sistemas BCI está focado em melhorar os métodos de extração de características dos sinais coletados e traduzi-los em comandos de controle de forma adequada para que os dispositivos obedeçam com maior fidelidade a intenção do usuário. Uma característica presente em um sinal pode ser vista como o reflexo de um aspecto específico da fisiologia e anatomia do sistema nervoso [Wolpaw et al., 2000]. O objetivo dos métodos de extração de características, com base nesta definição, seria obter o aspecto fisiológico específico do sistema nervoso através de uma série temporal específica. As etapas envolvidas na extração de características e tradução são detalhadas na Figura 2.7.

Tipos de Sinais Cerebrais

A) Picos e Potenciais de Campo

O cérebro gera uma grande quantidade de atividade neural. A captura dessa atividade gera uma infinidade de sinais elétricos, que podem ser usado para sistemas BCI. Esses sinais se dividem em duas classes principais: picos e potenciais de campo (Wolpaw, 2003 *apud* [Vallabhaneni et al., 2005]). Os picos refletem os potenciais de ação de neurônios individuais e, assim, adquiridos principalmente através de microeletrodos implantados por meio de técnicas invasivas. Potenciais de campo, no entanto, são medidas da atividade sináptica, neuronal e axonal de grupos de neurônios e pode ser medido por eletrodos implantados ou EEG de acordo com a resolução espacial necessária. Como mencionado anteriormente, a maioria das pesquisas está focada no BCI usando sinais de EEG.

B) EEG Bandas de Frequência

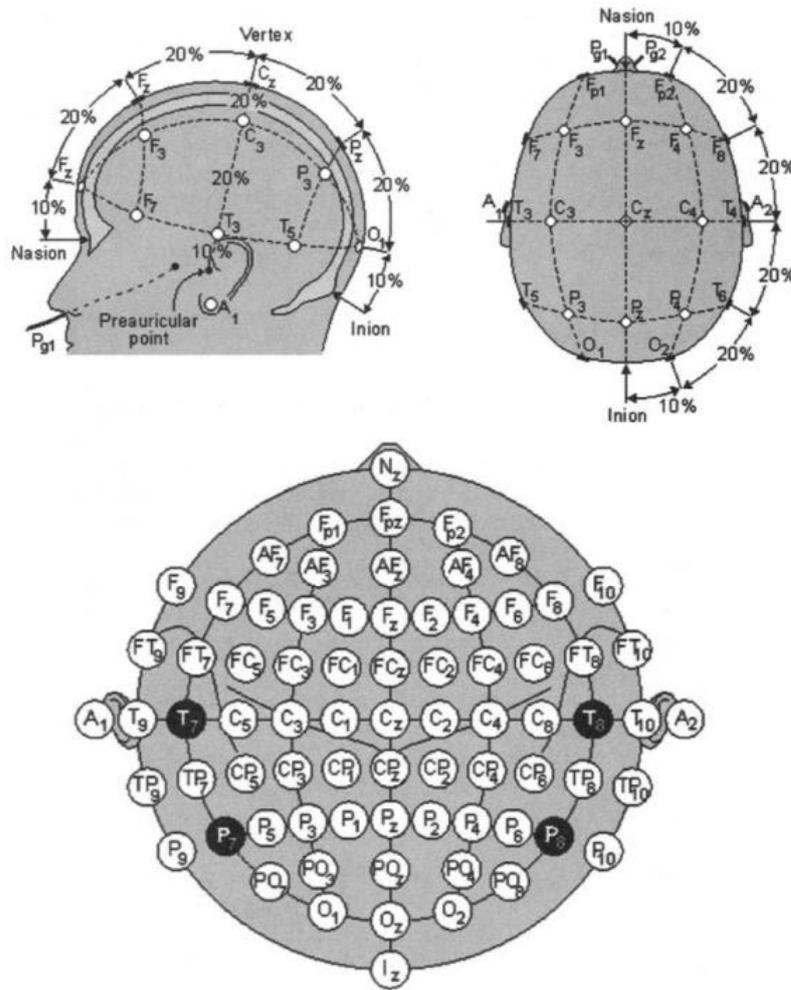


Figura 2.6: Colocação de eletrodos para aquisição de sinais de forma não-invasiva usando um eletroencefalograma (EEG). Este arranjo padronizado de eletrodos sobre o couro cabeludo é conhecida como o sistema internacional 10-20 e garante ampla cobertura de todas as regiões da cabeça. As posições exatas para cada eletrodo estão na interseção das linhas calculadas a partir de medições entre marcos padrão no crânio. A letra em cada eletrodo indica a região do cérebro (FP, lobo pré-frontal; F, lobo frontal; T, lobo temporal; C, sulco central; P, lobo parietal; O, lobo occipital). O número ou a segunda letra identificam a sua localização hemisférica (Z, linha zero no centro da cabeça; números pares representam o hemisfério direito; números ímpares representam o hemisfério esquerdo. Os números são em ordem crescente com o aumento da distância do centro) [Vallabhaneni et al., 2005].

Sinais gravados a partir de EEG são divididos em várias bandas como mostrado na Figura 2.8. A banda (ou ritmo) *delta* varia de 0,5 a 4 Hz, a banda *teta* cobre a faixa de



Figura 2.7: Etapas de processamento necessário para converter a intenção do usuário a partir do sinal bruto na ação do dispositivo. Sinais captados através de métodos invasivos ou não-invasivos contém uma grande quantidade de ruído. O primeiro passo antes da extração de características e tradução é remover o ruído. Isto é seguido pela seleção de características relevantes através de técnicas que focam na maximização da relação sinal-ruído. Finalmente, as técnicas de tradução são utilizadas para classificar as características relevantes em um dos estados possíveis [Vallabhaneni et al., 2005].

4 a 8 Hz. A maioria dos trabalhos em BCI centra-se na banda *alfa* (8-13 Hz) e na banda *beta* (13-30 Hz). A banda *gama* compreende todos os sinais maiores que 30 Hz. A seguir serão mais detalhados os ritmos presentes nas faixas de frequência determinadas.

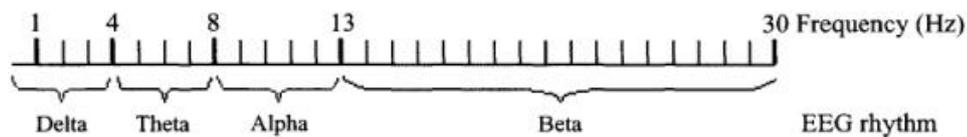


Figura 2.8: Diferentes bandas de sinal presente no sinal EEG. As faixas de banda *delta* e *teta* variam de 0,5 a 4 Hz e 4 a 8 Hz, respectivamente. A maioria dos sistemas BCI utilizam componentes na banda *alfa* (8-13 Hz) e a banda *beta* (13-30 Hz) [Vallabhaneni et al., 2005].

a) Ritmo Delta

O ritmo *delta* apresenta-se na faixa de 0,5 a 4 Hz, com amplitude variável, inferior a $100 \mu V$. Este ritmo está relacionado com o estado de sono profundo, em recém-nascidos e em algumas disfunções cerebrais, sendo mais predominante na região frontal. Por causa de sua magnitude variável, às vezes é confundido com um artefato (ruído), dessa forma esse tipo de sinal é pouco relevante para a área de BCI.

b) Ritmo Teta

O ritmo *teta* é limitado pela faixa de 4 a 8 Hz, com amplitude que pode alcançar

100 μV . Este ritmo é muito frequente na infância, já nos adultos está relacionado com o estresse emocional, mais especificamente com a frustração e desapontamento, podendo ser observado nas regiões parietal e temporal. Pode-se observá-lo também, durante momentos de inspiração criativa e profunda meditação.

c) Ritmo Alfa

O ritmo *alfa* é mais predominante sobre a região occipital do cérebro, podendo também ser registrado na região frontal, existindo na banda de frequência entre 8 e 13 Hz, com amplitude entre 30 e 50 μV . Este ritmo está, normalmente, associado com o estado de relaxamento e os olhos fechados.

d) Ritmo Mu

O ritmo *mu* se origina no córtex motor, englobando as áreas motoras primária, suplementar e parietal. Suas características são semelhantes às do ritmo *alfa*, com amplitude inferior a 50 μV e frequência entre 8 e 13 Hz, mas, representam diferentes fenômenos e são originados em diferentes zonas. Sua amplitude diminui com o movimento ou intenção de movimento.

e) Ritmo Beta

O ritmo *beta* pode ser detectado sobre as regiões parietal e frontal com uma amplitude entre 5 e 30 μV , na banda de frequência entre 13 e 30 Hz. Normalmente essa banda é subdividida em três sub-bandas, *beta 1* (13-18 Hz), *beta 2* (18-24 Hz) e *beta 3* (24-30Hz). Cada uma delas apresenta origens distintas, mas analisando-as como um todo, as ondas *beta* são associadas ao processamento de informação exterior, resolução de problemas, tomada de decisões, estando por isso presentes em qualquer movimento físico.

f) Ritmos Gama

O ritmo *gama* esta relacionado com processos mentais de complexidade elevada como é a consciência e percepção, ocorre a partir dos 30 Hz e até ao limite da banda determinada pelo filtro aplicado ao EEG. Suspeita-se que sejam os ritmos cerebrais que contêm a maior quantidade de informação, no entanto, poucos avanços significativos foram ainda feitos

na sua interpretação.

C) Componentes de interesse

Componentes de interesse para BCI podem ser divididos em quatro categorias: atividade oscilatória de EEG, potenciais relacionados a eventos (ERP - *Event-Related Potentials*), potenciais corticais lentos (SCP - *Slow Cortical Potentials*), e os potenciais neuronais:

a) Atividade oscilatória de EEG

Atividade oscilatória de EEG é causada pela complexa rede de neurônios criando *loops* de *feedback*. O disparo sincronizado dos neurônios nesses circuitos de *feedback* gera oscilações observáveis. A frequência das oscilações diminui à medida que o número de neurônios sincronizados aumenta. As propriedades de membrana dos neurônios subjacentes e a dinâmica dos processos sinápticos, a força e a complexidade das conexões na rede neuronal e as influências de outros sistemas neurotransmissores, também desempenham um papel na determinação das oscilações.

Duas oscilações distintas e de grande interesse são as ritmo *mu* rolândico (rolândico é como é chamado o sulco que separa as regiões frontal e parietal no cérebro), ocorrendo na faixa de 10-12 Hz, e o ritmo *beta* central, ocorrendo na faixa de Hz 14-18. Ambos originários da região do córtex sensório-motor do cérebro. Estas oscilações ocorrem continuamente durante a “marcha lenta”, quando o indivíduo está em repouso físico e mental. Durante os períodos diferentes do repouso, no entanto, essas oscilações são temporariamente modificadas e as mudança na frequência e amplitude são evidentes no EEG. A amplitude das oscilações diminui à medida que a frequência aumenta, pois a frequência das oscilações está negativamente correlacionada com a sua amplitude (Pfurtscheller e Neuper, 2001 *apud* [Vallabhaneni et al., 2005]).

b) Potenciais relacionados a eventos

Potenciais relacionados a eventos (ERP - *Event-Related Potentials*) são respostas do cérebro que ocorrem em um tempo fixo depois de um evento particular, externo ou interno. Estes potenciais ocorrem geralmente quando o indivíduo é submetido a estímulos

sensoriais visuais ou auditivos, evento mental, ou a omissão de um estímulo, ocorrendo constantemente [Vallabhaneni et al., 2005].

Componentes exógenos de ERP são respostas obrigatórias a estímulos e ocorrem devido ao processamento do evento externo, independente do papel dos estímulos no processamento de informações. O *flash* aleatório de uma lâmpada, por exemplo, irá gerar um componente exógeno de como o cérebro responde ao súbito clarão de luz, independentemente do contexto.

Componentes endógenos de ERP ocorrem quando um evento interno é processado. Ele depende do papel do estímulo na tarefa e o relacionamento entre o estímulo e o contexto em que ocorreu. Um usuário tentando localizar a letra R em uma palavra, por exemplo, irá gerar um componente endógeno de ERP se a letra R for apresentada já que é o evento que ele está procurando. Se o usuário está tentando encontrar a letra S, no entanto, ele não irá gerar um componente endógeno ERP se a letra R for apresentada, uma vez que a relação entre o estímulo e o contexto em que ocorreu não é mais válida.

c) Potenciais relacionados a eventos de sincronização e dessincronização

Um tipo particular de ERP é caracterizado pela ocorrência de um evento relacionado à dessincronização (ERD - *Event-Related Desynchronization*) ou evento relacionado à sincronização (ERS - *Event-Related Synchronization*). Modificações nos fatores que controlam a oscilação de redes neuronais, como a estimulação sensorial ou imagens mentais, são responsáveis pela geração desses potenciais relacionados a eventos.

Uma diminuição na sincronização dos neurônios provoca uma diminuição da potência em bandas de frequência específicas e esse fenômeno é definido como um ERD e pode ser identificado por uma diminuição na amplitude do sinal. Presença de ERD é muito frequente na banda *alfa*, especialmente durante as tarefas que envolvem percepção, memória e julgamento. Um aumento na complexidade dessas tarefas amplifica a magnitude do ERD.

ERS, por outro lado, é caracterizado por um aumento de potência em bandas de frequência específicas, principalmente nas bandas *beta* e *gama*, e é gerado por um aumento na sincronização dos neurônios e pode ser identificado por um aumento na amplitude do sinal. ERD e ERS são medidos em relação a uma linha de base ou do intervalo de

referência. Então a amplitude de um ERD/ERS é relacionado com a variação dos ritmos neste intervalo.

A propriedade *time-locked* (o tempo entre a alteração do sinal e a ocorrência do evento) de ERP é particularmente evidente para ERD/ERS durante tarefas motoras, imaginadas ou reais, como mostrado na Figura 2.9. Um ERD no ritmo *mu* começa 2,5s antes do início movimento e apresenta picos após o início do movimento, antes de recuperar a linha de base. O ERD de curta duração no ritmo *beta* ocorre antes do início movimento e é imediatamente seguido por um ERS com picos após o início do movimento. Oscilações e ERS também são encontradas em torno da banda *gama* de 40 Hz, quando submetido a estimulação visual, devido à ligação da informação sensorial com tarefas motoras. A alta frequência da banda *gama* funciona bem para configurar o acoplamento rápido ou sincronização entre grupos espacialmente separadas de neurônios [Pfurtscheller and da Silva, 1999].

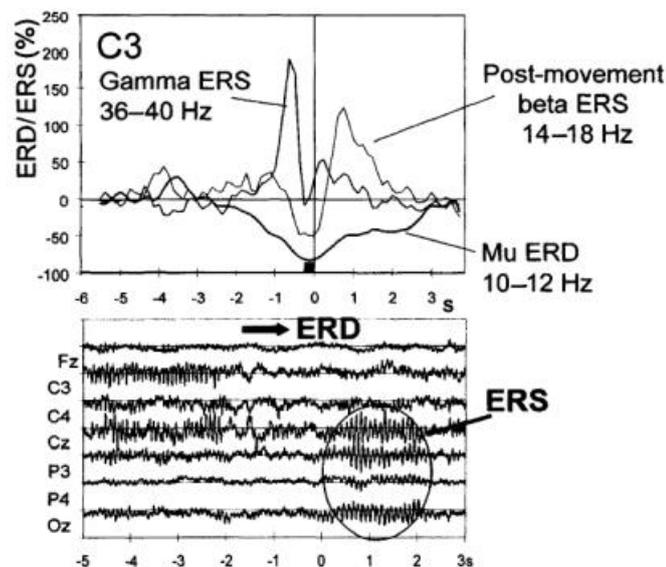


Figura 2.9: Evidências de eventos relacionados à dessincronização (ERD) e eventos relacionados à sincronização (ERS), fenômenos antes e após o início do movimento. ERD é o resultado de uma diminuição na sincronização dos neurônios, o que provoca uma diminuição do poder em bandas de frequência específica, e pode ser identificado por uma diminuição na amplitude do sinal. ERS é o resultado de um aumento na sincronização dos neurônios, o que provoca um aumento de potência em bandas de frequência específica, e pode ser identificada pelo aumento da amplitude do sinal [Vallabhaneni et al., 2005].

d) Potencial visualmente evocados

Outro tipo de ERP comumente usado em BCI é o potencial visualmente evocado (VEP- *Visual-Evoked Potential*), um componente do EEG que ocorre em resposta a um estímulo visual. VEP dependem que o usuário controle seu olhar, portanto requerem um controle muscular coerente. Um VEP frequentemente utilizado é o potencial visualmente evocado sustentado (SSVEP - *Steady-State Visual Evoked Potential*). SSVEP é um componente ERP exógeno. O usuário concentra seu olhar em um dos dois objetos que piscam na tela com frequências diferentes nas bandas *alfa* e *beta*. O componente SSVEP é amplificado quando o usuário muda o foco para o outro objeto e depois retorna ao inicial. O usuário pode continuar a alternar o foco entre os dois objetos na tela para gerar mudanças no sinal (Middendorff *et al.*, 2000 *apud* [Vallabhaneni et al., 2005]).

e) P300

O P300 é um componente ERP endógeno e ocorre como parte do paradigma *oddball*, que consiste na discriminação de uma frequência ou estímulo infrequente (estímulo-alvo) entre frequências ou estímulos frequentes (não-alvo) [Brayner, 2003]. Para a utilização deste componente os usuários são sujeitos a eventos que podem ser classificados em duas categorias distintas. Eventos em uma das duas categorias, porém, raramente são exibidos. Quando um evento da categoria rara é exibido, ele provoca um componente P300, que é uma grande onda positiva que ocorre cerca de 300 ms após o início de eventos como mostrado na Figura 2.10. A amplitude do componente P300 é inversamente proporcional à velocidade com que o evento raro é apresentado. Quanto mais vezes esse evento raro aparece, menor fica a amplitude do P300.

Este componente ERP é uma resposta natural e, portanto, especialmente útil nos casos em que tempo de treinamento é curto ou inexistente, ou ainda quando o usuário não pode ser facilmente treinado (Spencer *et al.*, 2001 *apud* [Vallabhaneni et al., 2005]).

f) Potencial Cortical Lento

Um tipo completamente diferente de sinal é o potencial cortical lento (SCP - *Slow Cortical Potential*), que é causado por mudanças nos níveis de despolarização de certos

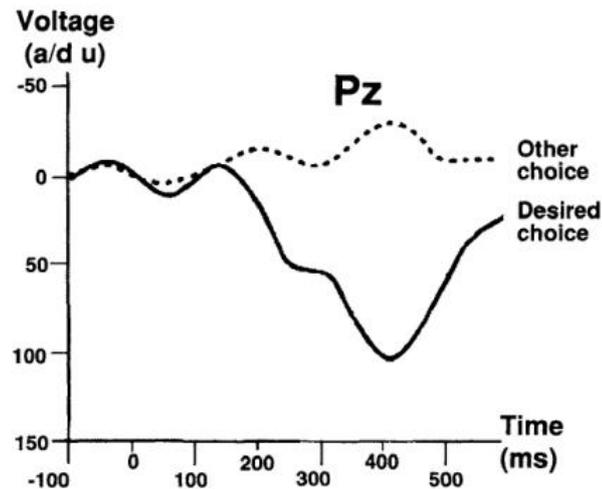


Figura 2.10: Componente ERP P300. Objetos são apresentados ao usuário aleatoriamente em uma tela. O componente P300 irá ocorrer quando o objeto que o usuário está procurando aparecer, enquanto qualquer um dos outros objetos está sendo apresentado não ocorre uma mudança semelhante na tensão. A amplitude do componente P300 é inversamente proporcional à taxa na qual o objeto de interesse é apresentado e ocorre aproximadamente 300 ms após o objeto é exibido. É uma resposta natural e não requer treinamento do usuário [Vallabhaneni et al., 2005].

dendritos (prolongamentos dos neurônios que funcionam como receptores de estímulos nervosos). SCP negativo indica a soma dos potenciais sincronizados, enquanto SCP positivo indica redução de potenciais sincronizados a partir dos dendritos. Quando o desempenho comportamental e cognitivo do usuário aumenta, os potenciais sincronizados também aumentam, resultando em um aumento de negatividade do SCP. Pelo fato deste potencial cortical ocorrer de 0,5 a 10s após o início de um evento interno, como mostrado na Figura 2.11, é chamado de potencial cortical lento (Birbaumer *et al.*, 1999, 2000; Wolpaw *et al.*, 2000b *apud* [Vallabhaneni et al., 2005]).

g) Potencial Neuronal

Potencial neuronal é um pico de tensão a partir de neurônios individuais, como mostrado na Figura 2.12. Recebe esse nome pois pode ser medido em um neurônio ou um grupo de neurônios. O sinal apresenta uma medida da taxa média, correlação e padrão temporal do disparo neuronal. O sistema nervoso central apresenta informações sobre a

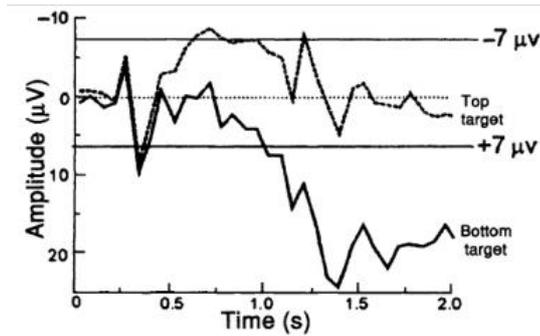


Figura 2.11: Diferentes SCP transmitindo sinais de intenções diferentes. SCPs são causadas por mudanças no nível de despolarização de dendrites. Ocorrem 0,5-10 s após o início de um evento interno e, portanto, são considerados um potencial cortical lento [Vallabhaneni et al., 2005].

taxa de disparo de cada neurônio. Portanto, o aprendizado pode ser medido através de mudanças na taxa média de disparo dos neurônios localizados nas áreas corticais associadas à tarefa.

O potencial neuronal apresenta a taxa de disparo e a localização dos neurônios que estão disparando. Pesquisas nessa área são limitadas a animais, devido aos procedimentos invasivos necessários para a implantação dos eletrodos e pela falta de eletrodos que gerem gravações estáveis durante um longo período de tempo. Os estudos são limitados, entretanto, demonstram que um melhor controle de dispositivos pode ser possível isolando sinais com melhor resolução espacial (Wolpaw *et al.*, 2002; Moxon, 2005 *apud* [Vallabhaneni et al., 2005]).

Treinamento

A eficácia de um sistema BCI depende da capacidade do usuário de controlar sua atividade EEG e de sua persistência ou boa vontade nessa tarefa. Ao contrário de tarefas motoras, o controle da atividade do cérebro é mais difícil de alcançar, pois o usuário não pode nem identificar nem avaliar a atividade. O usuário só pode compreender sua atividade EEG através do *feedback* recebido dos componentes no sistema BCI (Curran e Stokes, 2003; Kostov e Polak, 2000; Laubach *et al.*, 2000 *apud* [Vallabhaneni et al., 2005]).

O objetivo do treinamento, portanto, é conseguir que os usuários produzam voluntariamente sinais EEG detectáveis e que possam ser alterados para alcançar um resultado

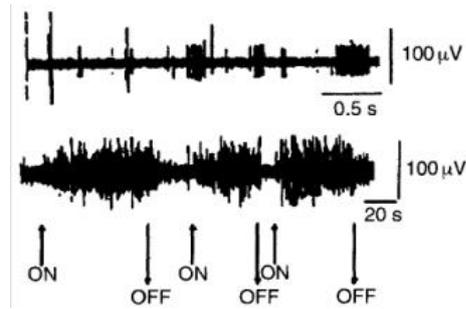


Figura 2.12: Potencial Neuronal. Estes sinais são picos de tensão e podem ser medidos a partir de neurônios individuais ou grupos de neurônios. Eles refletem a taxa de disparo média, correlação e padrão temporal de disparo neuronal. O quadro superior indica o sinal gravado a partir de neurônios em marcha lenta (indivíduo em repouso) e quadro inferior de neurônios ativos [Vallabhaneni et al., 2005].

específico. Embora o usuário não esteja ciente de como e quando os sinais são gerados, o processo de geração do sinal só pode ser ativado por ações voluntárias do usuário. No entanto esses sinais podem ser produzidos voluntariamente através da atividade mental consciente, como a contagem de números, ou como uma resposta automática para uma situação que exige pouco esforço consciente, como andar de bicicleta.

A) Tarefas cognitivas

A maioria dos métodos de treinamento exige que o usuário execute tarefas cognitivas específicas. Estes métodos visam o desenvolvimento de capacidade do usuário para gerar componentes EEG através de atividade mental voluntária e consciente. Tarefas de imagi-nética motora (MI - *Motor Imagery*) são as tarefas cognitivas mais utilizadas. Em cada teste, o usuário imagina um dos vários movimentos motores (como o movimento da mão esquerda ou direita) com base em sinais visuais ou auditivos. O usuário gera sinais no córtex sensório-motor do cérebro e pode ser detectado por EEG (Annett, 1995; Jeanne-rod, 1995 *apud* [Vallabhaneni et al., 2005]). Depois de várias sessões de treinamento, o usuário é capaz de controlar a amplitude e a frequência dos sinais cerebrais (Babiloni *et al.*, 2000 *apud* [Vallabhaneni et al., 2005]).

Outras tarefas cognitivas comumente usadas não envolvem imagética motora. Ao contrário, elas exigem que o usuário execute ações como aritmética (adição de uma série

de números), contagem visual (visualização sequencial de números), a rotação de figura geométrica (visualização de rotação de um objeto 3D em torno de um eixo), formação de sílabas (ou soletração) e relaxamento (linha de base). Pesquisas mostraram que essas tarefas produzem componentes EEG detectáveis após o treinamento (Pfurtscheller *et al.*, 1993; Penny e Roberts, 1999; Babiloni *et al.*, 2000; Birbaumer *et al.*, 2000; Penny *et al.*, 2000, *apud* [Vallabhaneni *et al.*, 2005]).

B) Condicionamento Operante

A abordagem do condicionamento operante não requer que usuário realize tarefas cognitivas específicas como no método anterior. O foco desse método está em ajudar no ganho automático de controle do dispositivo pelo usuário sem ter que pensar em algo específico. O *feedback* fornecido pelo sistema serve para condicionar o usuário a continuar produzindo os componentes EEG que tenham alcançado o resultado desejado de controle do dispositivo. Com a prática contínua, o usuário é capaz de ganhar o controle do dispositivo, sem necessariamente estar ciente dos componentes EEG específicos que está produzido. É importante notar, no entanto, que o método de condicionamento operante usa frequentemente tarefas de imagética motora na fase inicial do treinamento, para mostrar aos usuários o conceito de que as ondas cerebrais podem ser controladas.

C) Fatores que afetam o treinamento

Tanto o método de treinamento que utiliza as tarefas cognitivas quanto o condicionamento operante, estão sujeitos a inúmeros fatores externos. Alguns dos fatores mais comuns são a falta de concentração, distrações, frustração, estado emocional, fadiga, motivação e intenções. É importante para neutralizar esses fatores durante o treinamento, fornecer um *feedback* amplo e variar a duração ou frequência das sessões de treinamento [Vallabhaneni *et al.*, 2005].

Além disso, os componentes EEG produzidos por tarefas cognitivas são vulneráveis à quantidade de orientação dada ao usuário. Imagética motora, por exemplo, está sujeita a questões como a perspectiva em primeira ou terceira pessoa, a visualização da ação contra a recuperação de uma memória da ação realizada anteriormente, a imaginação da tarefa em

vez de uma narração verbal, etc. Pesquisa provaram que os usuários podem efetivamente controlar tais detalhes para produzir uma mudança significativa nos componentes que produzem [Vallabhaneni et al., 2005].

Como o foco dos sistemas BCI é proporcionar um meio de comunicação para pessoas com necessidades diferenciadas, é possível que alguns usuários que sofreram doenças mentalmente debilitantes não tenham o controle de todas as áreas do cérebro. Cada usuário deve trabalhar com as tarefas cognitivas que melhor atendam às suas capacidades.

É possível analisar diferentes tarefas cognitivas com base nos componentes EEG gerados quando a tarefa é realizada. Ao usar uma combinação de tarefas cognitivas durante o treinamento, pode ocorrer uma sobreposição dos sinais de EEG, se as tarefas exigirem habilidades ou áreas cerebrais semelhantes. É importante escolher tarefas com componentes EEG contrastantes e de discriminação fácil.

Outro fator a considerar durante o treinamento é o componente EEG específico para usar. Potenciais corticais lentos, por exemplo, são uma resposta natural e, portanto, requerem menos tempo de treinamento para os usuários do que tentar controlar o seu ritmo *mu*. A escolha de tarefas cognitivas contrastantes acelera treinamento.

O método de treinamento determina o método de aquisição de sinal. Atividade neuronal gerada por tarefas cognitivas é restrita a certas áreas do cérebro. Isto permite que a aquisição de sinal ocorra com poucos eletrodos que abrangem regiões específicas. O método de condicionamento operante, no entanto, só pode trabalhar em um sistema BCI que usa eletrodos em todas as regiões do cérebro já que o local que vai gerar a atividade mental usada para controlar o dispositivo não é definido.

Processamento de sinais e técnicas de extração de características

O usuário é capaz de gerar sinais detectáveis voluntariamente para transmitir as suas intenções. Métodos de aquisição de sinais, no entanto, capturam ruídos gerados por atividades não relacionadas com a intenção do usuário, e esse ruído pode ser interno ou externo ao cérebro. As características apropriadas precisam ser extraídas através da maximização da relação sinal-ruído.

O objetivo do processamento e da extração de características (ou atributos) é descrever um item através de seus atributos, que devem ser muito semelhantes para os da

mesma categoria, mas muito diferentes para os itens de categorias distintas. Tal caracterização é feita por escolha de características mais relevantes dentro de inúmeras opções disponíveis. Este processo de seleção é necessário, porque características não relacionadas podem fazer com que os algoritmos de tradução apresentem generalizações pobres, aumentem a complexidade dos cálculos e exijam mais amostras de treinamento para atingir um determinado nível de precisão.

A) Remoção de ruídos

Os sinais cerebrais são capturados por vários eletrodos espalhados pelo escalpo e apresentados como séries temporais. Dessa forma, os métodos de processamento utilizados se concentram no domínio espacial, temporal ou ambos. Além disso, estudos mostraram que uma grande quantidade de ruído captado por EEG é proveniente de sinais que não são gerados pelo sistema nervoso central, como atividades musculares, especialmente os movimentos dos músculos faciais [Wolpaw et al., 2002].

Para minimizar o ruído no sinal é importante compreender as suas fontes. O ruído pode ser capturado através de fontes neurais quando componentes não relacionados com o sinal-alvo são capturados, ou pode ser gerado por fontes não-neurais tais como movimentos musculares, principalmente dos músculos faciais. Este tipo de ruído é especialmente importante, porque os sinais gerados por movimentos musculares são muito fortes e podem ser confundidos com o sinal-alvo. O problema é ainda mais complexo quando a frequência ou a amplitude do ruído e do sinal-alvo são semelhantes [Vallabhaneni et al., 2005].

Ainda com maior intensidade do que nos sinais de EEG, os ruídos não neurais são encontrados em sinais de EMG (eletromiograma), por este registrar as atividades elétricas presentes nos músculos. Instruções simples para o usuário para não mover os músculos ou desconsiderar os sinais que contêm artefatos podem ser usados, mas nem sempre são suficientes para eliminar este ruído.

Operações matemáticas, tais como transformações lineares e análise de componentes também são utilizadas para a remoção do artefato (Makeig *et al.*, 2000; Muller *et al.*, 2000 *apud* [Vallabhaneni et al., 2005]).

B) Características de métodos de extração de atributos

Blum e Langley (1997) *apud* [Vallabhaneni et al., 2005] criaram uma analogia entre algoritmos de extração ou seleção de atributos e técnicas de busca heurística que processam grandes quantidades de dados irrelevantes para encontrar e extrair algumas características relevantes. Eles são caracterizados como algoritmos projetados para a extração de atributos com base em quatro critérios.

O primeiro critério é a definição de um ou mais pontos de partida que também irão determinar a direção da busca (*forward* ou *backward*), bem como a definição de funções que decidem quais os estados seguintes (quais atributos ou características serão incluídos ou excluídos do conjunto). Os algoritmos podem começar com um conjunto vazio de atributos ou características e, sucessivamente, adicioná-los com base em uma função que atribui uma pontuação para atributos que melhor caracterizem o sinal. Este método é chamado de seleção para frente (*forward*). Outra opção é começar com todos os atributos disponíveis e remover certas características com base em uma função de pontuação. Este método é conhecido como a eliminação para trás (*backward*). Alguns algoritmos podem utilizar uma combinação de seleção *forward* seguido de eliminação *backward* ou vice-versa.

O segundo critério é a organização da busca (pode não ser eficiente fazer uma busca abrangente do espaço de características inteiro). Assim, algoritmos que utilizam técnicas de seleção gulosa, adição e eliminação, são usados para selecionar o próximo atributo que irá melhorar a pontuação sobre o conjunto de atributos atual até atingir uma pontuação determinada.

O terceiro critério é a estratégia utilizada para avaliar todos os subconjuntos possíveis de recursos. A maioria dos algoritmos tende a usar uma função de pontuação que reflete a capacidade de um atributo para diferenciar uma classe de outra. Muitos algoritmos pontuam atributos com base na teoria da informação ou contribuição para a precisão da classificação (em algoritmos embarcados ou *wrapper*, citados a seguir).

O quarto critério é a condição de parada da busca. Alguns algoritmos de extração de características param após um número pré-definido de iterações sem obter melhora na pontuação do conjunto de atributos selecionados. Outros continuam a busca, enquanto não há uma diminuição na pontuação do conjunto de atributos ou das taxas de classificação utilizando esses atributos. Outra opção utilizada é classificar cada um dos atributos com base em alguma função de pontuação e selecionando um ponto de interrupção em que

todos os atributos acima deste ponto são automaticamente selecionados.

C) Tipos de Métodos de Extração de características

Também discutido por Blum e Langley (1997) *apud* [Vallabhaneni et al., 2005], técnicas de extração de características podem ser divididas em três categorias. A primeira categoria é chamada algoritmos embarcados, onde a seleção de atributos é uma parte da tradução, ou classificação, dos conjuntos de características em comandos de controle. O processo de seleção de características adiciona ou remove atributos, para reduzir as taxas de erro na classificação, enquanto novas instâncias de treinamento são introduzidas. Algoritmos embarcados, no entanto, são de pouca utilidade quando há um alta taxa de variação entre características relevantes.

A segunda categoria é chamada de algoritmos de filtro, que seleciona características específicas antes e independente da etapa de classificação. Eles funcionam através da remoção de características irrelevantes (aqueles que fornecem dados redundantes ou com ruído) antes da técnica da classificação. Uma forma de filtragem envolve o cálculo de correlação de cada atributo com a função de destino e, em seguida, a seleção de um número fixo de características com as maiores pontuações. Outro método de filtragem envolve a derivação de ordem superior de atributos com base em características dos dados brutos e classificação destas características de ordem superior com base na quantidade de variância que explicar e selecionar um número fixo de características de maior pontuação.

A última categoria é chamada de algoritmos de *wrapper*, que seleciona os atributos, utilizando os algoritmos de tradução ou classificação mas antes de partir para a etapa classificação. Estes algoritmos utilizam o algoritmo de tradução como uma sub-rotina para estimar a precisão de um subconjunto específico de características. Este tipo de algoritmo é utilizado para um algoritmo de tradução por vez, e é particularmente útil com dados de treinamento limitados.

D) Processamento no domínio espacial e temporal

Técnicas de filtragem espacial são úteis para extração de características específicas de uma distribuição espacial dos eletrodos (McFarland *et al.*, 1997; Muller-Gerking *et al.*,

1999 *apud* [Vallabhaneni et al., 2005]). Em sistemas BCI que utilizam os ritmos *mu* ou *alfa*, a seleção de filtros espaciais podem afetar significativamente a relação sinal-ruído. Um filtro passa-alta espacial como a derivação bipolar calcula a primeira derivada espacial e enfatiza a diferença no gradiente de tensão em uma determinada direção. A superfície Laplaciana também age como um filtro passa-alta e pode ser aproximada pela subtração da média do sinal em quatro nós ao redor do sinal no nó de interesse (Hjorth, 1975 *apud* [Vallabhaneni et al., 2005]).

Técnicas de processamento no domínio temporal também são úteis para maximizar a relação sinal-ruído. Nestes métodos, o sinal é avaliado através de um certo período de tempo. Alguns métodos de processamentos no domínio temporal, como análise de Fourier, exigem segmentos de sinal mais longos, enquanto outros, como filtragem passa-banda ou análise auto-regressiva podem trabalhar com segmentos de tempo mais curto. Apesar de todos os métodos de processamento no domínio temporal funcionarem bem durante a análise BCI *offline*, alguns deles não são tão úteis quanto os métodos de processamento no domínio espacial durante a análise *online*, por causa da rápida resposta necessária [Wolpaw et al., 2002].

Técnicas de Tradução

Técnicas de tradução são algoritmos desenvolvidos com o objetivo de converter as características de entrada (variável independente) em comandos de dispositivo de controle (variável dependente) [Wolpaw et al., 2002]). Técnicas de tradução que são amplamente utilizadas em outras áreas de processamento de sinal são adaptadas para sistemas BCI.

Discutido por Wolpaw [Wolpaw et al., 2002], técnicas eficazes em sistemas BCI tem três níveis de adaptação. Primeiro, a técnica deve ser capaz de se adaptar à singularidade das características do sinal de cada usuário. Em segundo lugar, a técnica deve ser capaz de reduzir o impacto de variações espontâneas que ocorrem durante o uso regular, fazendo ajustes periódicos *online*. Finalmente, a técnica deve ser capaz de acolher e envolver a capacidade adaptativa do cérebro através de níveis crescentes de *feedback* para incentivar a geração características mais fortes no sinal.

Wolpaw [Wolpaw et al., 2002] sugeriram que o sucesso de uma técnica de tradução é determinado por três critérios. O primeiro critério é a seleção das características adequa-

das. Em outras palavras, as características extraídas devem transmitir com o máximo de fidelidade a intenção do usuário. O segundo critério é a capacidade de adaptação da técnica ao modo como o usuário controla as características do sinal. O critério final é a eficácia do método na tradução dos sinais em comandos de controle.

Existem vários tipos de algoritmos de tradução de características. Alguns utilizam características simples, como a amplitude ou a frequência. Outros utilizam características individuais, enquanto algoritmos avançados utilizam uma combinação de características espaciais e temporais produzidas por um ou mais processos fisiológicos. Algoritmos em uso atualmente incluem, mas não estão limitados a: classificadores linear, discriminante de Fisher e CSSD (*Common Spatial Subspace Decomposition*), classificadores com base na distância de Mahalanobis, redes neurais (NN - *Neural Networks*), máquinas de vetor de suporte (SVM - *Support Vector Machines*), e modelos ocultos de Markov (HMM - *Hidden Markov Models*) [Vallabhaneni et al., 2005].

2.3 Aprendizado de Máquina e Árvores de Decisão

Aprendizado de Máquina é uma área da Inteligência Artificial que trata de técnicas computacionais sobre o aprendizado e a construção de sistemas com a capacidade de adquirir conhecimento de forma automática.

“Um sistema de aprendizado é um programa de computador que toma decisões baseado em experiências acumuladas através da solução bem sucedida de problemas anteriores” [Monard and Baranauskas, 2003].

Existem três casos em que o aprendizado de máquina pode ser dividido: aprendizado por reforço, não- supervisionado e supervisionado [Russel and Norvig, 2004].

O aprendizado por reforço, ou através de recompensa, é a categoria mais geral das três. O agente de aprendizado por reforço deve aprender a partir das recompensas que recebe, e não sendo informado por um instrutor de qual a melhor atitude tomar. Por exemplo, se um agente tem uma perda muito grande de energia ao percorrer um caminho muito longo, isso fornece uma indicação de que ele não fez a melhor escolha. Na aprendizagem por reforço está incluído o subproblema de aprender como o ambiente funciona.

No aprendizado não-supervisionado as instâncias de entrada não possuem uma classificação. Um agente de aprendizagem não-supervisionada não aprende o que fazer, pois não possui a informação de qual é o estado desejado ou qual a ação correta a ser tomada [Russel and Norvig, 2004]. Esse método de aprendizado também é conhecido como aprendizado auto-supervisionado ou de auto-organização por que não requer saída desejada e/ou não precisa usar supervisores para seu treinamento, mas os dados são reorganizados de modo a que se formem classes ou agrupamentos de padrões.

No aprendizado supervisionado é fornecido ao algoritmo de aprendizado, ou indutor, um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido. Esse método envolve a aprendizagem de uma função a partir de suas entradas e saídas. O objetivo do indutor é, a partir das funções ou regras induzidas geradas com dados já rotulados, classificar novas instâncias que ainda não possuam esse rótulo.

2.3.1 Indução de Árvores de Decisão

Segundo Russel e Norvig [Russel and Norvig, 2004], a indução de árvores de decisão é uma das formas mais simples e bem sucedidas de algoritmos de aprendizagem.

A indução de árvores de decisão é um método de aprendizado supervisionado, já que os exemplos devem estar classificados antes de serem apresentados ao indutor. Mas se tais exemplos forem escassos, inconsistentes ou mal classificados o resultado pode não ser satisfatório, como diz [Monard and Baranauskas, 2003]:

“A indução é a forma de inferência lógica que permite obter conclusões genéricas sobre um conjunto particular de exemplos. Ela é caracterizada como o raciocínio que se origina em um conceito específico e o generaliza, ou seja, da parte para o todo. Na indução, um conceito é aprendido efetuando-se inferência indutiva sobre os exemplos apresentados. Portanto, as hipóteses geradas através da inferência indutiva podem ou não preservar a verdade.

Mesmo assim, a inferência indutiva é um dos principais métodos utilizados para derivar conhecimento novo e predizer eventos futuros. Foi através da indução que Arquimedes descobriu a primeira lei da hidrostática e o princípio da alavanca, que Kepler descobriu as leis do movimento planetário, que Darwin

descobriu as leis da seleção natural das espécies.

Apesar da indução ser o recurso mais utilizado pelo cérebro humano para derivar conhecimento novo, ela deve ser utilizada com cautela, pois se o número de exemplos for insuficiente, ou se os exemplos não forem bem escolhidos, as hipóteses obtidas podem ser de pouco valor.”

Algoritmos que induzem árvores de decisão pertencem à família de algoritmos TDIDT (*Top Down Induction of Decision Trees*). Tais algoritmos utilizam uma abordagem de divisão e conquista, e a árvore é induzida da raiz para as folhas.

Segundo [de Araújo, 2004]:

“Nota-se que uma árvore de decisão representa uma disjunção de conjunções de testes em atributos de instâncias, onde cada ramo completo representa uma conjunção de atributos, enquanto os nós provêm disjunções. Um algoritmo de aprendizado para uma árvore de decisão deve descobrir quais atributos devem ser testados em quais nós de modo a aprender o conceito. Assim, uma árvore de decisão é construída quebrando um problema complexo de decisão em diversas decisões mais simples (SAFAVIAN; LANDGREBE, 1991), realizadas nos nós.”

Uma árvore de decisão é uma estrutura de dados que pode ser definida recursivamente como:

- um nó folha que corresponde a uma classe ou
- um nó de decisão que contém um teste sobre algum atributo. Para cada resultado do teste existe uma aresta para uma subárvore. Cada subárvore tem a mesma estrutura que a árvore.

Por exemplo, para decidir se o dia está apropriado para jogar uma partida de tênis costuma-se analisar algumas condições meteorológicas (*aparência*, que pode assumir os seguintes valores: ensolarado, nublado ou chuvoso; *umidade* tem os valores: alta, normal ou baixa; *vento* com valores: forte ou fraco e *temperatura* assumindo os valores: alta, média, baixa), tais condições são os atributos e as classes são as possíveis decisões (sim ou não). Um conjunto de instâncias, que é a combinação desses atributos e a decisão

adequada, pode ser visto na Tabela 2.1. A árvore de decisão induzida com base nesse dados é apresentada na Figura 2.13.

Tabela 2.1: Conjunto de instâncias para tomada de decisão.

	aparência	umidade	vento	temperatura	jogar
1	sol	alta	fraco	media	não
2	sol	alta	forte	media	não
3	sol	normal	fraco	media	sim
4	sol	normal	forte	media	sim
5	nublado	alta	fraco	alta	não
6	nublado	alta	forte	media	não
7	nublado	normal	fraco	media	não
8	nublado	normal	forte	baixa	não
9	chuva	alta	fraco	alta	sim
10	chuva	normal	fraco	media	sim
11	chuva	normal	forte	baixa	não
12	chuva	alta	forte	media	não

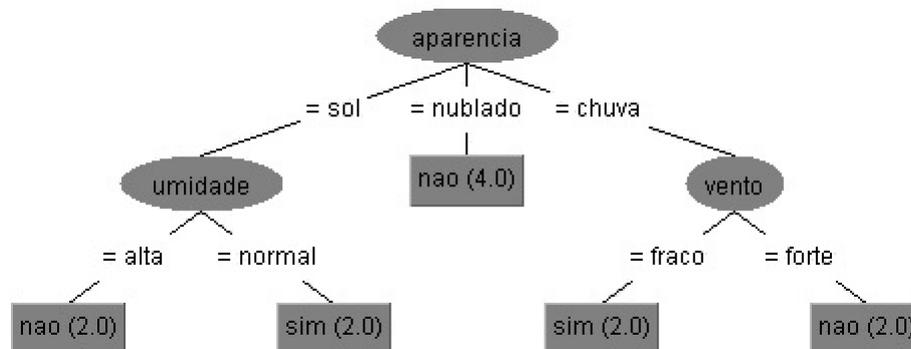


Figura 2.13: Árvore de decisão para decidir jogar ou não uma partida de tênis.

Um dos algoritmos TDIDT mais conhecidos é o ID3 (Induction of Decision Tree), de Ross Quinlan. Sendo um algoritmo TDIDT, constrói a árvore de cima para baixo e em cada nó é tomada uma decisão de qual atributo deve-se testar. Tal decisão é tomada de forma gulosa, ou seja, a melhor naquele determinado momento. Segundo [de Souza Vasconcelos, 2002]:

“Uma série de melhoramentos do ID3 culminou com o algoritmo chamado C4.5. Os melhoramentos incluem métodos para lidar com atributos numéricos, valores não informados, dados com ruído, poda de árvores (*‘prunning’*) e geração de regras SE - ENTÃO a partir das árvores.”

Escolha do atributo preditivo para o nó da árvore

A escolha do melhor atributo ocorre de forma a utilizar aquele que tenha melhor capacidade isolada de classificar os exemplos. Existem diferentes tipos de critérios de seleção, sendo esta uma das variações entre os diversos algoritmos de indução de árvores de decisão. A maioria dos algoritmos de indução de árvores de decisão trabalha com funções de divisão univariável, ou seja, cada nó interno da árvore é dividido de acordo com um único atributo. Nesse caso, o algoritmo tenta encontrar o melhor atributo para realizar essa divisão. Tais algoritmos buscam um atributo para ser o nó-pai (da árvore ou subárvores), de modo a minimizar ao máximo o grau de impureza dos nós-filhos. O grau de impureza de um nó será nulo se todos os exemplos nele pertencem a mesma classe. E o nó será totalmente impuro se houver o mesmo número de exemplos para cada classe possível [ATTUX and ZUBEN, 2010].

No exemplo citado anteriormente, que decide se o dia é apropriado para a prática de tênis, o atributo *aparência* foi escolhido para ser o nó pai, pois melhor dividia o conjunto de dados.

A seguir, são apresentadas as medidas mais utilizadas para a seleção da melhor divisão, utilizadas por Quinlan em seus algoritmos.

Ganho de informação

Uma das medidas baseadas em impureza é o Ganho de Informação, o qual usa a entropia como medida de impureza, o algoritmo ID3 utiliza essa medida. Para determinar o quão boa é uma condição de teste realizada, é necessário comparar o grau de entropia do nó-pai (antes da divisão) com o grau de entropia dos nós-filhos (após a divisão). O atributo que gerar uma maior diferença é escolhido como condição de teste. O ganho é dado pela Equação 2.1, na forma [ATTUX and ZUBEN, 2010]:

$$\text{ganho} = \text{entropia} - \sum_{j=1}^n \left[\frac{N(v_j)}{N} \text{entropia}(v_j) \right] \quad (2.1)$$

onde n é o número de valores do atributo, ou seja, o número de nós-filhos, N é o número total de objetos do nó-pai e $N(v_j)$ é o número de exemplos associados ao nó-filho (v_j). O grau de entropia é definido pela Equação 2.2.

$$\text{entropia}(\text{nó}) = - \sum_{i=1}^c p(i/\text{nó}) \times \log_2 [p(i/\text{nó})] \quad (2.2)$$

onde $p(i/\text{nó})$ é a fração dos registros pertencentes à classe i no nó, e c é o número de classes. A entropia está relacionada a organização da informação, quanto maior a entropia mais uniforme está a distribuição, ou seja quanto menor a entropia dos nós-filhos menos classes diversas terá naquele nó.

Um problema relacionado a essa técnica é que na escolha do atributo que maximiza o ganho de informação, terão prioridade aqueles que tiverem mais valores possíveis. Um exemplo é citado por [ATTUX and ZUBEN, 2010]:

“O critério de ganho seleciona como atributo-teste aquele que maximiza o ganho de informação. O grande problema ao se utilizar o ganho de informação é que ele dá preferência a atributos com muitos valores possíveis (número de arestas).”

Um exemplo claro desse problema ocorreria ao utilizar um atributo totalmente irrelevante (por exemplo, um identificador único). Nesse caso, seria criado um nó para cada valor possível, e o número de nós seria igual ao número de identificadores. Cada um desses nós teria apenas um exemplo, o qual pertence a uma única classe, ou seja, os exemplos seriam totalmente discriminados. Assim, o valor da entropia seria mínima porque, em cada nó, todos os exemplos (no caso um só) pertencem à mesma classe. Essa divisão geraria um ganho máximo, embora seja totalmente inútil.

Razão de Ganho

Uma solução proposta por Quinlan (1993) foi a Razão de Ganho, ou seja, o ganho relativo a entropia de cada nó, como critério de avaliação. A razão de ganho é definida pela Equação (2.3), na forma:

$$\text{razão_de_ganho (nó)} = \frac{\text{ganho}}{\text{entropia (nó)}} \quad (2.3)$$

De acordo com equação acima, não existe razão de ganho quando entropia é zero, mas ainda favorece os atributos que possuem menor entropia. De acordo com [ATTUX and ZUBEN, 2010]:

“Em QUINLAN (1988), é sugerido que a razão de ganho seja realizada em duas etapas.

Na primeira etapa, é calculado o ganho de informação para todos os atributos. Após isso, considerar apenas aqueles atributos que obtiveram um ganho de informação acima da média, e então escolher aquele que apresentar a melhor razão de ganho.

Dessa forma, Quinlan mostrou que a razão de ganho supera o ganho de informação tanto em termos de acurácia quanto em termos de complexidade das árvores de decisão geradas.”

2.3.2 Validação das Árvores de Decisão

A validação das árvores de decisão é feita na forma de divisão do conjunto de exemplos a fim de que parte deste seja utilizada para o treinamento das árvores e outra parte para testar a capacidade da árvore obtida de classificar exemplos que ela desconhece. Dentre as tantas técnicas de validação existentes, a utilizada nesse trabalho é a Validação Cruzada.

Validação Cruzada

O método de validação cruzada consiste na divisão do conjunto de exemplos em n partes iguais, utilizando $n-1$ partes para treinar a árvore e a última parte para testar. Esse processo é repetido n vezes, deixando, a cada rodada, uma parte diferente para testar. Após as n repetições serão feitas as estimativas de erro.

Matriz de Confusão

A matriz de confusão é uma forma de analisar a classificação dos dados. Ela demonstra quantas instâncias da base de dados utilizada são classificadas corretamente pelo mo-

Tabela 2.2: Matriz de Confusão do exemplo "jogar tênis".

a	b	
4	0	a = sim
1	7	b = não

delo construído (representados na diagonal principal da matriz) sendo que as outras são classificadas incorretamente. A Tabela 2.2 apresenta um exemplo de matriz de confusão gerada a partir dos dados da Tabela 2.1, sobre decidir jogar tênis. As linhas da matriz mostram quantas instâncias de cada classe estão no banco de dados (4 da classe $a = \text{sim}$ e 8 da classe $b = \text{não}$) e as colunas mostram quantas instâncias foram classificadas em cada classe (5 na classe a , 4 corretas e 1 incorreta; e 7 na classe b , todas corretas).

Capítulo 3

Estado da Arte em Sistemas BCI

Com a combinação de mais modos de captação de sinais, métodos de extração de características e técnicas de tradução, o número de sistemas BCI diferentes está crescendo rapidamente. Pesquisas são tipicamente iniciadas em sistemas BCI *offline*, onde a aquisição do sinal é seguida por extração de características e tradução, em etapas separadas. Este tipo de trabalho permite que os pesquisadores refinem e testem algoritmos de extração e tradução de características antes de utilizá-las nos dispositivo que se pretende aplicar tais técnicas. Em última análise, no entanto, uma técnica BCI precisa ser testada *online* para avaliar o seu desempenho.

Outra importante classificação dos sistemas BCI é em *externo* ou *interno*. Sistemas BCI externos, também conhecidos como sistemas BCI *exógenos*, trabalham com base em estímulos que não estão sob o controle do usuário para a geração do sinal. Estes sistemas utilizam componentes evocados pelos estímulos externos, tais como VEP. Sistemas BCI exógenos não requerem treinamento intensivo, mas exigem um ambiente controlado. Sistemas BCI internos, também conhecidos como sistemas BCI *endógenos*, trabalham com evento programado ou estímulo interno. Estes sistemas utilizam componentes evocados por tarefas, como a imagética motora, e precisam de um significativo treinamento do usuário [Wolpaw et al., 2002].

Além disso, os sistemas BCI podem ser classificados quanto aos métodos de aquisição do sinal, que podem ser específicos ou não. Sistemas BCI específicos usam sinais gravados em posições bem escolhidas e onde o efeito é esperado, como na realização de tarefas cognitivas. Sistemas BCI não específicos, entretanto, usam sinais gravados a partir de

eletrodos em todo o cérebro, como no método condicionamento operante.

Nos últimos 20 anos, os pesquisadores criaram vários modelos de sistemas de trabalho BCI. Em um desses sistemas, eles criaram um BCI que poderia ser usado para escrever textos por seleção de letras, palavras e comandos de um *display*. O sistema utilizado apresentava uma matriz 6x6 em uma tela com letras piscando aleatoriamente enquanto o usuário pensava na letra que ele deseja utilizar. Quando a letra esperada pisca na tela, o usuário deve gerar um componente P300 detectável. Como o sistema era focado em detectar somente P300, a aquisição de sinais foi feita em eletrodos específicos. Extração de características gerou 36 vetores de características, um para cada quadrado na tela. Como o P300 tem um tempo fixo de resposta ao estímulo, quando uma determinada linha ou coluna brilha, uma janela de 600 ms do sinal é adicionada a cada um dos vetores de características correspondentes. A tradução foi feita através de um *ranking* de todos os vetores de características, usando vários métodos. A letra, palavra ou comando correspondente ao vetor de características mais bem classificado é designado como a intenção do usuário [Farwell and Donchin, 1988]).

Outros pesquisadores desenvolveram um sistema BCI que permitia os usuários com deficiências físicas graves se comunicassem soletrando palavras através de códigos específicos que formam comandos pré-definidos. Dependendo da tarefa cognitiva realizada pelo usuário, o sistema poderia detectar diferenças em níveis de potência espectral em regiões do cérebro. Como as tarefas cognitivas não foram definidas, os sinais foram captados por eletrodos que cobrem os lobos parietal e occipital. A extração de características gerou dois vetores de características usando Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*) e método de estimação espectral autorregressivo (AR - *Auto-regressive*) e seguido da execução através de um filtro passa-banda em quatro bandas de frequência. Um terceiro vetor foi gerado através de coeficientes AR dos sinais nas quatro bandas de frequência. Um classificador Bayesiano quadrático foi utilizado na tradução das características com base na potência ou coeficientes AR das características (Kerin e Aunon, 1990, *apud* [Vallabhaneni et al., 2005]).

Pesquisas mais recentes estão sendo desenvolvidas em vários centros ao redor do mundo. O trabalho desenvolvido por Kroupi *et al.* (2011) da *École Polytechnique Fédérale de Lausanne - EPFL*, na Suíça, apresenta um método para a remoção de ruído

proveniente de movimentos oculares em sinais de EEG. Os sinais utilizados foram coletados de 9 indivíduos que executaram tarefas de imaginação do movimento das mãos, pés e língua. O estudo faz uma comparação entre a utilização da análise de componentes independentes e a filtragem adaptativa, concluindo que o primeiro é mais robusto porém mais lento, podendo ser utilizado em abordagens *offline*, enquanto o segundo é rápido mas menos preciso e pode ser utilizado em algumas abordagens em que a velocidade é mais importante que a precisão [Kroupi et al., 2011].

O trabalho de Waldert *et al.* (2008) da *University of Tübingen*, na Alemanha, apresentou um estudo sobre sinais de EEG e MEG durante o movimento da mão a fim de analisar a direção do movimento. A pesquisa foi realizada com sinais cerebrais de 9 indivíduos destros durante o movimento de um *joystick*. Os dados foram filtrados utilizando um filtro passa-alta de 5 Hz para remover ruídos, na análise dos dados foram utilizadas FFT, análise do discriminante linear regularizada, filtro passa-baixa de *Butterworth*. Ainda utiliza a Entropia de Shannon para quantificar a informação extraída dos sinais. O estudo demonstrou uma modulação nos sinais tanto nos períodos de descanso quanto de movimento. Essa modulação foi mais forte nas áreas motoras do cérebro. Houve 67% de acerto e se concluiu que tanto sinais de EEG quanto de MEG podem gerar bons resultados [Waldert et al., 2008].

Também existem no Brasil grupos de pesquisa em sistemas BCI. Um deles é da Universidade Federal do Espírito Santo (UFES). O trabalho de Garcia *et al.* (2008) apresenta o uso de mapas auto-organizáveis (SOM - *Self-organizing map*) para a detecção de estados mentais para utilização em BCI. Os sinais utilizados foram coletados por EEG de uma mulher, que tem a tarefa de controlar uma barra, presente no monitor de vídeo a sua frente, utilizando a imaginação do movimento da mão esquerda e da mão direita. Foi utilizado o espectro de potências para gerar vetores de características que serviram de entrada para um mapa auto-organizável de dimensão 12x12. Os resultados apresentaram acerto acima de 83% [Garcia et al., 2008].

O trabalho de Ranaudo *et al.* (2011) da Universidade Federal do Rio de Janeiro (COPPE/UFRJ) apresentou um sistema para detecção de respostas auditivas em tempo real. Os sinais utilizados são de EEG, de 6 indivíduos normais adultos em uma cabine isolada, estimulados auditivamente, com frequência diferente para cada ouvido. Para a

detecção das respostas do cérebro foram utilizadas as técnicas de magnitude quadrática de coerência e coerência múltipla. Os sinais de EEG foram enviados ao computador via *ethernet* e foram aplicadas as técnicas com auxílio do *software Matlab*. O experimento mostrou resultados de classificação com tempo de 13s para testes com sinais de 3 eletrodos simultaneamente, com o aumento no número de sinais o tempo aumenta [Ranaudo et al., 2011].

Foram encontrados trabalhos que analisam especificamente a utilização de árvores de decisão para a classificação de sinais cerebrais para sistemas BCI, como os apresentados a seguir.

O trabalho de Koprinska (2010) apresenta uma avaliação de 5 métodos de extração de características e 10 algoritmos de classificação. Os dados utilizados são imaginação de movimentos das mãos direita e esquerda, da língua ou dos pés. Os 10 classificadores utilizados foram: 1R (uma regra com base nos valores de um atributo), Árvore de Decisão (DT) (utilizou o J48), K-vizinhos mais próximos (k-NN)(algoritmo baseado em instância clássica; normalizando a distância euclidiana com $k = 5$), Naive Bayes (classificador padrão probabilístico), funções de base radial (RBF)(rede neural de duas camadas, que utiliza gaussianas como funções de base na primeira camada (número e centros estabelecidos pelo algoritmo K-means) e uma camada linear), máquinas de vetor de suporte (SVM), regressão logística (LogR)(regressão linear padrão), Ada2Boost (Adab)(produz uma série de classificadores iterativamente onde novos classificadores focam os casos que foram mal classificados pelos classificadores anteriores), Bagging(Bagg) (Amostragem aleatória com reposição que gera conjuntos de treinamento para os classificadores), floresta aleatória (RF)(Um conjunto de árvores de decisão baseadas agrupamento e seleção de recursos aleatória). Os melhores classificadores, com acertos superiores a 80% foram SVM, AdaBoost, Bagg, RBF e RF. Três desses classificadores (AdaBoost, RBF, RF) utilizam o algoritmo J48 para geração de árvores de decisão [Koprinska, 2010].

O trabalho de Aparna *et. al.* (2010) apresenta um sistema que permite a classificação de tarefas mentais baseado em dados estatísticos obtidos no domínio da frequência usando transformada discreta de cosseno e extração de características úteis a partir da frequência e a aplicação de algoritmos de árvore de decisão para a classificação. Os dados utilizados são de imaginação de movimentos dos dedos ou da língua. Os classificadores utilizados foram os algoritmos para geração de árvores de decisão QUEST e CART, que fazem divisões

binárias dos dados. Foi aplicada a transformada discreta de cosseno para converter os dados de séries de tempo para o domínio da frequência. O filtro Butterworth foi usado como um filtro passa banda para eliminar frequências fora da banda desejada de 5 Hz a 30 Hz. O valor máximo, o valor mínimo e a média foram calculados para cada um dos canais, para todas as épocas, e foram registados como características. Os dados foram usados como a entrada para o classificador de árvore de decisão. Este trabalho concluiu que as árvores de decisão são capazes de classificar razoavelmente bem no método proposto e o CART (81.3%) teve um desempenho melhor do que QUEST (78.4% de acerto) no método de pré-processamento proposto [Aparna et al., 2010].

Capítulo 4

Materiais e Métodos

Este capítulo apresenta os materiais (*software*, equipamento, especialista) que foram utilizados e como cada etapa (Figura 4.1) deste trabalho foi desenvolvida.

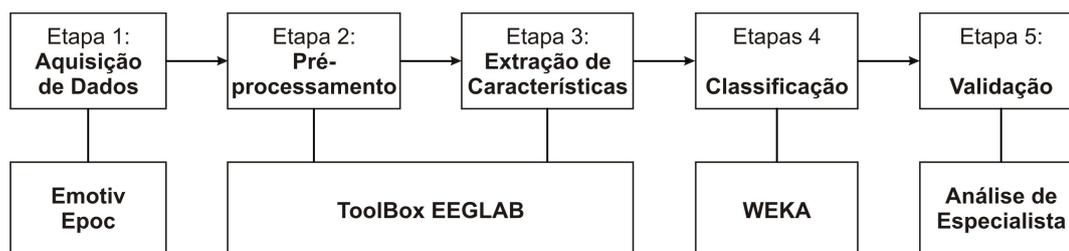


Figura 4.1: Etapas da realização do trabalho e o *software* utilizado em cada uma delas.

4.1 Aquisição dos Dados

Os sinais cerebrais analisados foram coletados de 3 sujeitos, alunos da oitava série do ensino fundamental de uma escola da cidade de Rio Grande-RS, com idade de 13 anos, sem diagnóstico de qualquer transtorno de aprendizagem e com quociente de inteligência considerado na média para essa idade. O projeto com o título *Análise e Classificação de Sinais Cerebrais para Utilização em Sistemas BCI* foi encaminhado ao CEPAS (Comitê de Ética em Pesquisa na Área da Saúde) em novembro de 2012, com CAAE (Certificado de Apresentação para Apreciação Ética) número 11354612.5.0000.5324, obteve aprovação no dia 28/12/2012 com número de parecer 182.255.

A coleta de dados foi realizada no CEAMECIM (Centro de Estudos Ambientais, Ciên-

cias e Matemática) da FURG, em janeiro de 2013, durante 4 dias consecutivos, utilizando o equipamento *Epoc* da *Emotiv* (posteriormente apresentado), de propriedade da professora Fernanda de Carvalho, co-orientadora deste trabalho.

Foi solicitado a cada aluno que abrisse e fechasse a mão, segurando uma bola durante um minuto, primeiro com a mão esquerda e depois com a mão direita. Em seguida foi solicitado que somente imaginasse abrir e fechar a mão, também por um minuto com a mão direita e um minuto com a mão esquerda. Entre cada tarefa houve uma pausa de aproximadamente 30 segundos.

Os arquivos que apresentam os sinais de realização do movimento não serão utilizados nesse trabalho, mas acreditou-se, que se os sujeitos primeiro realizassem a tarefa seria mais fácil a sua imaginação, pois é uma “dica” de evocação da memória procedimental. Esses sinais foram salvos, podendo ser usados em trabalhos, onde por exemplo, sejam comparados o desempenho dos algoritmos na imaginação e realização das tarefas, e quais eletrodos estão envolvidos em cada uma das tarefas.

4.1.1 Emotiv Epoc

A aquisição de sinais cerebrais requer equipamentos específicos e, na maioria das vezes, com um alto custo, os quais são adquiridos por hospitais, clínicas e laboratórios, para fins de exames clínicos, ou por centros de pesquisas que concentram seus estudos na área de sinais cerebrais. Alguns equipamentos estão sendo comercializados para consumidores finais, como controladores de jogos.

Um desses equipamentos é o *Epoc* da *Emotiv*¹, cujo slogan é “você pensa, portanto, você pode”, e intitula-se como uma interface nova e revolucionária para interação homem-computador. Ele é baseado em torno do *headset* (Figura 4.2) para gravar sinais de EEG e um *software* que processa e analisa os dados.

O equipamento permite o monitoramento de 14 canais (além dos pontos de referência CMS/DRL - *Common Mode Sense/Driven Right Leg*, terminais P3/P4), a aquisição de sinais neurais e o processamento através de uma interface de comunicação sem fio. Os terminais de captação seguem o padrão internacional “10-20” de posicionamento, localizados nos seguintes pontos: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8,

¹<http://www.emotiv.com>



Figura 4.2: *Headset* de coleta de dados *Epoc*.

AF4 (ver Figuras 2.6 e 4.3)[Miguel, 2010].

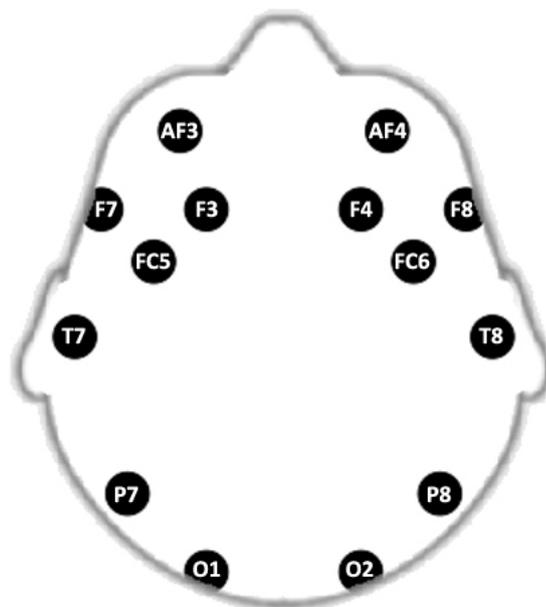


Figura 4.3: Eletrodos utilizados no *Epoc*, no padrão internacional “10-20”.

A bateria de lítio garante uma autonomia de 12 horas e o aparelho ainda conta com um giroscópio. A *Emotiv* oferece 6 kits de desenvolvimento de *software* diferentes que concedem o controle sobre a API e as bibliotecas de detecção e vêm com até 4 programas diferentes [Szafrir, 2009].

A edição de pesquisa inclui o Painel de Controle Emotiv, EmoComposer (um emulador

para simular sinais de EEG), EmoKey (uma ferramenta para o mapeamento de vários eventos detectados pelo *headset* em teclas), o *testbench* e uma API que permite a captura de dados brutos de EEG a partir de cada sensor individual.

O Painel de Controle Emotiv é uma interface gráfica que funciona como uma porta de entrada para usar o *headset*. Ele supervisiona a conexão com o *headset*, realiza o pré-processamento, classifica os sinais de entrada, fornece um *feedback* para o usuário e permite ao utilizador criar um perfil com pensamentos e ações. O Painel de Controle inclui as suítes *Expressiv*, *Affectiv* e *Cognitiv*, bem como um emulador de mouse que permite ao usuário controlar o mouse, movendo a cabeça e utilizando o giroscópio do *headset*.

A suíte *Expressiv* é projetada para medir expressões faciais com base na leitura de EEG/EMG e é uma forma inovadora na utilização de artefatos que geralmente são simplesmente filtradas de sistemas de EEG. A suíte *Expressiv* pode reconhecer 12 ações: piscar os olhos, piscar o olho direito ou esquerdo, olhar para a direita ou esquerda, levantar a testa, franzir a testa, sorrir, fechar a cara, mexer a boca para a direita ou esquerda e rir. Ele retorna um *feedback*, combinando os sinais de entrada e passando para um avatar simulando as expressões do usuário (Figura 4.4).

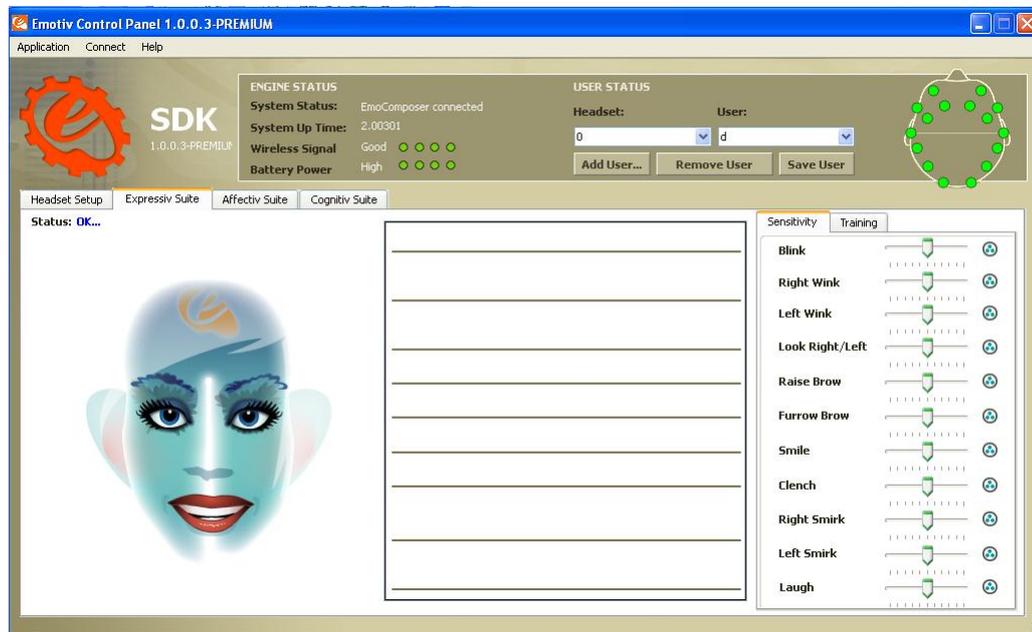


Figura 4.4: Suíte *Expressiv* do sistema Emotiv, que mostra o avatar dando um *feedback* para o usuário [Szafir, 2009]

A suíte *Affectiv* monitora os estados emocionais do usuário. Pode medir o tédio, frustração, meditação, excitação instantânea e emoção a longo prazo (Figura 4.5). A suíte *Cognitiv* monitora e interpreta os pensamentos conscientes do usuário. Ele pode medir 13 pensamentos ativos: empurrar, puxar, levantar, baixar, esquerda, direita, girar à esquerda e direita, girar no sentido horário e anti-horário, girar para frente e trás, e desaparecer, assim como o estado neutro ou relaxado. O *software Emotiv* detecta esses pensamentos usando uma ferramenta do *software* proprietário. Este *software* utiliza os sinais coletados pelos eletrodos como entrada de uma rede neural para tentar classificar os sinais como um dos 13 pensamentos de ação pré-estabelecidos no *software*. Os dados, relacionados aos pensamentos, presentes no protótipo foram recolhidos antes do lançamento do *headset* a partir de centenas de casos de teste e servem de base para a classificação. Pensamentos nas ações específicas devem ser treinados antes do uso e o usuário pode relacionar pensamentos diferentes para as ações pré-programadas (ou seja, o treinamento do comando “empurrar” pensando “azul”). No entanto, isso pode diminuir a precisão de reconhecer os pensamentos e aumentar o tempo de treinamento uma vez que esses pensamentos não vão igualar-se aos pensamentos que o *software* inicialmente espera. O *software* fornece um *feedback* sob a forma de um cubo flutuante que responde aos pensamentos reconhecidos (Figura 4.6).

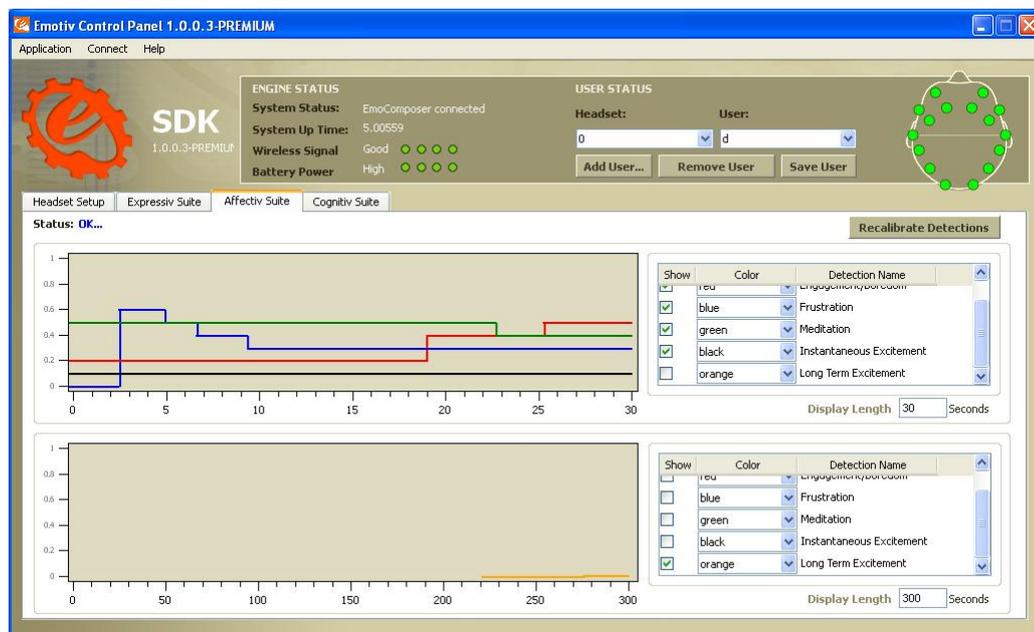


Figura 4.5: Suíte *Affectiv* do sistema Emotiv, que mostra o estado emocional do usuário [Szafir, 2009].

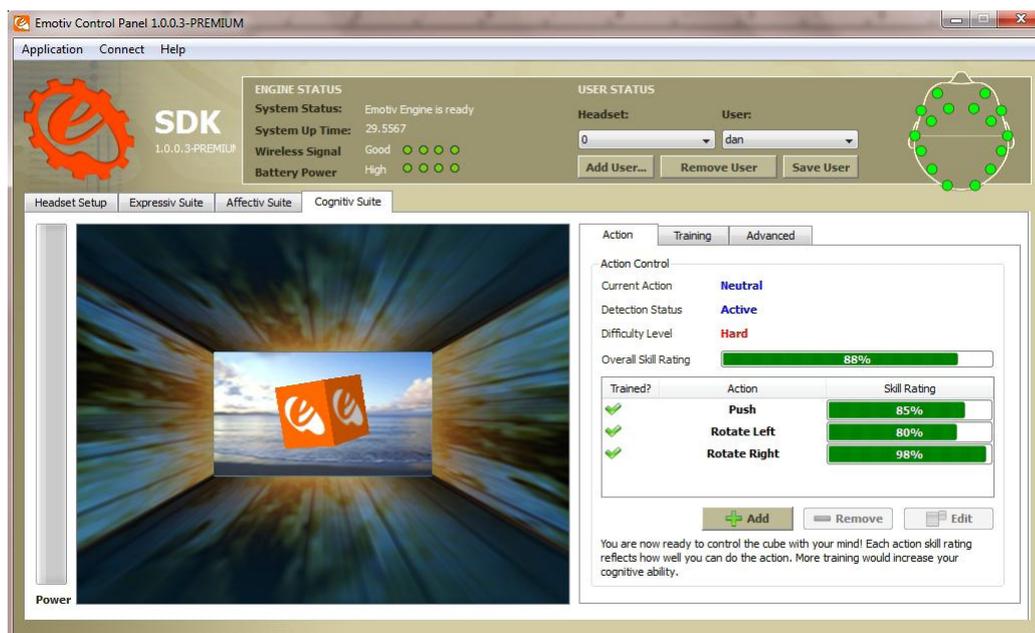


Figura 4.6: Suíte *Cognitiv* do sistema Emotiv, que mostra um cubo que obedece aos comandos do usuário [Szafir, 2009].

Atualmente, a suíte *Cognitiv* pode distinguir entre quatro pensamentos diferentes simultaneamente. Esse limite ocorre devido a problemas de usabilidade, pois a adição de pensamentos podem aumentar muito a dificuldade de usar a suíte *Cognitiv* de forma eficaz. Apesar disso, a Emotiv está atualmente considerando aumentar o limite de reconhecimento simultâneo [Szafir, 2009].

4.2 Pré-processamento dos Sinais e Extração de Características

Como mencionado no início deste capítulo, os sinais de realização dos movimentos não foram utilizados neste trabalho. Então, quando forem citados sinais cerebrais está se tratando somente dos sinais de imaginação de movimentos.

O pré-processamento dos sinais foi feito no EEGLAB, uma ToolBox para o MATLAB (apresentado na subseção a seguir). Cada um dos sinais foi salvo em formato EDF contendo 36 canais, pois o *software* do *Epoc* guarda, além do sinal dos 14 eletrodos do equipamento, uma série de parâmetros, como a qualidade de cada um dos sinais, os eixos

X e Y do equipamento em cada instante, entre outros. Cada sinal foi carregado no EEGLAB, onde foram retirados os canais que não eram de interesse, sendo salvos somente os 14 sinais dos eletrodos.

A extração de características foi feita de forma temporal, onde cada sinal foi filtrado nas bandas de frequência *delta* (0 a 4 Hz), a banda *teta* (4.01 a 8 Hz), *alfa* (8.01-13 Hz) e *beta* (13.01 a 30 Hz).

Cada sinal gerou 5 arquivos, um sem filtragem, e um para cada um dos 4 filtros. Os arquivos também são salvos em formato EDF pelo EEGLAB. Para a utilização no *software* WEKA, que faz a classificação dos dados, esses arquivos precisam ser CSV, para tanto foi utilizado o Polyman².

Depois desse processo, os arquivos CSV continham o sinal da tarefa imaginação da mão esquerda e imaginação da mão direita, separadamente. Então, foram mesclados no *software* Excel, da Microsoft. No Excel foram selecionadas 8 mil instâncias de cada tarefa, gerando arquivos com 16 mil instâncias. Além disso, foi inserido mais um atributo, uma etiqueta, para identificar se aquela instância era imaginação do movimento da mão direita (imaD) ou se era imaginação do movimento da mão esquerda (imaE), pois árvores de decisão são classificadores supervisionados, portanto precisam desse atributo para saber quais classes estão sendo classificadas.

4.2.1 EEGLAB

EEGLAB é um pacote de ferramentas utilizado no Matlab para o processamento de dados de EEG, MEG e outros dados eletrofisiológicos, contínuos e relacionados a eventos incorporando análise de componentes independentes (ICA), análise de tempo/frequência, rejeição de ruídos, estatísticas relacionadas a eventos e vários modos úteis de visualização de dados [Delorme and Makeig, 2004].

EEGLAB oferece uma interface gráfica interativa (GUI) (Ver Figura 4.7) que permite aos usuários, de forma flexível e interativa, processar alta densidade de dados de EEG e outros sinais cerebrais. Também incorpora vários tutoriais e janelas de ajuda, além de uma função de histórico de comando que facilita a transição dos usuários da GUI de exploração de dados para a criação e execução de lote ou scripts personalizados de análise

²<http://www.edfplus.info/downloads/downloads.html>

de dados.

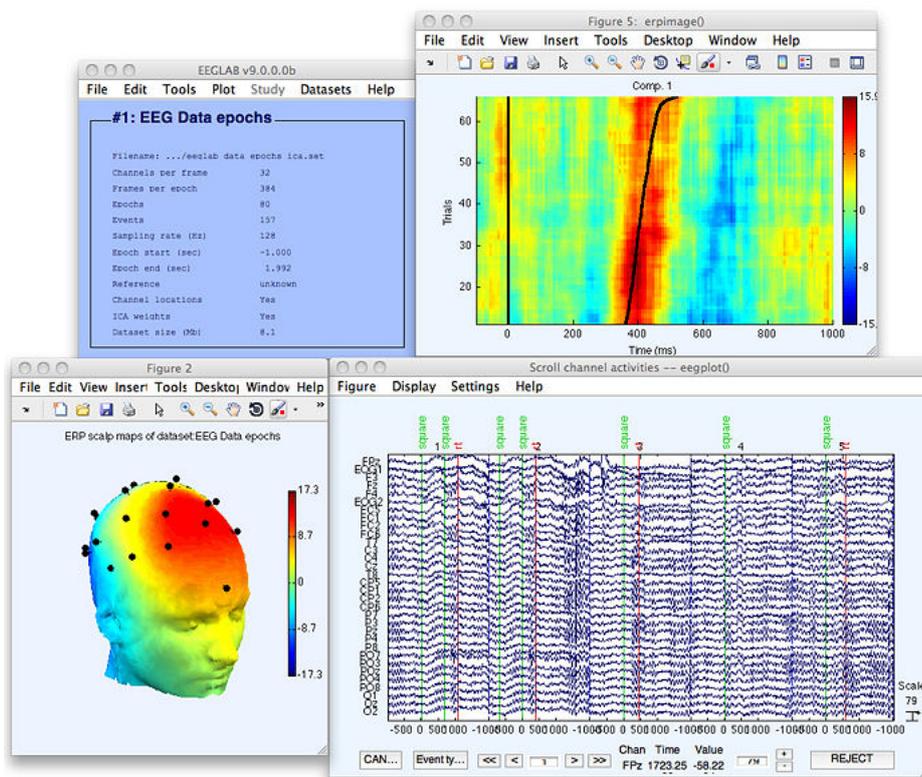


Figura 4.7: Telas do *software* EEGLAB

EEGLAB oferece uma riqueza de métodos para visualizar e modelar a dinâmica de eventos relacionados com o cérebro, tanto no nível de conjuntos de dados indivíduo e/ou através de uma coleção de conjuntos de dados reunidos em um EEGLAB *studysset*.

Para usuários experientes Matlab, EEGLAB oferece um ambiente de programação estruturada para armazenar, acessar, medir, manipular e visualizar dados de EEG. Para programadores pesquisadores e desenvolvedores, o Toolbox oferece uma extensível plataforma de código aberto, através do qual eles podem compartilhar novos métodos com a comunidade científica mundial através da publicação de funções EEGLAB *plug-in* que aparecem automaticamente no menu EEGLAB de usuários que baixá-las.

4.3 Classificação

Os dados contém duas classes, uma referente a tarefa de imaginação do movimento da mão direita (com a etiqueta ImaD) e outra referente a mesma tarefa com a mão esquerda (com

a etiqueta ImaE). Cada arquivo apresenta 16 mil instâncias, 8 mil para cada classe. Cada instância contém 14 atributos além da etiqueta, referente aos sinais cerebrais coletados pelos 14 eletrodos. São eles: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4. A Figura 4.8 apresenta exemplos de instâncias do banco de dados. Para classificar esses dados foi utilizado o Algoritmo J48 presente na versão 3.6 do *software* WEKA.

AF3[μ V]	F7[μ V]	F3[μ V]	FC5[μ V]	T7[μ V]	P7[μ V]	O1[μ V]	O2[μ V]	P8[μ V]	T8[μ V]	FC6[μ V]	F4[μ V]	F8[μ V]	AF4[μ V]	TAREFA
4063	-199	4203	-64	4106	-30	4787	154	4006	131	4490	-105	4280	336	imaE
4086	-191	4217	-70	4111	14	4815	140	4003	154	4489	-110	4294	-319	imaE
4063	-197	4203	-60	4100	-63	4784	157	4008	137	4489	-109	4277	330	imaD
4092	-194	4231	-72	4115	15	4815	137	4009	158	4498	-103	4302	-307	imaE

Figura 4.8: Exemplos de instâncias do banco de dados.

Utilizando o Algoritmo J48 (apresentado na subseção a seguir) foram geradas 4 árvores de decisão para cada um dos 60 conjuntos de dados (3 sujeitos \times 4 dias \times 5 modos de filtragem (1 sem filtro + 4 bandas)).

As 4 árvores geradas para cada conjunto de dados diferem entre si somente no número de instâncias necessárias para a formação de uma folha. Foram feitas árvores com no mínimo 2, 200, 500 e 1000 instâncias por folha. Quanto menos instâncias necessárias, mais alta é a precisão dessa árvore e maior seu tamanho, com o aumento no número de instâncias a precisão é reduzida, mas a árvore se apresenta de forma mais enxuta facilitando sua visualização e entendimento, mantendo somente os nós mais relevantes em cada classificação.

As árvores de decisão com no mínimo 2 instâncias por folha apresentaram elevado número de folhas, o que impossibilitou a visualização de forma gráfica no *software*. Dessa forma, foram geradas graficamente 180 árvores, 3 para cada um dos 60 conjuntos de dados.

Todas as 180 árvores de decisão e os 240 arquivos de log, estão anexadas a essa dissertação em um CD. Os arquivos de log apresentam a árvore de decisão em formato de texto, as matrizes de confusão, o percentual de acerto e erro, entre outras variáveis.

Neste trabalho foram analisadas as árvores de decisão com no mínimo 1000 instâncias por folha para os conjuntos de dados sem filtragem, totalizando 12 árvores. Optou-se por esse conjunto de dados já que as taxas de acerto dos dados sem filtragem ficaram próximas as taxas de acerto das árvores do conjunto de dados filtrados com maior acerto (filtro de 0 a 4 Hz), que obteve acerto por volta de 90%. Tabelas com as taxas de acerto

da classificação dos dados sem filtragem, dos 3 sujeitos, com no mínimo 2, 200, 500 e 1000 instâncias por folha, são apresentadas no capítulo a seguir (Tabelas 5.1, 5.6 e 5.11).

4.3.1 WEKA e Algoritmo J48

WEKA (*Waikato Environment for Knowledge Analysis*) é um *software* de domínio público da Universidade de Waikato na Nova Zelândia. Tal *software* é uma coleção de algoritmos de aprendizado de máquina utilizados na mineração de dados e implementados em Java. O WEKA possui ferramentas para os dados de pré-processamento, classificação, regressão, agrupamento, regras de associação e visualização [Hall et al., 2009].

O sistema possui uma interface gráfica amigável (Ver Figura 4.9) e seus algoritmos fornecem relatórios com dados analíticos e estatísticos do domínio minerado onde é possível ver a matriz de confusão, um sumário contendo o percentual de dados corretamente classificados e não classificados, o erro médio absoluto e o erro relativo absoluto, entre outros.

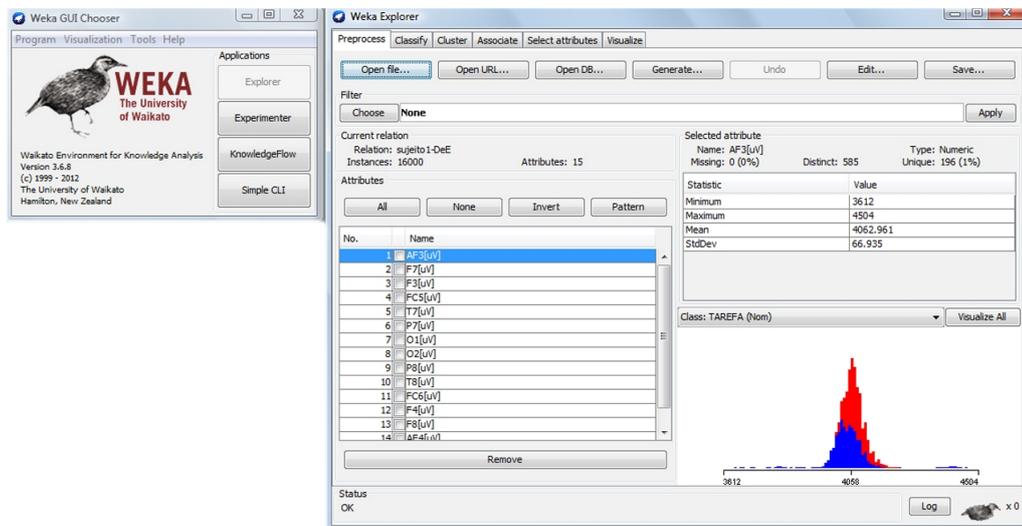


Figura 4.9: Telas do *software* WEKA

Uma abrangente documentação do código fonte está disponível online. Por ser escrito em Java, o código pode ser rodado em diferentes plataformas, conferindo uma boa portabilidade ao *software*. Uma limitação da ferramenta é a sua escalabilidade, uma vez que suas versões atuais limitam o volume de dados a ser manipulado. Mesmo assim, é possível minerar bases de dados relevantes, tornando o pacote atrativo para um grande número

de aplicações (componentes do WEKA tem sido utilizados em um considerável número de projetos).

O algoritmo utilizado para a geração de árvores de decisão foi o J48. O algoritmo J48 é uma implementação em Java, do algoritmo C4.5 release 8, gera árvores de decisão, sendo considerado o algoritmo mais popular do WEKA.

A construção da árvore, utilizando tal algoritmo, ocorre a partir de um conjunto de dados de treinamento que utiliza o conceito de ganho da informação como critério de ramificação, para a construção da árvore de decisão. O ganho da informação é baseado no índice de entropia para medição da homogeneidade de cada nó [Dalagassa et al., 2008]. A árvore é gerada na abordagem *top-down*, ou seja, da raiz para as folhas. Em cada nó é escolhido o atributo que melhor divide os dados naquele momento, e assim sucessivamente até que todos os dados tenham sido classificados. Depois da árvore completa, cada folha é uma classe e cada nó representa uma regra da classificação.

4.4 Validação

Os resultados adquiridos da etapa anterior, de classificação, foram validados com base na neurociência. Para tanto, a co-orientadora deste trabalho, Prof^a. Dr^a. Fernanda Antonilo Hammes de Carvalho é especialista nesta área. Baseado na literatura, a especialista formulou a tabela 4.1 onde as regiões do cérebro, bem como cada eletrodo está espacialmente posicionado conforme padrão internacional “10-20”, é apresentado baseado em suas funcionalidades. Os dados apresentados no próximo capítulo são baseados nas funções cerebrais apresentadas nessa tabela.

Percepção somatossensorial; Representações espaciais e Percepções táteis

Tabela 4.1: Áreas cerebrais, eletrodos e funções correspondentes.

Região	Eletrodo	Funções prioritárias diante de um ato motor
PRÉ-FRONTAL	AF3 AF4	Funções executivas (gerenciamento dos recursos cognitivos/emocionais diante de uma dada tarefa)
FRONTAL	F7 F3 F4 F8	Planejamento e movimento
CENTRAL	FC5 FC6	Última porção do lobo frontal: córtex motor primário
TEMPORAL	T7 T8	Percepção do movimento biológico
PARIETAL	P7 P8	Percepção somatossensorial Representações espaciais e Percepções táteis
OCCIPITAL	O1 O2	Visualização de imagens (inclusive durante um diálogo)

Capítulo 5

Análise dos Dados Obtidos

As atividades solicitadas aos três sujeitos nos testes realizados foram as mesmas, ou seja, primeiramente apertar uma bola com a mão direita e depois com a mão esquerda durante um minuto e num segundo momento imaginar apertar a bola com a mão direita e depois com a mão esquerda também durante um minuto.

Optou-se por realizar a análise da atividade de imaginação. Pretende-se como trabalhos futuros também realizar a análise da atividade de realização (apertar a bola).

Como cada indivíduo pode processar as informações de maneiras diferentes, as informações obtidas com as árvores de decisão também são diferentes para cada indivíduo.

A análise aqui realizada é baseada na tabela 4.1 onde busca-se uma explicação baseada na neurociência para os resultados obtidos.

5.1 Análise dos Dados do Sujeito 1

O sujeito 1 apresenta taxas de acerto (Tabela 5.1) acima de 90% para as árvores de decisão com no mínimo 2 instâncias por folha, sendo que no terceiro dia apresenta valores mais elevados. A tabela 5.1 apresenta as taxas de acerto do sujeito 1 ao longo dos 4 dias de coletas de dados com valores para árvores com no mínimo 2, 200, 500 e 1000 instâncias por folha. Como citado anteriormente as árvores de decisão que serão analisadas serão as com 1000 instâncias por folha, por serem mais enxutas e de fácil visualização.

A árvore 1 (Figura 5.1), referente ao primeiro dia de coleta do sujeito 1, apresentou 6 caminhos possíveis para a classificação das tarefas (imaginar movimento da mão direita e

Tabela 5.1: Taxas de acerto do sujeito 1 para os 4 dias de coleta

Instâncias\dia	Dia 1	Dia 2	Dia 3	Dia 4
2	96.0563%	94.7438%	98.7375%	91.1125%
200	86.8688%	83.5813%	93.9875%	81.4313%
500	82.0813%	80.625%	89.2875%	77.5313%
1000	78.8125%	75.5438%	85.825%	73.2313%

da mão esquerda) (Tabela 5.2). O caminho 1 envolveu o córtex motor (FC6). No caminho 2, além da área motora, é ativado o córtex temporal esquerdo (T7). É interessante destacar que, conforme Eysenck e Keane [Eysenck and Keane, 2007] a área cortical temporal é ativada ao perceber um movimento biológico, inclusive pela observação de outros movimentos humanos como das mãos, face e cabeça. Ainda no caminho 2, emerge a ativação do córtex pré-frontal (AF3), o qual gerencia a execução da tarefa. O mesmo acontece com o caminho 3, onde além dos eletrodos anteriores, envolve o córtex occipital (O2), podendo ser considerada a possibilidade de uma ativação visual da ação imaginada.

O caminho 4 pode ser considerado o mais completo, pois envolve a área onde são formadas as representações espaciais, percepções táteis e o movimento das mãos (P8). Paralelamente, uma outra justificativa dessa ativação provém da necessidade de prestar atenção, pois também envolve o lobo parietal, em especial no hemisfério direito (P8). Eysenck e Keane (2007), retomando os estudos de Corbetta e Shulman (2002), salientam que uma rede frontoparietal localizada no hemisfério direito do cérebro constitui o sistema direcionado para o alvo, o qual tem o funcionamento influenciado pela expectativa, pelo conhecimento. Nesse momento, é possível inferir que o sujeito 1 ativou a área responsável pela realização do movimento das mãos, mesmo sem movimentá-las de fato.

O caminho 5, envolveu não só a área motora (FC5 e FC6), mas também o córtex temporal esquerdo (T7). No caminho 6, além dessas, emerge a ativação do córtex pré-frontal (AF3), o qual gerencia a execução da tarefa.

A árvore 2 (Figura 5.2) apresenta o segundo dia de testes do sujeito 1. A árvore 2 apresentou 5 caminhos possíveis para a classificação das tarefas (Tabela 5.3). O caminho 1 abarca o lobo frontal, ocorrendo a ativação do córtex motor (F3) e o lobo parietal (P8), área cortical envolvida com representações espaciais, percepções táteis e movimento das

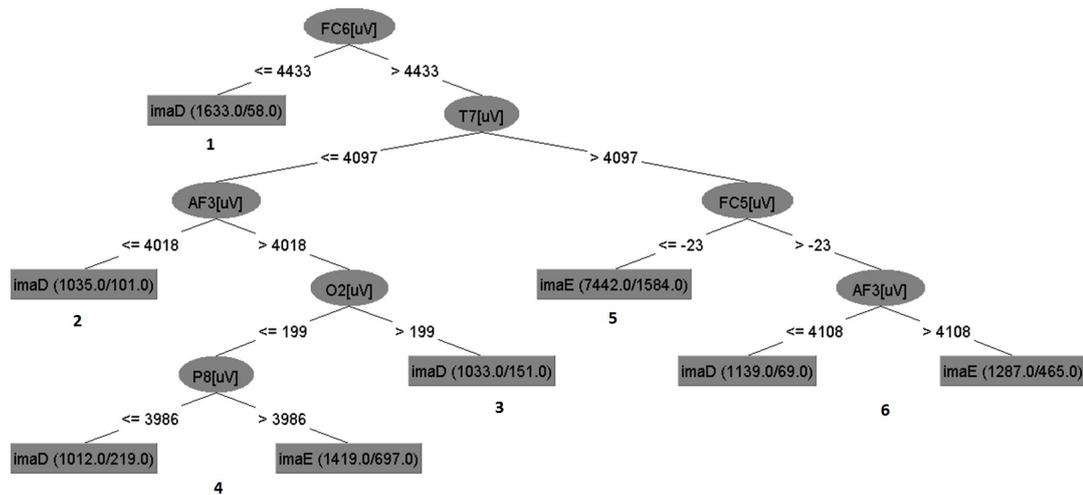


Figura 5.1: Árvore 1: primeiro sujeito, no primeiro dia.

Tabela 5.2: Caminhos presentes na árvore do sujeito 1 no primeiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	FC6	1633	
2	FC6 - T7 - AF3	1035	
3	FC6 - T7 - AF3 - O2	1033	
4	FC6 - T7 - AF3 - O2 - P8	1012	1419
5	FC6 - T7 - FC5		7442
6	FC6 - T7 - FC5 - AF3	1139	1287

mãos. O caminho 2 contém o caminho 1(F3 e P8), acrescido da área correspondente ao córtex motor primário (FC5). No caminho 3, soma-se a área do córtex pré-frontal (AF4), ligada às funções executivas, correspondendo a um sistema responsável pelo gerenciamento das ações. O córtex pré-frontal tem sido apontado como uma região cortical aprimorada na supervisão e seleção das tarefas, sendo fundamental na habilidade de selecionar uma postura ou uma resposta motora entre as várias opções presentes num repertório motor [Lent, 2008]. O caminho 4 envolve o caminho 3 e reitera a atuação da área motora (F7, sendo que o caminho 5, demonstra a ativação ampliada dessas regiões corticais (F3 e F7), alta concentração e planejamento dos movimentos (AF4), bem como uma possível representação do movimento a partir da ativação do parietal (P7). Conforme Lent [Lent, 2008], o córtex parietal parece ter papel fundamental na integração de informações sensoriais, colaborando na construção de uma resposta motora apropriada, desempenhando inclusive uma atividade antecipatória com relação à execução do movimento.

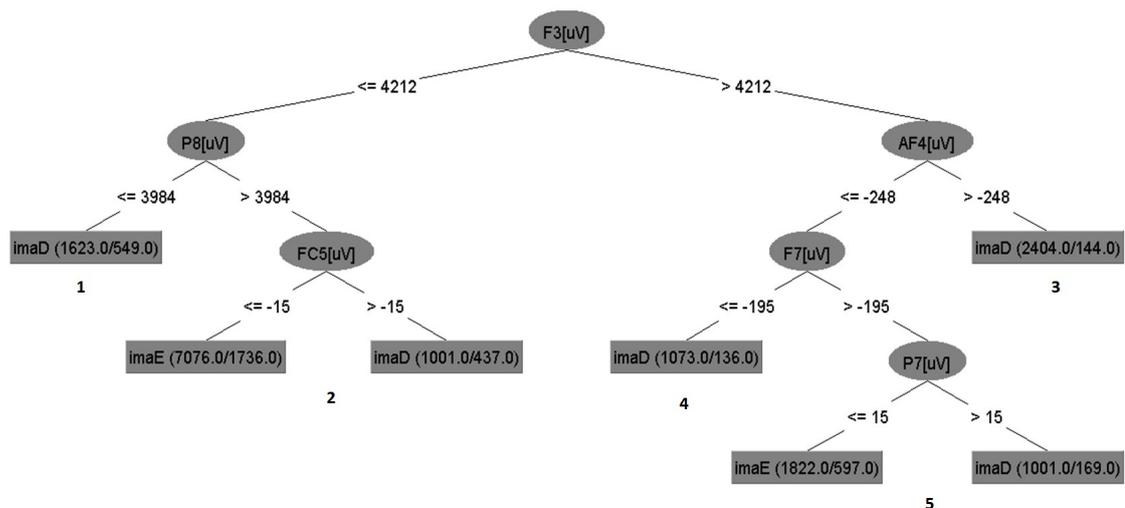


Figura 5.2: Árvore 2: primeiro sujeito, no segundo dia.

A árvore 3 (Figura 5.3) apresenta o terceiro dia de testes do sujeito 1, e apresentou apenas 2 caminhos (Tabela 5.4). Para classificar a tarefa no caminho 1, o sujeito demonstrou estar atento a diante da necessidade de planejar o movimento (AF4). Conforme Posner e Raichle [Posner and Raichle, 2001] “O lobo frontal direito é uma fonte muito provável da vigília, uma vez que os pacientes com lesões neste lobo desempenham de forma menos eficaz as tarefas que exigem vigília”. Estudos com pacientes com o cérebro dividido, permitem conclusões interessantes referentes a atenção e ao funcionamento cere-

Tabela 5.3: Caminhos presentes na árvore do sujeito 1 no segundo dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	F3 - P8	1623	
2	F3 - P8 - FC5	1001	7076
3	F3 - AF4	2404	
4	F3 - AF4 - F7	1073	
5	F3 - AF4 - F7 - P7	1001	1822

bral, como a observação de que o hemisfério direito parece ser dominante para se manter o estado de alerta [Sternberg, 2008]. Já o caminho 2 envolve, além de alta concentração, a visualização de imagens, sendo possível inferir que o sujeito tenha olhado para sua mão ou visualizado mentalmente a mão se movendo (O2).

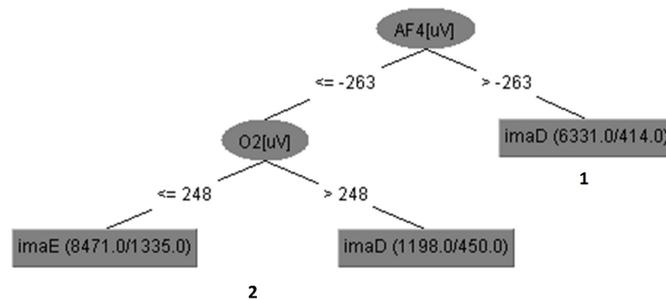


Figura 5.3: Árvore 3: primeiro sujeito, no terceiro dia.

Tabela 5.4: Caminhos presentes na árvore do sujeito 1 no terceiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	AF4	6331	
2	AF4 - O2	1198	8471

A árvore 4 (Figura 5.4) apresenta o quarto dia de testes do sujeito 1, contando com 7 caminhos (Tabela 5.5).. Esta árvore é incremental, ou seja, os caminhos se complementam (novos nós são inseridos), mas a sequência anterior continua a mesma. Nos caminhos 1, 2 e 3 o sujeito realizou a tarefa através do lobo temporal (T7 e T8), áreas do cérebro envolvidas na percepção do movimento, mesmo que diante de uma informação visual deficiente [Eysenck and Keane, 2007]. É possível também inferir que nesse momento tenha

ocorrido algum tipo verbalização interna como “comando” para a execução da tarefa, pois trata-se de uma área cerebral profundamente envolvida com a linguagem. Para o caminho 4, além desse, agregou o córtex motor (F8). Esses envolvimento se repetiram no caminho 5 somados ao envolvimento do córtex pré-frontal (AF3). O caminho 6 pode ser considerado o mais completo, pois além das ativações anteriores, envolve o parietal, área que está ligada à imaginação da realização do movimento (P7). O caminho 7 apenas confirma o caminho 6, onde o sujeito demonstra o envolvimento das funções executivas (AF4).

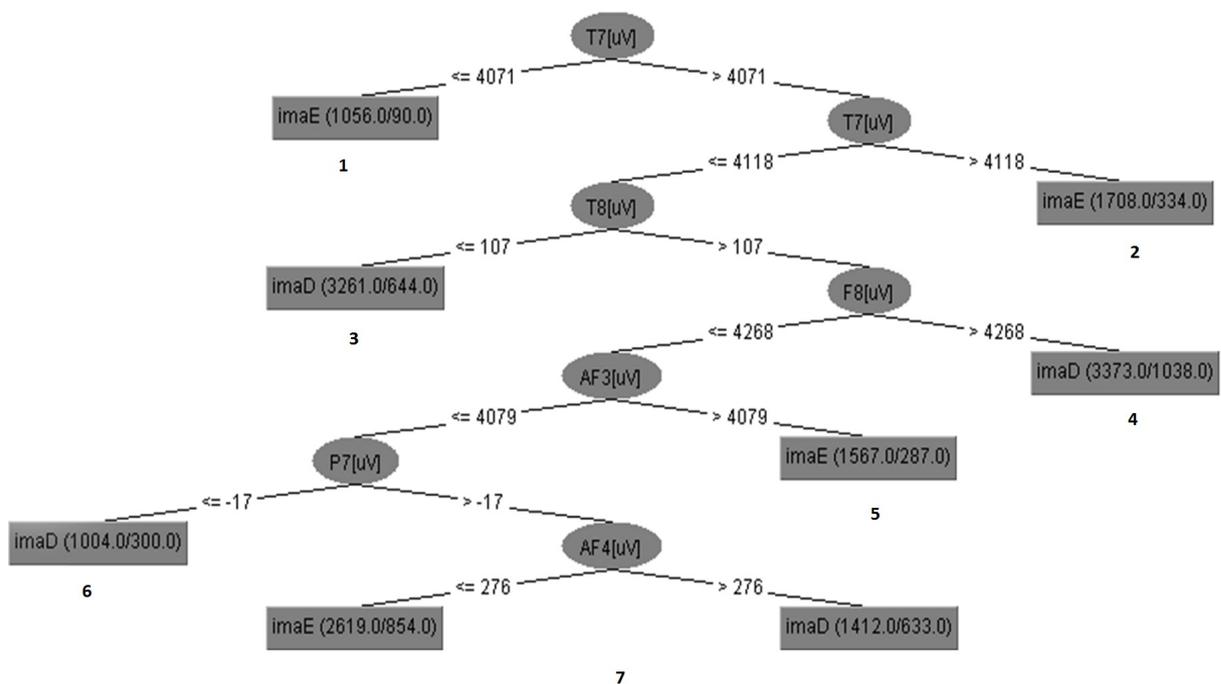


Figura 5.4: Árvore 4: primeiro sujeito, no quarto dia.

Tabela 5.5: Caminhos presentes na árvore do sujeito 1 no quarto dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	T7		1056
2	T7 - T7		1708
3	T7 - T7 - T8	3261	
4	T7 - T7 - T8 - F8	3373	
5	T7 - T7 - T8 - F8 - AF3		1567
6	T7 - T7 - T8 - F8 - AF3 - P7	1004	
7	T7 - T7 - T8 - F8 - AF3 - P7 - AF4	1412	2619

5.2 Análise dos Dados do Sujeito 2

O sujeito 2 apresenta taxas de acerto (Tabela 5.6) acima de 88% para as árvores de decisão com no mínimo 2 instâncias por folha, sendo que no segundo dia apresenta valores mais elevados. A tabela 5.6 apresenta as taxas de acerto do sujeito 2 ao longo dos 4 dias de coletas de dados com valores para árvores com no mínimo 2, 200, 500 e 1000 instâncias por folha.

Tabela 5.6: Taxas de acerto do sujeito 2 para os 4 dias de coleta

Instâncias \ dia	Dia 1	Dia 2	Dia 3	Dia 4
2	91.2375%	95.6375%	88.2813%	91.1688%
200	79.45%	86.1563%	79.8875%	85.5063%
500	75.7%	82.475%	77.1125%	81.9188%
1000	72.7688%	80.4813%	74.6188%	78.6063%

A árvore 5 (Figura 5.5), referente ao primeiro dia de coleta do sujeito 2, apresentou 6 caminhos possíveis para a classificação das tarefas (Tabela 5.7). O caminho 1 indica que houve um envolvimento do córtex motor (F8). No caminho 2, esse envolvimento é ampliado (F3). O caminho 3 apresentou, além das ações determinadas no caminho 2, processamento no córtex temporal direito (T8). No caminho 4, além do apresentado no anterior, houve a ativação da área apontada como local de representações espaciais e percepções táteis (P8) e novamente a ampliação na ativação de áreas motoras (F7).

Nos caminhos 5 e 6, é possível pressupor uma visualização das imagens, isto é, da mão executando a tarefa, visto que envolve as áreas corticais (O1 e O2). O cérebro, diante da necessidade de executar movimentos, processa a informação visual de dois modos: através da via ventral, que sai do córtex estriado e vai para a parte inferior do lobo temporal (envolvida com o reconhecimento de objetos, como a seletividade para forma, cor e textura) e da via dorsal responsável pelos aspectos espaciais da visão, como a análise do movimento e das relações entre as posições de objetos na cena visual, inclui a área temporal média, indo do córtex estriado até o lobo parietal.

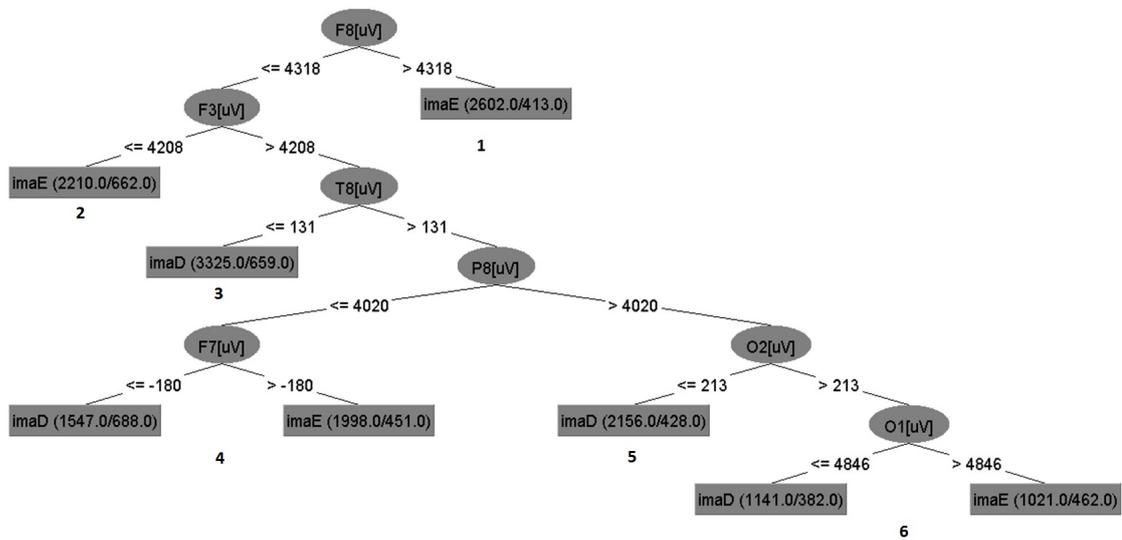


Figura 5.5: Árvore 5: segundo sujeito, no primeiro dia.

Tabela 5.7: Caminhos presentes na árvore do sujeito 2 no primeiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	F8		2602
2	F8 - F3		2210
3	F8 - F3 - T8	3325	
4	F8 - F3 - T8 - P8 - F7	1547	1998
5	F8 - F3 - T8 - P8 - O2	2156	
6	F8 - F3 - T8 - P8 - O2 - O1	1141	1021

A árvore 6 (Figura 5.6), referente ao segundo dia de coleta do sujeito 2, apresenta 3 caminhos (Tabela 5.8). O caminho 1 indica a ativação da área responsável pelo movimento

das mãos (P7), pois como já destacado anteriormente, essa área é bastante envolvida no planejamento motor. No caminho 2, além do apresentado no caminho 1, percebe-se a ativação do córtex motor (F3), e da área parietal (P8). No caminho 3 destaca-se a ativação do parietal (P7) e do córtex motor (F3), que apareceu duas vezes.

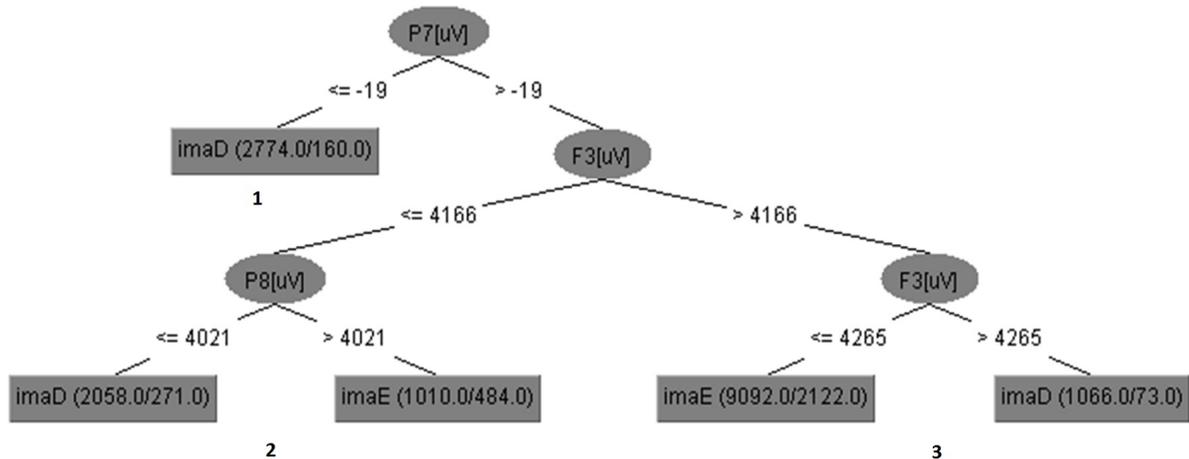


Figura 5.6: Árvore 6: segundo sujeito, no segundo dia.

Tabela 5.8: Caminhos presentes na árvore do sujeito 2 no segundo dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	P7	2774	
2	P7 - F3 - P8	2058	1010
3	P7 - F3 - F3	1066	9092

A árvore 7 (Figura 5.7), referente ao terceiro dia de coleta com o sujeito 2, apresentou 6 caminhos (Tabela 5.9). No caminho 1 é perceptível a ativação do córtex motor (F3). No caminho 2, associado a esse envolvimento, emerge a participação do córtex temporal (T8), relacionado com a percepção de movimentos biológicos. No caminho 3, além do apresentado no caminho 2, é possível inferir a concentração na tarefa e o planejamento de movimentos (AF4). O caminho 4 teve as mesmas características do caminho 3, mas apresentou registros em ambos hemisférios (AF4 e AF3), reiterando o envolvimento na tarefa, pois as estruturas neurobiológicas mais diretamente responsáveis pelas funções executivas estão precipuamente localizadas nos lobos frontais. O caminho 5 apresenta as mesmas áreas que o caminho 2. O caminho 6 abarcou, além dos córtex motor e do córtex

temporal (F3 e T8) uma ativação do córtex motor primário (FC6).

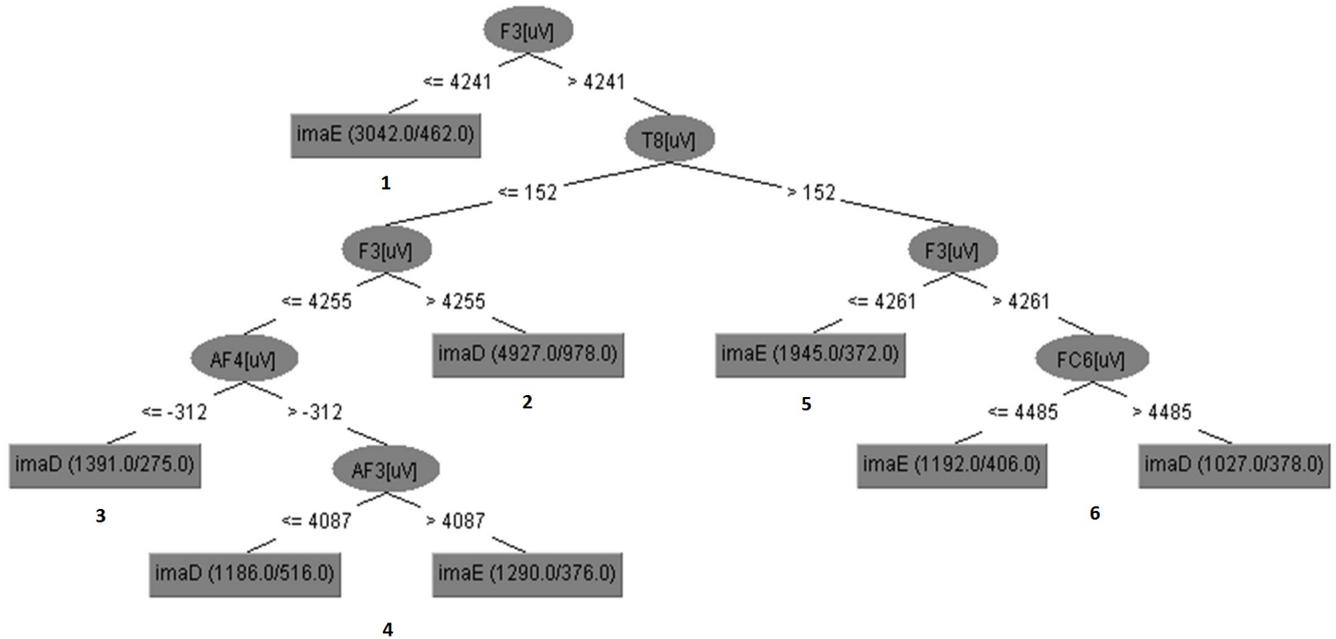


Figura 5.7: Árvore 7: segundo sujeito, no terceiro dia.

Tabela 5.9: Caminhos presentes na árvore do sujeito 2 no terceiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	F3		3042
2	F3 - T8 - F3	4927	
3	F3 - T8 - F3 - AF4	1391	
4	F3 - T8 - F3 - AF4 - AF3	1186	1290
5	F3 - T8 - F3		1945
6	F3 - T8 - F3 - FC6	1027	1192

A árvore 8 (Figura 5.8), referente ao quarto dia de coleta do sujeito 2, apresentou 5 caminhos (Tabela 5.10), sendo os caminho 2 e 3 iguais. O caminho 1 apresentou alto nível de concentração e planejamento de movimentos (AF4). Os caminhos 2 e 3, além do apresentado no caminho 1, indicam um processamento motor (F7). No caminho 4, além do apresentado no caminho anterior, a área parietal também é ativada (T7). O caminho 5 apresenta todas as características do caminho 4, acrescido do envolvimento do córtex motor primário (FC5).

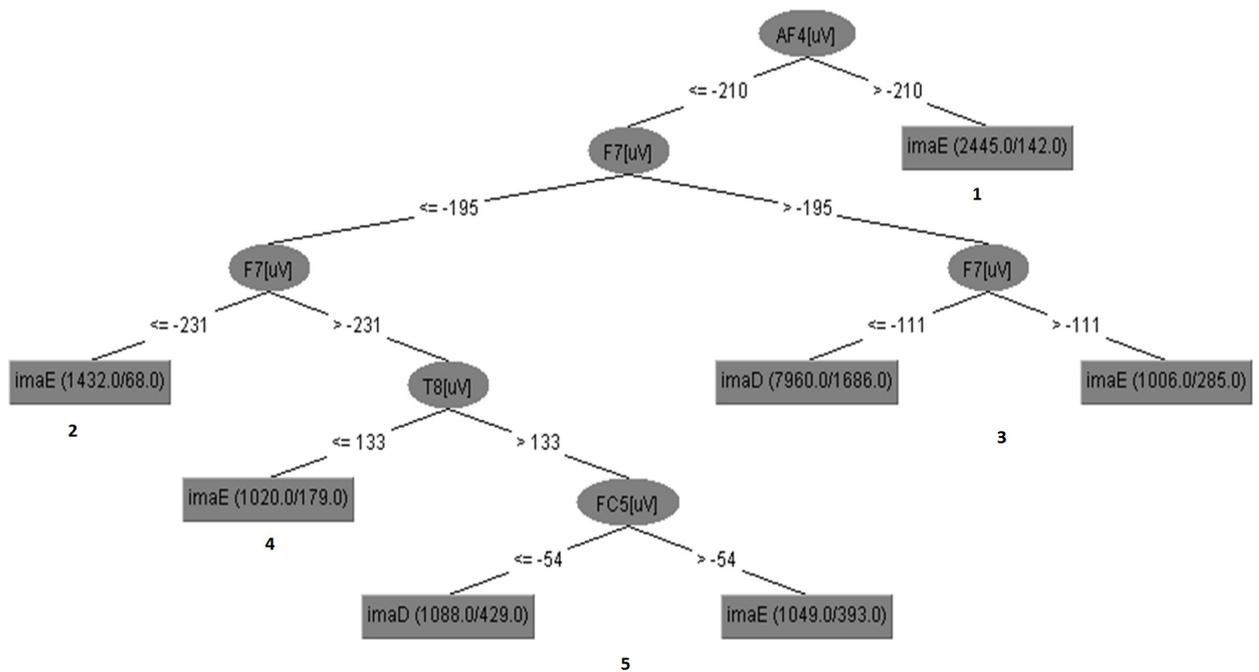


Figura 5.8: Árvore 8: segundo sujeito, no quarto dia.

Tabela 5.10: Caminhos presentes na árvore do sujeito 2 no quarto dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	AF4	2445	
2	AF4 - F7 - F7	7960	1006
3	AF4 - F7 - F7		1432
4	AF4 - F7 - F7 - T8		1020
5	AF4 - F7 - F7 - T8 - FC5	1088	1049

5.3 Análise dos Dados do Sujeito 3

O sujeito 3 apresenta taxas de acerto (Tabela 5.11) acima de 82% para as árvores de decisão com no mínimo 2 instâncias por folha, sendo que no segundo dia apresenta valores mais elevados. A tabela 5.1 apresenta as taxas de acerto do sujeito 1 ao longo dos 4 dias de coletas de dados com valores para árvores com no mínimo 2, 200, 500 e 1000 instâncias por folha.

Tabela 5.11: Taxas de acerto do sujeito 3 para os 4 dias de coleta

Instâncias\dia	Dia 1	Dia 2	Dia 3	Dia 4
2	86.6625%	89.45%	82.8%	83.8125%
200	73.5625%	79.0125%	76.2625%	76.2375%
500	68.975%	76.6875%	73.8438%	72.4438%
1000	65.4063%	72.4688%	72.9%	67.6313%

A árvore 9 (Figura 5.9), referente ao primeiro dia de coleta do sujeito 3, apresentou 8 caminhos possíveis para a classificação das tarefas (Tabela 5.12). No caminho 1 houve um processamento nos 2 hemisférios da região temporal, relacionada a percepção de movimentos biológicos (T7 e T8). O caminho 2, além do apresentado no caminho 1, foi ativado o lobo occipital que é ligado a percepção visual (O2). O caminho 3 é continuação do caminho anterior e apresenta ativação do córtex motor (F3). O caminho 4, contém o anterior, e apresenta concentração no planejamento de movimentos (AF3). O caminho 5 ativa (T7) e processamento no córtex motor primário (FC5). O caminho 6, além do mostrado no caminho anterior, apresenta processamento no córtex motor (F3). O caminho 7, é continuação do caminho 6, e apresenta (T7). O caminho 8 difere do anterior devido a ativação do lobo occipital (O1).

A árvore 10 (Figura 5.10), referente ao segundo dia de coleta do sujeito 3, apresentou 6 caminhos (Tabela 5.13). O caminho 1 apresentou a ativação das funções executivas no córtex pré-frontal (AF3). No caminho 2, soma-se a esse, uma possível percepção de movimento biológico através da ativação do lobo temporal (T8). No caminho 3, além do apresentado no caminho 2, houve a ativação da área diretamente responsável pelo movimento das mãos (P7). O caminho 4, paralelamente aos lobos ativados no caminho

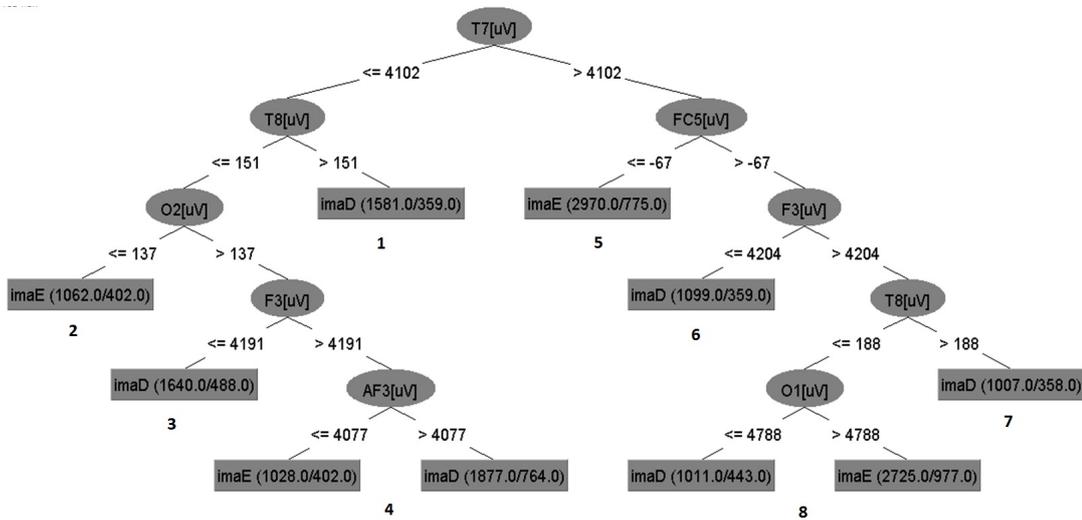


Figura 5.9: Árvore 9: terceiro sujeito, no primeiro dia.

Tabela 5.12: Caminhos presentes na árvore do sujeito 3 no primeiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	T7 - T8	1581	
2	T7 - T8 - O2		1062
3	T7 - T8 - O2 - F3	1640	
4	T7 - T8 - O2 - F3 - AF3	1877	1028
5	T7 - FC5		2970
6	T7 - FC5 - F3	1099	
7	T7 - FC5 - F3 - T8	1007	
8	T7 - FC5 - F3 - T8 - O1	1011	2725

anterior, ocorre a ativação nos dois lados da região occipital (O1 e O2) relacionadas a visualização de imagens. Os caminhos 5 e 6 não apresentam ativação de O1, mas apontam ativação das redes executivas frontais (AF3 e AF4), de modo que no caminho 6 a área AF3 se repete.

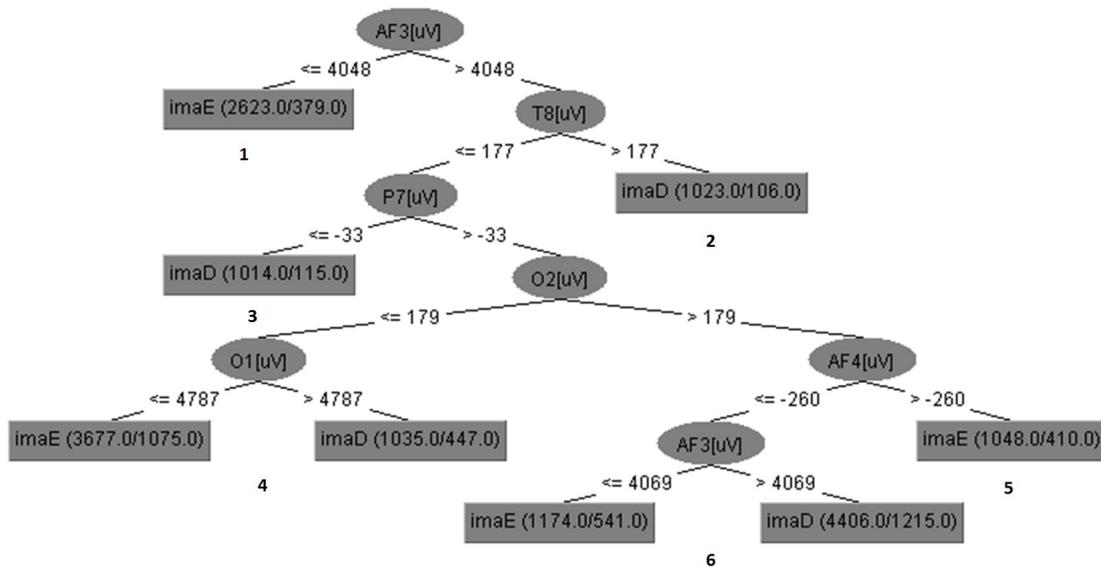


Figura 5.10: Árvore 10: terceiro sujeito, no segundo dia.

Tabela 5.13: Caminhos presentes na árvore do sujeito 3 no segundo dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	AF3		2623
2	AF3 - T8	1023	
3	AF3 - T8 - P7	1014	
4	AF3 - T8 - P7 - O2 - O1	1035	3677
5	AF3 - T8 - P7 - O2 - AF4		1048
6	AF3 - T8 - P7 - O2 - AF4 - AF3	1174	4406

A árvore 11 (Figura 5.11), referente ao terceiro dia de coleta do sujeito 3, apresentou 4 caminhos (Tabela 5.14), onde os caminhos 1 e 3 apresentam os mesmo eletrodos, bem como os caminhos 2 e 4. Os caminhos 1 e 3 apresentam ativação da área frontal motora (FC5). Os caminhos 2 e 4 apresentam também a ativação do lobo frontal, agora ampliado (F3).

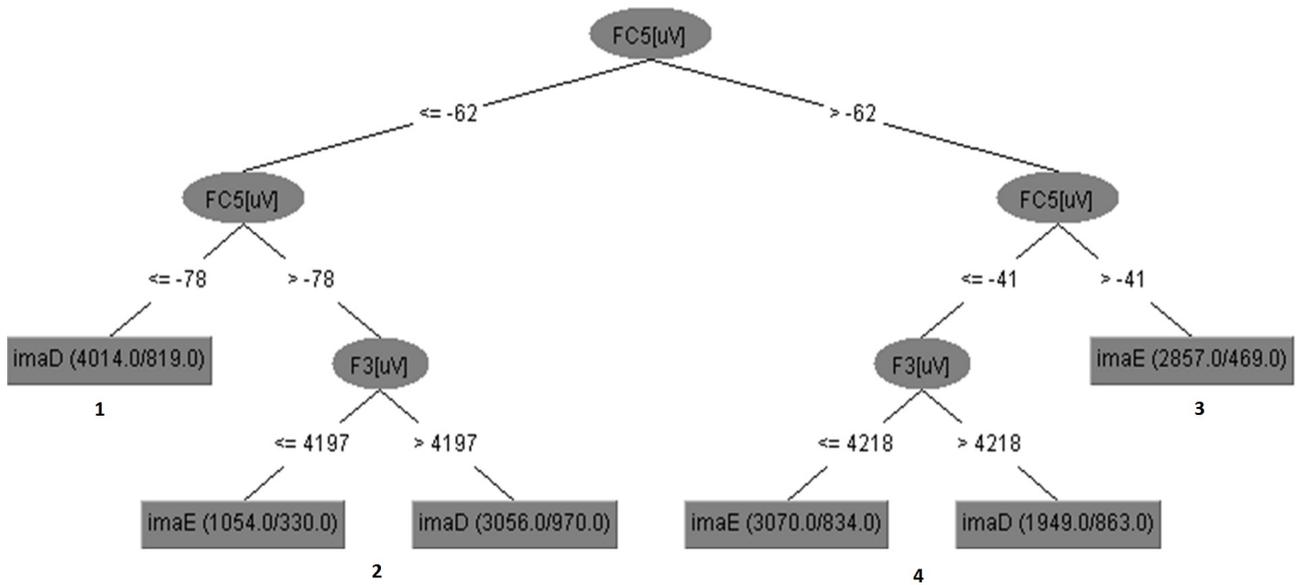


Figura 5.11: Árvore 11: terceiro sujeito, no terceiro dia.

Tabela 5.14: Caminhos presentes na árvore do sujeito 3 no terceiro dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	FC5 - FC5	4014	
2	FC5 - FC5 - F3	3056	1054
3	FC5 - FC5		2857
4	FC5 - FC5 - F3	1949	3070

A árvore 12 (Figura 5.12), referente ao quarto dia de coleta do sujeito 3, apresenta 7 caminhos (Tabela 5.15). O caminho 1 produziu ativação de região do lobo pré-frontal (AF3), relacionada as funções executivas. No caminho 2, a esse é acrescentado o envolvimento do córtex motor e da área visual (FC6 e O2). Essas ativações se reproduzem no caminho 3 e ampliam a ativação do lobo frontal (F8 e F4). Os caminhos 5 e 6 se diferem dos caminhos 3 e 4, respectivamente, por não apresentarem o eletrodo O2. O caminho 7, conjuntamente a ativação do córtex pré-frontal (AF3) e das áreas motoras (FC6, F8 e F4), ocorre o envolvimento do lobo temporal (T7).

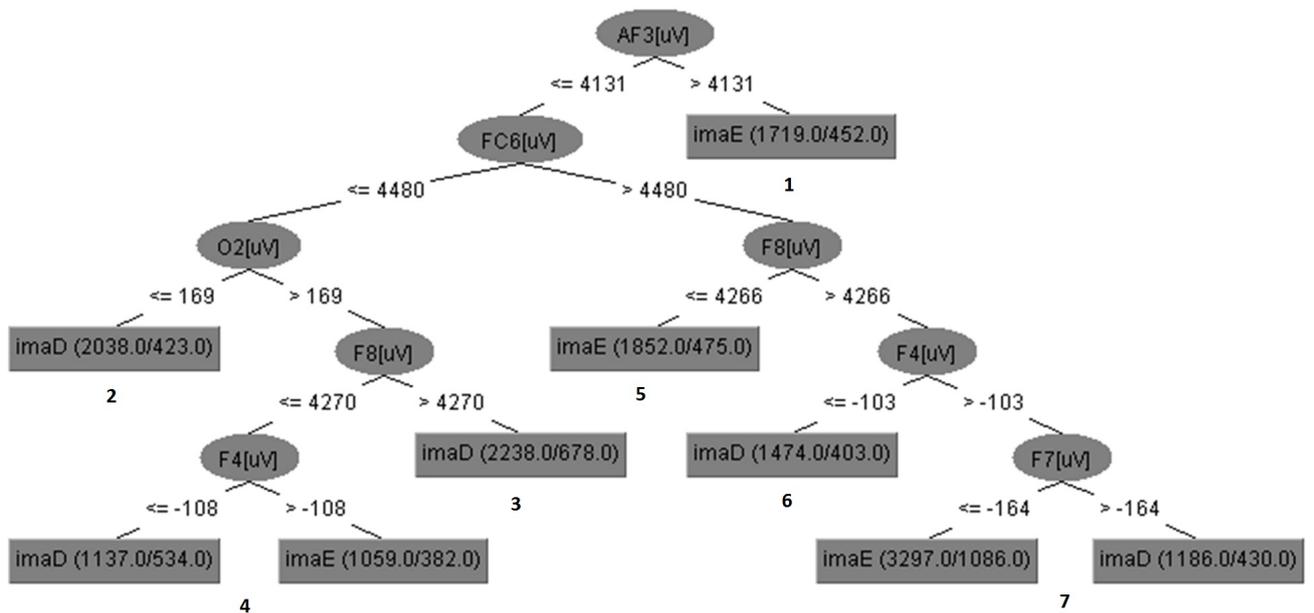


Figura 5.12: Árvore 12: terceiro sujeito, no quarto dia.

Tabela 5.15: Caminhos presentes na árvore do sujeito 3 no quarto dia.

Caminho	Eletrodos	Instâncias Direita	Instâncias Esquerda
1	AF3		1719
2	AF3 - FC6 - O2	2038	
3	AF3 - FC6 - O2 - F8	2238	
4	AF3 - FC6 - O2 - F8 - F4	1137	1059
5	AF3 - FC6 - F8		1852
6	AF3 - FC6 - F8 - F4	1474	
7	AF3 - FC6 - F8 - F4 - F7	1186	3297

5.4 Discussão sobre os resultados obtidos

Nas seções anteriores deste capítulo foram apresentadas 12 árvores de decisão: 4 árvores para cada um dos 3 sujeitos analisados. Como dito anteriormente, para cada sujeito foi realizada a coleta das mesmas ações por 4 dias consecutivos. Percebe-se que em nenhuma das árvores, o resultado obtido foi igual. Baseado na literatura da neurociência, esses resultados estão corretos, visto que cada sujeito pode ativar áreas diferentes do cérebro, mesmo executando a mesma ação.

Pode-se observar, a partir das árvores de decisão, que em todos os dias de coleta os eletrodos presentes no córtex frontal (que inclui a região central com FC5 e FC6) foram utilizados para a ramificação das ADs dos sujeitos 1, 2 e 3.

As teorias cognitivas apontam que o controle de atenção de alto nível, o planejamento, a detecção de erros e as respostas a estímulos difíceis ou completamente novos emergem do controle sobre o processamento da informação, o qual ocorre nos lobos frontais [Posner and Raichle, 2001]. Essa área do córtex está intimamente relacionada com as funções executivas (FEs), como por exemplo, a imaginação do movimento das mãos, tarefa solicitada aos sujeitos nesse trabalho.

Observa-se ainda que os eletrodos AF3 e/ou AF4 aparecem nas ADs do sujeito 1 em todos os dias de coleta, no terceiro e quarto dia do sujeito 2 e no segundo e quarto dia do sujeito 3. Esses eletrodos estão localizados da região anterior do lobo frontal, chamada de córtex pré-frontal. Essa região é responsável, dentro do lobo frontal, principalmente

pela alta concentração e pela memória operacional [Lent, 2001]. A memória operacional, também chamada de memória de trabalho, está relacionada com o modo que o sujeito vai realizar determinada ação. Pode-se inferir que essa memória foi ativada no momento de imaginar a execução do movimento das mãos, tarefa esta que tinha sido realizada antes da imaginação. A memória operacional produz arquivos que podem ser “apagados” ou transferidos para a memória de longo prazo (“arquivados”) [Xavier, 1993]. Quando se aprende e memoriza uma dada tarefa, o cérebro sabe (apesar de não se estar consciente) o que fazer, “[...] e isso o leva a fazê-lo mais depressa e com mais exatidão” [Mora, 2004].

No que diz respeito a atividades motoras, ou seja, apoiadas no desenvolvimento de habilidades motoras, a execução regular leva a construção de um referencial que poderá ser utilizado sempre que a atividade exija determinado domínio procedimental. Entretanto, é pertinente lembrar que o engrama (conjunto de memórias formado a partir de suas aprendizagens e experiências ao longo da vida) é singular, cada indivíduo constitui o seu [Squire and Kandel, 2003, Corrêa, 2010].

Embora haja uma significativa utilização do lobo frontal, paralelamente, outras áreas cerebrais também são ativadas durante a imaginação do movimento.

Os eletrodos dispostos no córtex temporal foram utilizados para a ramificação das ADs do sujeito 1 no primeiro (T8) e quarto dia (T7 e T8), do sujeito 2 no primeiro (T8), terceiro (T8) e quarto dia (T8), e do sujeito 3 no primeiro (T7 e T8) e segundo dia (T8). O córtex temporal, em conexão com o córtex frontal, participa de um tipo de memória operacional chamada memória espacial, permitindo a formação de um mapa cognitivo relacionando os eventos que estão ocorrendo no espaço ao qual se encontra com eventos já ocorridos no mesmo contexto [Lent, 2001].

A necessidade de se concentrar e prestar atenção à tarefa envolve também envolve o lobo parietal, em conjunto com lobo frontal [Eysenck and Keane, 2007]. Além, o lobo parietal está relacionado com a percepção do espaço imediatamente próximo ao corpo [Lent, 2001]. Essa percepção influencia no planejamento, realização e correção de movimentos. A árvore de decisão do sujeito 1 apresentou a utilização dessa região no primeiro (P8), segundo (P8) e quarto dia (P7), enquanto o sujeito 2 apresentou utilização dos eletrodos nos primeiro (P8) e segundo (P7 e P8) dia, e o sujeito 3 apresentou utilização somente o eletrodo P7 no segundo dia. Mesmo que as ADs tenham sido obtidas a partir

de dados coletados durante a imaginação dos movimentos, esses conceitos se aplicam a esse caso, sem a realização do movimento, já que é sabido que as áreas ativadas durante a realização de uma tarefa são muito similares às áreas ativadas durante a imaginação somente.

Quanto à ativação do córtex occipital (O1 e O2), o qual foi ativado pelo sujeito 1 no primeiro (O2) e terceiro dia (O2), pelo sujeito 2 somente no primeiro dia (O1 e O2), e pelo sujeito 3 no primeiro (O1 e O2), segundo (O1 e O2) e quarto dia (O2), pode ser explicada pelo fato de que o lobo occipital está fortemente relacionado com o sentido da visão. Durante a imaginação do movimento das mãos, acredita-se que os sujeitos tenham visualizado sua mão se movendo e evocado a memória visual desse acontecimento por terem realizado a tarefa de abrir e fechar as mãos antes da tarefa de imaginação. O córtex occipital é dividido em áreas visuais diferentes, sendo a maior o córtex visual primário, circundado por áreas visuais secundárias, processa distintos atributos da imagem visual, tais como sua cor, movimento e formas [Gazzaniga and Heatherton, 2005].

Acredita-se que com a coleta de dados realizada, por 4 dias consecutivos, as ADs apareceram em várias formas diferentes por se tratar de memórias operacionais de tarefas desconhecidas, pois os mesmos não tiveram treinamento prévio. Segundo Sternberg [Sternberg, 2008], com prática suficiente muitos procedimentos rotineiros estáveis, isto é, que envolvem tarefas conhecidas ou altamente praticadas, podem ser automatizados exigindo: pouca ou nenhuma intenção ou esforço; menores recursos atencionais e níveis relativamente baixos de processamento cognitivo (análise ou síntese mínimas), caracterizando-se pelo processamento paralelo (com muitas operações ocorrendo simultaneamente ou pelo menos sem qualquer ordem sequencial específica). Esses processos automatizados passam a ocorrer de forma relativamente mais rápida. Com treinamento prolongado é possível que ADs similares sejam construídas, devido ao automatismo advindo da repetição das tarefas.

Capítulo 6

Conclusão

Este é um trabalho multidisciplinar pois envolve diversas áreas de conhecimento, como ciência da computação, neurociência, engenharia, psicologia, imagens médicas, etc. O desenvolvimento da área de sistemas BCI necessita do aumento da cooperação entre essas diferentes áreas, bem como o estabelecimento de equipes que pesquisa multidisciplinares.

A neurociência é um campo muito amplo que trata de um estudo do sistema nervoso, sua estrutura, seu desenvolvimento, funcionamento, evolução, relação com o comportamento e a mente, e também suas alterações. Na área de neurociência cognitiva, que estuda a forma como o sistema nervoso controla o comportamento e o corpo humano, encontra-se base para estudar o controle motor, a imaginação de movimento e as áreas do cérebro responsáveis por essas ações. Sabe-se que as técnicas de captura de sinais cerebrais não invasivas podem dar informações elétricas somente das regiões corticais do cérebro, que ficam mais externamente, próximas ao crânio.

Sistemas BCI permitem um método de comunicação baseado na atividade cerebral, não dependendo da realização dos movimentos musculares que os comandos cerebrais geram. A pesquisa básica utiliza coleta de sinais cerebrais de forma não invasiva, e é normalmente iniciada em sistemas BCI *offline*, onde a aquisição do sinal é seguida por extração de características e tradução, em etapas separadas. Permitindo assim um refinamento dos algoritmos de extração e classificação de características, antes de utilizá-las em pesquisa aplicada. No entanto, uma técnica BCI precisa ser testada *online* para avaliar o seu desempenho.

Árvores de decisão são ferramentas para classificação de dados e previsão de fenômenos.

Fornecem regras que explicam o comportamento de sistemas, além de fornecer modelos de classificação. Uma de suas principais características é que as regras inferidas são de fácil interpretação. Sua indução é um método de aprendizado supervisionado, onde os exemplos são classificados antes de serem apresentados ao indutor. Assim, se a quantidade de exemplos for baixa ou incorreta, o resultado poderá não ser satisfatório.

Os resultados deste trabalho são iniciais, onde foram coletados e analisados sinais cerebrais de 3 sujeitos, e se trabalhou sempre de forma *offline*. Como explicado anteriormente, um sistema BCI necessita de testes *online* para ser implantado.

De acordo com os resultados obtidos percebe-se que as árvores de decisão foram capazes de classificar os sinais cerebrais coletados. Foram encontradas semelhanças e diferenças entre as ADs geradas e, com base nas neurociências, isso se explica devido ao cérebro desempenhar determinadas funções em regiões específicas para todos os humanos, mas também, cada indivíduo pode desempenhar uma tarefa de maneira particular. Ao imaginar o movimento das mão, por exemplo, pode-se visualizar mentalmente a mão se movendo, ou imaginar a sensação dos músculos e articulações em movimento, o que pode resultar em sinais cerebrais diversos em regiões cerebrais distintas.

A etapa de extração de características, muito enfatizada em alguns trabalhos, não apresentou grande melhora na classificação dos sinais. Das bandas de frequência utilizadas, somente uma apresentou taxas de acerto maiores que as taxas quando não foi feita nenhuma filtragem. Essa banda, *delta* (0 a 4 Hz), é relacionada com sono profundo, sendo pouco relevante na área de sistemas BCI.

A contribuição deste trabalho é a sugestão de uma forma automatizada para o tratamento dos sinais, minimizando a extração de características e focando na classificação e análise. No âmbito institucional local, colabora para alavancar estudos que tenham como foco a análise de sinais cerebrais para Sistemas BCI e promove a integração de conhecimentos de áreas diversas, como a Computação e as Neurociências.

Salienta-se também como contribuição, a publicação dos seguintes trabalhos:

- “Desenvolvimento de técnicas de classificação de sinais em sistemas BCI” no Seminário Internacional de Educação em Ciências(SINTEC), 2011.
- “Classification of Brain Signals in BCI Systems” na International Conference Cog-

inition and Exploratory Learning in Digital Age (CELDA), 2012.

- “Processamento e Classificação de Sinais Cerebrais para o Uso em Sistemas BCI” na Conferência Sul em Modelagem Computacional (MCSUL), 2012.

Como trabalhos futuros pretende-se analisar os dados de realização de movimento, que já foram coletados, comparando-os com a imaginação de movimento, buscando semelhanças nas áreas utilizadas pelo cérebro.

Apesar das semelhanças presentes nas ADs, identificar um padrão requer um estudo mais prolongado, ampliando a pesquisa, para verificar se um conjunto de dados coletados de um grupo de sujeitos, gerariam um padrão a ser utilizado em dispositivos BCI. Para tanto, imagina-se uma coleta de sinais cerebrais por um período de tempo maior (30 dias, por exemplo), onde pode haver um treinamento, ou aprendizado, por parte dos sujeitos resultando numa automatização do processo. Nesse caso, há possibilidade do resultado (árvores de decisão geradas) ser semelhante nos últimos dias de cada sujeito, onde eles terão estabelecido um caminho mais constante para a imaginação de um movimento. E também podem ser encontradas semelhanças entre as árvores de decisão de agentes distintos, já que passaram longo tempo realizando as mesmas ações, no mesmo local.

Bibliografia

- [Alpaydin, 2010] Alpaydin, E. (2010). *Introduction to Machine Learning*. The MIT Press, 2nd edition. 537 p.
- [Aparna et al., 2010] Aparna, C., Murthy, J. V. R., Babu, B. R., Chandra, M. V. P., and Rao, S. (2010). Reducing dataset size in frequency domain for brain computer interface motor imagery classification. *International Journal on Computer Science & Engineering*, 02(09):2924 – 2927.
- [ATTUX and ZUBEN, 2010] ATTUX, R. R. and ZUBEN, F. J. V. (2010). Tópicos de aula - tópico de 7 - árvore de decisão. DCA/FEEC/Unicamp.
- [Brayner, 2003] Brayner, I. C. d. S. (2003). Aplicação do paradigma auditivo oddball no estudo do p300: normatização para faixa etária de 7-14 anos e avaliação de crianças com dificuldade de aprendizagem com e sem transtorno de déficit de atenção/hiperatividade. Master's thesis, Universidade Estadual de Campinas. Mestrado em Medicina.
- [Corrêa, 2010] Corrêa, A. C. O. (2010). *Memória, aprendizagem e esquecimento: a memória através das ciências cognitivas*. Editora Atheneu, São Paulo.
- [Dalagassa et al., 2008] Dalagassa, M., S.H, S., and Carvalho, R. (2008). Avaliação de modelos para a classificação de beneficiários com indicativos para o diabetes mellitus tipo 2. In *Anais do XI Congresso Brasileiro de Informática em Saúde*. XI Congresso Brasileiro de Informática em Saúde.
- [de Araújo, 2004] de Araújo, R. M. (2004). Aprendizado de máquina em sistemas complexos multiagentes: estudo de caso em um ambiente sob racionalidade limitada. Master's thesis, Universidade Federal do Rio Grande do Sul. Instituto de Informática. Programa de Pós-Graduação em Computação, Porto Alegre.

- [de Souza Vasconcelos, 2002] de Souza Vasconcelos, B. (2002). Mineração de regras de classificação com sistemas de banco de dados objeto-relacional. estudo de caso: Regras de classificação de litofácies de poços de petróleo. Master's thesis, UNIVERSIDADE FEDERAL DE CAMPINA GRANDE, Campina Grande - Paraíba - Brasil.
- [Delorme and Makeig, 2004] Delorme, A. and Makeig, S. (2004). Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134:9–21.
- [Duda et al., 2002] Duda, R., Hart, P., and Stork, D. (2002). *Pattern Classification*, chapter Chapter 8. Willey Interscience, 2nd edition.
- [Eysenck and Keane, 2007] Eysenck, M. and Keane, M. (2007). *Manual de psicologia cognitiva*. Artmed.
- [Farwell and Donchin, 1988] Farwell, L. A. and Donchin, E. (1988). Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, 70:510–523.
- [Garcia et al., 2008] Garcia, F. D., Muller, S. M. T., Bastos Filho, T. F., and Sarcinelli Filho, M. (2008). Uso de mapas auto-organizáveis em classificação de estados mentais para aplicação em uma interface cérebro-computador. *CBIS 2008 - XI Congresso Brasileiro de Informática em Saúde*.
- [Gazzaniga and Heatherton, 2005] Gazzaniga, M. S. and Heatherton, T. (2005). *Ciência psicológica: mente, cérebro e comportamento*. Artmed, Porto Alegre.
- [Gazzaniga et al., 2006] Gazzaniga, M. S., Ivry, R. B., and Magnum, G. R. (2006). *Neurociência Cognitiva: a biologia da mente*. Artmed, Porto Alegre.
- [Hall et al., 2009] Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The weka data mining software: An update. *SIGKDD Explorations*, 11(1).
- [Izquierdo, 2002] Izquierdo, I. (2002). *Memória*. Artmed, Porto Alegre.

- [Kolb and Wishaw, 2002] Kolb, B. and Wishaw, I. Q. (2002). *Neurociência do Comportamento*. Manole, São Paulo.
- [Koprinska, 2010] Koprinska, I. (2010). Feature selection for brain-computer interfaces. In *Proceedings of the 13th Pacific-Asia international conference on Knowledge discovery and data mining: new frontiers in applied data mining*, PAKDD'09, pages 106–117, Berlin, Heidelberg. Springer-Verlag.
- [Kroupi et al., 2011] Kroupi, E., Yazdani, A., Vesin, J.-M., and Ebrahimi, T. (2011). Ocular artifact removal from eeg: A comparison of subspace projection and adaptive filtering methods. In *Proceedings of 19th European Signal Processing Conference (Eusipco 2011)*.
- [Lent, 2001] Lent, R. (2001). *Cem bilhões de neurônios: conceitos fundamentais de neurociência*. Atheneu, São Paulo.
- [Lent, 2008] Lent, R. (2008). *Neurociência da mente e do comportamento*. Guanabara Koogan, Rio de Janeiro.
- [Miguel, 2010] Miguel, P. V. d. O. (2010). *ECOLIG - O protocolo semiótico para comunicação homem-máquina que utiliza interfaces do tipo cérebro-computador*. PhD thesis, Universidade Estadual de Campinas. Doutorado em Engenharia elétrica.
- [Mitchell, 1997] Mitchell, T. (1997). *Machine Learning*. WCB McGraw-Hill.
- [Monard and Baranauskas, 2003] Monard, M. and Baranauskas, J. (2003). *Sistemas Inteligentes - Fundamentos e Aplicações*, de Rezende, S.O.; Prati, R., chapter 4, pages 39–56. Manole. ISBN 85-204-1683-7.
- [Mora, 2004] Mora, F. (2004). *Como funciona o cérebro*. Artmed, Porto Alegre.
- [Pfurtscheller and da Silva, 1999] Pfurtscheller, G. and da Silva, F. L. (1999). Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11):1842 – 1857.
- [Posner and Raichle, 2001] Posner, M. I. and Raichle, M. (2001). *Imagens da Mente*. Porto Editora, Porto.

- [Quinlan, 1993] Quinlan, J. (1993). *C4.5: Programs for machine learning*. Morgan Kaufmann Publishers.
- [Ranaudo et al., 2011] Ranaudo, F., MIRANDA-DE-SÁ, A. M., and Felix, L. (2011). Sistema para detecção em tempo real de respostas evocadas auditivas: Aplicação em interfaces cérebro computador. *SBAI 2011 - X Simpósio Brasileiro de Automação Inteligente*.
- [Ratey, 2002] Ratey, J. J. (2002). *O cérebro: um guia para o usuário*. Objetiva, Rio de Janeiro.
- [Russel and Norvig, 2004] Russel, S. and Norvig, P. (2004). *Inteligência Artificial*. Elsevier/Campus, Rio de Janeiro.
- [Schuette, 2010] Schuette, M. (2010). Lessons from a life with nia. *LOSTCIRCUITS*, pages 1–21. Disponível em: <http://www.lostcircuits.com>.
- [Squire and Kandel, 2003] Squire, L. R. and Kandel, E. R. (2003). *Memória: da mente às moléculas*. Artmed, Porto Alegre.
- [Sternberg, 2008] Sternberg, R. (2008). *Psicologia cognitiva*. Artmed.
- [Szafir, 2009] Szafir, D. J. (2009). *Non-Invasive BCI through EEG: An Exploration of the Utilization of Electroencephalography to Create Thought-Based Brain-Computer Interfaces*. PhD thesis, Boston College, Boston, UK.
- [Vallabhaneni et al., 2005] Vallabhaneni, A., Wang, T., and He, B. (2005). Brain-computer interface. In He, B., editor, *Neural Engineering*, pages 85–121. Kluwer Academic, New York.
- [Waldert et al., 2008] Waldert, S., Preissl, H., Demandt, E., Braun, C., Birbaumer, N., Aertsen, A., and Mehring, C. (2008). Hand movement direction decoded from meg and eeg. *Journal of Neuroscience*, 28(4):1000–1008.
- [Wolpaw et al., 2000] Wolpaw, J. R., Birbaumer, N., Heetderks, W. J., McFarland, D. J., Peckham, P. H., Schalk, G., Donchin, E., Quatrano, L. A., Robinson, C. J., and

- Vaughan, T. M. (2000). Brain-computer interface technology: a review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, 8(2):164–173.
- [Wolpaw et al., 2002] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical neurophysiology*, 113(6):767 – 791.
- [Xavier, 1993] Xavier, G. F. (1993). A modularidade da memória e o sistema nervoso. *Psicologia USP*, 4(1-2).