

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO TECNOLÓGICO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDERSON PRADO AZEVEDO

**ESTUDO DO SINAL ELETROENCEFALOGRÁFICO (EEG)  
APLICADO A INTERFACES CÉREBRO COMPUTADOR COM  
UMA ABORDAGEM DE RECONHECIMENTO DE PADRÕES**

VITÓRIA  
2005

ANDERSON PRADO AZEVEDO

**ESTUDO DO SINAL ELETROENCEFALOGRÁFICO (EEG)  
APLICADO A INTERFACES CÉREBRO COMPUTADOR COM  
UMA ABORDAGEM DE RECONHECIMENTO DE PADRÕES**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica, na área de concentração em Automação.

Orientador: Prof. Dr. Evandro Ottoni Teatini Salles e Prof. Dr. Ailson Rosetti de Almeida.

VITÓRIA  
2005

Dados Internacionais de Catalogação-na-publicação (CIP)  
(Biblioteca Central da Universidade Federal do Espírito Santo, ES, Brasil)

---

A994e Azevedo, Anderson Prado, 1978-  
Estudo do sinal eletroencefalográfico (EEG) aplicado a interfaces  
cérebro-computador com uma abordagem de reconhecimento de padrões /  
Anderson Prado Azevedo. – 2005.  
110 f. : il.

Orientador: Evandro Ottoni Teatini Salles.  
Co-Orientador: Ailson Rosetti de Almeida.  
Dissertação (mestrado) – Universidade Federal do Espírito Santo,  
Centro Tecnológico.

1. Processamento de sinais. 2. Inteligência artificial. 3. Comunicação.  
I. Salles, Evandro Ottoni Teatini. II. Almeida, Ailson Rosetti de. III.  
Universidade Federal do Espírito Santo. Centro Tecnológico. IV. Título.

CDU: 621.3

---

ANDERSON PRADO AZEVEDO

**ESTUDO DO SINAL ELETROENCEFALOGRÁFICO (EEG)  
APLICADO A INTERFACES CÉREBRO COMPUTADOR COM  
UMA ABORDAGEM DE RECONHECIMENTO DE PADRÕES**

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisição parcial para a obtenção do Grau de Mestre em Engenharia Elétrica - Automação.

COMISSÃO EXAMINADORA

---

**Prof. Dr. Evandro Ottoni Teatini Salles**  
Universidade Federal do Espírito Santo  
Orientador

---

**Prof. Dr. Ailson Rosetti de Almeida**  
Universidade Federal do Espírito Santo  
Orientador

---

**Prof. Dr. Teodiano Freire Bastos Filho**  
Universidade Federal do Espírito Santo

---

**Prof. Dr. Rodrigo Varejão Andreão**  
Pesquisador Conselho Nacional de Desenvolvimento  
Tecnológico – CNPq.

*“O que sabemos é uma gota, o que ignoramos é um oceano”.*

Isaac Newton.

## **DEDICATÓRIA**

Aos meus amados pais, José Zeferino de Azevedo e Catarina Francisca Prado Azevedo, aos quais dedico todas as vitórias em minha vida, pois eu não as conquistaria sem eles. Ao meu irmão, Igor, e minha noiva, Vanessa, pelos momentos de amor, apoio e compreensão. E, finalmente, a Deus por me proporcionar saúde, educação e força para utilizar no trabalho que desenvolvo em benefício do próximo.

## **AGRADECIMENTOS**

Esta dissertação foi desenvolvida no Laboratório de Computação Inteligente e Sistemas Neurais da Universidade Federal do Espírito Santo, sob a supervisão dos orientadores Evandro e Ailson, aos quais devo infindáveis agradecimentos pelos ensinamentos e colaboração no desenvolvimento deste trabalho. Nossas longas discussões, inclusive sobre assuntos não pertinentes à dissertação, serão sempre lembradas.

Agradeço à Universidade de Berlim pelo fornecimento do banco de dados e a toda comunidade científica que luta contra todos os tipos de dificuldade para contribuir para o bem estar das pessoas que possuem algum tipo de deficiência física.

Agradeço a todos meus amigos, principalmente aos companheiros de pesquisa Teodiano, Klaus, André, Vinícius, Sandra e Anselmo, que contribuíram para o sucesso deste trabalho e que continuarão no desenvolvimento do protótipo de uma cadeira de rodas controlada por EEG.

## SUMÁRIO

<b>DEDICATÓRIA .....</b>	<b>6</b>
<b>AGRADECIMENTOS .....</b>	<b>7</b>
<b>LISTA DE TABELAS .....</b>	<b>10</b>
<b>LISTA DE FIGURAS.....</b>	<b>11</b>
<b>LISTA DE SIGLAS.....</b>	<b>13</b>
<b>RESUMO.....</b>	<b>15</b>
<b>ABSTRACT .....</b>	<b>16</b>
<b>1 INTRODUÇÃO .....</b>	<b>17</b>
1.1    Sistemas de Reconhecimento de Padrões .....	20
1.2    Estrutura da Dissertação .....	22
<b>2 ANATOMIA DO CÉREBRO HUMANO.....</b>	<b>23</b>
2.1    O Neurônio .....	23
2.1.1    Transmissão da Informação .....	26
2.2    O Cérebro.....	27
2.3    O Córtex Cerebral.....	28
2.4    Medição da Atividade Elétrica do Cérebro .....	32
<b>3 ELETROENCEFALOGRAFIA .....</b>	<b>37</b>
3.1    Introdução .....	37
3.2    Aquisição do <i>EEG</i> .....	39
3.2.1    Equipamento.....	39
3.2.2    Eletrodos.....	40
3.3    Artefatos.....	42
3.3.1    Artefatos de Origem Técnica .....	42
3.3.2    Artefatos de Origem Fisiológica .....	43
3.3.3    Remoção do Ruído em <i>EEG</i> .....	44
3.4    Características Estatísticas do Sinal <i>EEG</i> .....	45
3.4.1    Atividade Rítmica do Cérebro.....	47
3.4.2    Potenciais Relacionados a Eventos .....	50
3.4.3    Dessincronização / Sincronização Relacionada a Eventos. ....	52



<b>4</b>	<b>INTERFACES CÉREBRO-COMPUTADOR .....</b>	<b>54</b>
4.1	Abordagens de <i>ICC</i> .....	56
4.1.1	Abordagem de Reconhecimento de Padrões.....	56
4.1.2	Abordagem de Condicionamento do Operador .....	57
4.2	Classificação de Interfaces Cérebro Computador .....	59
4.3	Estado da Arte de <i>ICCs</i> .....	60
<b>5</b>	<b>SISTEMA IMPLEMENTADO.....</b>	<b>63</b>
5.1	Formatação do Banco de Dados .....	64
5.2	Potenciais Relacionados a Movimentos ( <i>MRP</i> ) .....	66
5.3	Análise das Características do <i>EEG</i> no Banco de Dados de Berlim ....	69
5.3.1	Potencial de <i>Bereitschafts</i> .....	70
5.3.2	Dessincronização Relacionada a Eventos .....	72
5.4	Visão Geral do Sistema Implementado .....	74
5.5	Extração de características do <i>ERD</i> .....	75
5.5.1	Filtragem Espacial e Temporal dos Dados.....	76
5.5.2	Decomposição Espacial em Subespaços Comuns.....	77
5.5.3	Análise no Domínio da Frequência.....	84
5.6	Extração de Características do <i>BP</i> .....	86
5.7	Classificador .....	89
<b>6</b>	<b>RESULTADOS OBTIDOS .....</b>	<b>93</b>
6.1	Resultados Obtidos .....	93
<b>7</b>	<b>CONCLUSÕES E PROJETOS FUTUROS .....</b>	<b>99</b>
	<b>REFERÊNCIAS .....</b>	<b>102</b>

## LISTA DE TABELAS

Tabela 3.1 - Ritmos de frequência no EEG.....	48
Tabela 4.1 - Classificação das <i>ICCs</i> . .....	59
Tabela 6.1 – Taxa de acertos para números diferentes de neurônios na camada oculta. ....	94
Tabela 6.2 - Taxa de acertos obtida com o conjunto de treino utilizando o método <i>Validação Cruzada</i> . ....	95
Tabela 6.3 - Comparação entre os resultados obtidos. ....	96
Tabela 6.4 - Taxa de acertos utilizando o banco de testes. ....	96
Tabela 6.5 - Comparação entre as taxas de acerto. ....	97

## LISTA DE FIGURAS

Figura 1.1 - Gravação do sinal EEG com 28 canais para 4 épocas .....	22
Figura 2.1 – Imagem de um neurônio obtida por um microscópio [67]. .....	24
Figura 2.2 - Estrutura de um neurônio [14]. .....	25
Figura 2.3 – Visão superior do Córtex Cerebral. O mapeamento motor do cérebro é feito de uma forma cruzada. Adaptado de [14]. .....	27
Figura 2.4 - Visão lateral do hemisfério esquerdo. Localização dos quatro lobos cerebrais. Adaptado de [14]. .....	29
Figura 2.5 - Localização de áreas funcionais responsáveis por tipos específicos de movimentos [37]. .....	30
Figura 2.6 - Áreas funcionais motoras e somatossensoriais do córtex cerebral [37]. .....	31
Figura 2.7 - Grau de representação dos diferentes músculos do corpo no córtex motor [37]. .....	32
Figura 2.8 - Resolução espacial / temporal dos métodos utilizados para a obtenção da atividade cerebral. Adaptado de [42]. .....	35
Figura 3.1 - Sistema de aquisição do sinal <i>EEG</i> . .....	40
Figura 3.2 – Sistema Internacional 10-20 para a colocação de eletrodos. ....	41
Figura 3.3 - (a) Ritmos do Sinal EEG. (b) Mudança do Ritmo Alfa para uma descarga assíncrona quando o paciente abre os olhos [87]. .....	50
Figura 3.4 - Análise do ERP através da média das épocas. Adaptado de [79]. ...	52
Figura 4.1 - ICC com abordagem de reconhecimento de padrões. ....	57
Figura 4.2 - ICC com abordagem de condicionamento do operador .....	58
Figura 5.1 - Posição dos eletrodos do Banco de Dados utilizado. ....	64
Figura 5.2 - Temporização para a gravação da época. ....	65
Figura 5.3 - EEG com 28 canais representando a tarefa de movimentar o dedo da mão esquerda. ....	68

Figura 5.4 - Visualização do EEGLAB. Ações podem ser executadas através da Interface Gráfica (GUI, do inglês Graphic User Interface) ou através da janela de linha de comando do MATLAB. ....	70
Figura 5.5 - Distribuição sob o escalpo do Potencial de Bereitschafts obtido utilizando a análise por média. (a) Movimento do dedo da mão direita. (b) Movimento do dedo da mão esquerda. ....	71
Figura 5.6 - Sinal de EEG representando a tarefa E, com o <i>BP</i> totalmente corrompido. ....	72
Figura 5.7 – Visualização do Espectro de Frequência dos Sinais dos Canais C1, C2, C3 e C4. ....	73
Figura 5.8 - Sistema implementado. ....	75
Figura 5.9 - Autovalores da matriz de Covariância Branqueada. (a) Autovalores associados à tarefa D. (b) Autovalores associados à tarefa E. (c) Autovalores associados à matriz de covariância branqueada, correspondente à somatória dos autovalores da tarefa D e da tarefa E. ....	83
Figura 5.10 - Filtragem Espacial. ....	84
Figura 5.11 - Distribuição das classes, após a etapa de extração de características do ERD. ....	86
Figura 5.12 - Extração de características do BP. ....	87
Figura 5.13 - Janela $W(n)$ . ....	88
Figura 5.14 - Fluxograma do classificador de padrões. ....	90

## LISTA DE SIGLAS

<i>ABI</i>	Adaptive Brain Interface;
<i>AEP</i>	Auditive Evoked Potential;
<i>BCI</i>	Brain-Computer Interface;
<i>BP</i>	Potencial de Bereitschafts;
<i>BSS</i>	Blind Source Separation (Separação Cega de Fontes);
<i>CA</i>	Corrente Alternada;
<i>CAR</i>	Common Average Reference;
<i>CC</i>	Corrente Contínua;
<i>CSSD</i>	Common Subspace Spatial Decomposition;
<i>DFT</i>	Discrete Fourier Transform;
<i>DNA</i>	Ácido Desoxirribonucléico;
<i>ECOG</i>	Eletrocorticograma;
<i>EEG</i>	Eletroencefalograma;
<i>ELA</i>	Esclerose Lateral Amiotrófica;
<i>EMG</i>	Eletromiograma;
<i>EOG</i>	Eletroculograma;
<i>EP</i>	Evoked Potential (Potencial Evocado);
<i>ERP</i>	Event-Related Potential (Potencial Relacionado a Eventos);
<i>ERD</i>	Event-Related Desynchronization (Dessincronização relacionada a Eventos);
<i>ERS</i>	Event-Related Synchronization (Sincronização relacionada a Eventos);
<i>FDA</i>	Fisher Discriminant Analysis;
<i>FFT</i>	Fast Fourier Transform;
<i>FIR</i>	Finite Impulse Response Filter;
<i>fMRI</i>	Functional Magnetic Resonance Imaging;
<i>HOS</i>	High Order Statistical Separation;
<i>IA</i>	Inteligência Artificial;
<i>ICA</i>	Independent Component Analysis (Análise de Componentes Independentes);

<i>ICC</i>	Interface Cérebro-Computador;
<i>IRMf</i>	Imagem por Ressonância Magnética Funcional;
<i>LDA</i>	Linear Discriminant Analysis;
<i>MEG</i>	Magnetoencefalografia;
<i>MLP</i>	Multilayer Perceptron;
<i>MRP</i>	Movement-Related Potential (Potencial Relacionado a Movimentos);
<i>Oxi-Hb</i>	Hemoglobina Oxigenada;
<i>Deoxi-Hb</i>	Hemoglobina Desoxigenada;
<i>PC</i>	Personal Computer (Computador Pessoal);
<i>PCA</i>	Principal Component Analysis;
<i>PET</i>	Positron Emission Tomography;
<i>RBF</i>	Radial Basis Function;
<i>RM</i>	Ressonância Magnética;
<i>RNA</i>	Rede Neural Artificial;
<i>SCP</i>	Slow-Cortical Potential (Potencial Cortical Lento);
<i>SFA</i>	Signal Fraction Analysis;
<i>SNR</i>	Signal Noise Relation (Relação Sinal Ruído);
<i>SQUID</i>	Superconducting Quantum Interference Devices;
<i>SNC</i>	Sistema Nervoso Central;
<i>SSS</i>	Strict Sense Stationarity (Estacionário no Sentido Estrito);
<i>SSVEP</i>	Steady State Visual Evoked Potential;
<i>SVM</i>	Suport Vector Machine;
<i>TC</i>	Tomografia Computadorizada;
<i>TTD</i>	Thought Translation Device;
<i>UFES</i>	Universidade Federal do Espírito Santo;
<i>VEP</i>	Visual Evoked Potential;
<i>VLSI</i>	Very Large System Integration;
<i>WSS</i>	Wide Sense Stationarity (Estacionário no Sentido Amplo).

## RESUMO

A conjunção de técnicas de processamento de sinais, de reconhecimento de padrões e técnicas de captura de sinais cerebrais torna possível uma nova modalidade de comunicação, antes somente sonhada pela ficção: a Interface Cérebro-Computador (*ICC*). Tal sistema é capaz de adquirir o sinal cerebral e processá-lo com o intuito de extrair informações que podem ser usadas como um sinal de controle.

A *ICC* pode beneficiar pessoas que sofrem de distúrbios neuromusculares, as quais provocam a perda da capacidade de movimento voluntário. Tais pessoas poderiam se comunicar, ou até mesmo se mover, usando uma *ICC* para o controle de equipamentos. Avaliando em um horizonte mais longínquo, estes sistemas poderão ser usados nas mais diversas aplicações, principalmente para fins multimídia.

O objetivo desta dissertação é estudar as características do sinal eletroencefalográfico, assim como técnicas de processamento de sinais e de reconhecimento de padrões para uso em uma interface cérebro computador (*ICC*). Para tanto, será utilizado um banco de dados internacional, a fim de que a eficácia da técnica empregada possa ser avaliada com mais propriedade, comparando-se os resultados alcançados com aqueles obtidos por outros grupos de pesquisa internacionais.

Destarte, esta dissertação descreve as características do cérebro humano e do sinal *EEG* relevantes para o estudo das *ICCs*, apresenta também as principais características das *ICCs* existentes e implementa um sistema de reconhecimento de padrões capaz de discriminar a lateralidade da imaginação motora com uma taxa de acerto de superior a 85%, o que no atual estado da arte é uma taxa de acertos satisfatória.

## ABSTRACT

The conjunction of signal processing, pattern recognition and brain electrical signal acquisition made possible a new communication modality, until now a subject for science fiction movies: the Brain-Computer Interface (*BCI*). This complex system can acquire and process the brain signals in order to obtain information to be used as a control signal.

This innovation can benefit people who have neuromuscular disorders, which cause damages on the volunteer movement. These people would communicate, or even move, using a *BCI* to control electronic devices. Looking ahead, these systems can be used in other applications, mainly for multimedia purposes.

The purpose of this work is study the *EEG* characteristics, the signal processing and pattern recognition techniques in order to use in a Brain Computer Interface (*BCI*) For this, will be used a international data base, in order to compare our results with results of other international groups.

In this context, this work describes the human brain and the *EEG* characteristics relevant to *BCI* understanding. Moreover, it presents the implementation of a pattern recognition system, which is able to classify the motor imagination laterality with accuracy over 85%.



## 1 INTRODUÇÃO

Uma das características mais importantes da raça humana que a distingue das demais é a capacidade de se comunicar. Incontestavelmente, a comunicação entre duas pessoas é a mais rica e mais complexa forma de transmissão de informação [1]. Por via de regra, a transmissão da informação entre pessoas é realizada através de um processo de codificação e decodificação da intenção do que se quer transmitir. A codificação é feita transformando a informação a ser transmitida em algum tipo de movimento muscular como, por exemplo, o das cordas vocais ou gestos faciais e a decodificação é realizada fazendo uso de sensores especialmente desenvolvidos para captar os sinais gerados.

Com o avanço tecnológico, uma nova forma de comunicação surgiu: a comunicação entre homens e máquinas. Atualmente, diversos grupos de pesquisa em todo o mundo buscam desenvolver sistemas que reconheçam e interpretem sinais de comunicação gerados por um indivíduo, para ser então usado como sinal de controle em computadores [6][48], aplicando, para isto, diversas técnicas. Entretanto, tais técnicas necessitam que o usuário transforme sua intenção em algum tipo de movimento muscular (cordas vocais, dedos, movimento dos olhos, etc). Este movimento é então decodificado por um sistema especialmente desenvolvido para este fim, para ser usado como sinal de controle. Pode-se citar como exemplos o reconhecimento automático de voz ou imagens.

Contudo, pessoas com Esclerose Lateral Amiotrófica (*ELA*), tumores na Medula Espinhal, alguns tipos de Distrofia Muscular e outros tipos de deficiência, são incapazes de realizar praticamente qualquer atividade muscular voluntária, mantendo somente a sua capacidade cognitiva [5]. Como essas pessoas não podem utilizar os meios de comunicação usuais, tampouco as técnicas citadas anteriormente, elas não interagem com o ambiente externo e, portanto, podem passar a vida em um estado de completo isolamento. Nesses casos, os sinais de controle devem ser obtidos diretamente da fonte geradora de nossas vontades e emoções, ou seja, o cérebro.

A medição da atividade elétrica do cérebro tornou-se possível com o desenvolvimento da tecnologia de captura de sinais cerebrais. A primeira forma de medição da atividade cerebral de uma maneira não invasiva foi o registro eletroencefalográfico realizado por Hans Berger em 1924 [19]. Em um primeiro momento, este sinal foi utilizado principalmente para avaliar desordens neurológicas na análise clínica [1][35][54][93] e para a investigação das funções cerebrais. Posteriormente, alguns outros estudos também surgiram investigando o seu uso para funções terapêuticas [88]. No entanto, com o barateamento dos equipamentos envolvidos, novas perspectivas e desafios surgiram, como, por exemplo, as Interfaces Cérebro-Computador [7][62][73][88][89][74][10].

Recentemente, grupos de pesquisas de todo o mundo têm buscado meios para a utilização dos sinais cerebrais como forma de comunicação. Contudo, o cérebro humano é um grande desafio, devido principalmente à sua função coordenadora do corpo humano e à grande quantidade de sinais envolvidos. Dentre os possíveis métodos de extração de sinais cerebrais, o Eletroencefalograma (*EEG*) é o que vem sendo utilizado em maior escala e é também o mais promissor [89], como veremos no Capítulo 3.

Apesar do sinal *EEG* refletir a atividade cerebral, o que poderia fazer com que a intenção de uma pessoa pudesse, em teoria, ser detectada através de sua análise, o uso do sinal *EEG* como um canal de comunicação entre homens e máquinas representa um dos desafios atuais na pesquisa de processamento de sinais. O desafio é devido ao fato da resolução e a confiabilidade da informação detectada em uma gravação *EEG* ser limitada pelo vasto número de elementos neuronais eletricamente ativos, pela geometria da cabeça e do cérebro, que mistura e espalha as informações das fontes de uma maneira complexa, e pela desconcertante variabilidade intra-gravações, intra-classes e inter-classes [88]. A possibilidade de se reconhecer uma simples mensagem ou um comando em meio a esta complexidade, distorção e variabilidade parece ser extremamente remota [88].

As técnicas de processamento de sinais e reconhecimento de padrões apresentam uma importância crucial no desenvolvimento de uma Interface Cérebro-Computador (*ICC*), que será melhor definida no Capítulo 4. Até recentemente, vários progressos têm sido feitos nesta área, mas nenhum suficientemente bem sucedido para o uso em um sistema real.

Assim sendo, o problema que se pretende resolver nesta dissertação é o reconhecimento de padrões de dois estados mentais relacionados às seguintes tarefas motoras: movimento dos dedos da mão esquerda e movimento dos dedos da mão direita. A importância deste problema está no fato de que estes estados mentais estão associados à imaginação de movimentos sem que o usuário tenha que realmente realizá-lo, o que é bastante útil para as pessoas desprovidas da capacidade de movimentar-se. Será dado um enfoque especial ao sistema de reconhecimento de padrões, dado que este é um ponto crucial para o funcionamento de uma *ICC*.

O objetivo desta dissertação é estudar as características do sinal eletroencefalográfico, assim como técnicas de processamento de sinais e de reconhecimento de padrões para uso em uma interface cérebro computador (*ICC*). Especificamente, as técnicas avaliadas estão relacionadas ao problema acima exposto, ou seja, determinação de dois estados mentais relacionados à imaginação de tarefas motoras.

Para tanto, será utilizado um banco de dados internacional, a fim de que a eficácia da técnica empregada possa ser avaliada com mais propriedade, comparando-se os resultados alcançados com aqueles obtidos por outros grupos de pesquisa internacionais. Além disso, será desenvolvido um estudo dos fatores que caracterizam uma *ICC* com o fim de cooperar com as pesquisas que se iniciam no Departamento de Engenharia Elétrica da *UFES*, no mesmo tema deste trabalho.

## 1.1 Sistemas de Reconhecimento de Padrões

O reconhecimento de padrões é um dos tópicos mais desafiadores em se tratando da capacidade cognitiva de um ser humano [78]. Para um indivíduo, o fato de reconhecer padrões é uma tarefa constantemente exercitada de diversas formas, reconhecendo desde padrões visuais a padrões de origem táteis.

No entanto, para um sistema de computadores, o reconhecimento de padrões não é uma tarefa tão simples, principalmente devido à ausência da capacidade de generalização e abstração, o que é preponderante nos seres humanos. A capacidade de generalização dos seres humanos é diretamente relacionada à capacidade de processamento paralelo, característica típica dos nossos “circuitos neuronais” [8].

Um sistema computacional de reconhecimento de padrões pode ser visto como um conjunto *hardware* de e *software* capaz de realizar uma tarefa de decisão, a qual consiste em associar uma determinada medição a uma determinada classe [32]. O homem é capaz de realizar esta tarefa com uma alta taxa de acertos para uma medição de dimensão reduzida e com baixo nível de ruído.

A aplicação de técnicas de Inteligência Artificial (*IA*), associadas com a alta capacidade de processamento computacional tem tornado possível o reconhecimento de padrões de sinais de dimensão elevada e altamente ruidosos, às custas de algoritmos mais complexos.


No contexto do reconhecimento de padrões para sinais *EEG* aplicados às Interfaces Cérebro-Computador, o problema se torna ainda mais complexo. Como será demonstrado no decorrer deste trabalho, o sinal eletroencefalográfico é altamente contaminado por ruídos das mais variadas fontes e formas, sendo que em boa parte das vezes, o ruído presente no sinal se torna maior do que o próprio sinal que se quer classificar.

Além da baixa relação sinal ruído, outro fator a se considerar é a alta dimensionalidade dos dados. Como o sinal *EEG* adquirido sobre o escalpo é uma

mistura de fontes elétricas, sendo que esta mistura é feita espalhando e atenuando as fontes sobre o escalpo, é necessário que tenhamos informações das mais variadas posições, a fim de se obter a maior quantidade de informação possível para que seja realizada a correta classificação. Para efeito de ilustração, o sinal eletroencefalográfico utilizado neste estudo possui 28 canais, ou seja, ele é mapeado em um espaço de dimensão 28.

Deve-se ainda considerar que a classificação tem que ser realizada em um espaço de tempo curto, para que o usuário não tenha que esperar um tempo demasiado, a fim de gerar um sinal para controlar um determinado equipamento.

Outro fator a se considerar é a grande variabilidade entre gravações inter-classes e intra-classes. Para fins de ilustração, a Figura 1.1 representa gravações do sinal de *EEG* de 28 canais. O sinal plotado possui 4 épocas de 500 amostras com taxa de amostragem de 1.000 Hz. Em cada uma das épocas, o usuário realizou tarefas mentais de imaginar, sem realizar, o movimento do dedo da mão esquerda ou da mão direita. Observe, na Figura 1.1, que visualmente é extremamente difícil realizar a classificação. O eixo das ordenadas indica a localização de cada um dos 28 canais no escalpo, e o eixo das abscissas indica as 4 épocas, com 500 amostras cada.



Épocas 1 e 3: tarefa de imaginar movimentação do dedo esquerdo.  
 Épocas 2 e 4: tarefa de imaginar movimentação do dedo direito.

**Figura 1.1 - Gravação do sinal EEG com 28 canais para 4 épocas**

## 1.2 Estrutura da Dissertação

Esta dissertação está organizada da seguinte forma: para obtermos um melhor entendimento sobre o que será discutido nos capítulos seguintes, o Capítulo 2 descreve o funcionamento e a anatomia do cérebro humano, discutindo os tópicos relevantes para o entendimento das *ICCs*. O Capítulo 3 discute os aspectos relativos ao sinal eletroencefalográfico, desde a aquisição às características estatísticas relevantes. No Capítulo 4 são discutidas as características e o estado da arte das *ICCs*. No Capítulo 5 é apresentado o sistema de reconhecimento de padrões implementado e são discutidas as técnicas utilizadas neste sistema. Os resultados obtidos desta pesquisa são discutidos no Capítulo 6, enquanto que as conclusões e projetos futuros são apresentados no Capítulo 7.

## **2 ANATOMIA DO CÉREBRO HUMANO**

O cérebro é basicamente constituído por água e gordura [71]. A combinação destes elementos é que nos permite andar e conversar, rir e chorar, amar, odiar, criar ou destruir. Tudo que fazemos é mediado pelo nosso cérebro. Ele é que nos guia durante nossa vida, sendo o órgão responsável pelo controle das funções vitais humanas. Este capítulo é devotado para uma análise simplificada deste complexo órgão, dando ênfase aos fatores relevantes para interfaces cérebro-computador. Para o leitor que desejar obter mais informações sobre o cérebro humano, sugere-se [43].

Assim como nos demais tecidos, as estruturas básicas do cérebro são as células. O cérebro é formado por dois tipos principais de células, os neurônios e as células gliais. As células gliais representam a maior parte das células existentes no sistema nervoso central humano (cerca de 10 a 50 vezes mais que os neurônios) [43]. Contudo, nos estudos da atividade elétrica do cérebro, estas células recebem menor atenção, devido ao fato de não haver evidências de processamento de sinais elétricos. Segundo [43], as células nervosas (neurônios) têm a função de processamento de informação enquanto as células gliais têm como função dar suporte ao funcionamento dos neurônios.

O neurônio é a célula computacional fundamental do cérebro [82]. Eles são especializados em receber, armazenar e transmitir informação [71], como será analisado adiante.

### **2.1 O Neurônio**

O sistema nervoso central contém mais de 100 bilhões de neurônios [37]. Para os diferentes tipos de neurônios, pode haver de algumas centenas até 200.000 conexões com outras células neuronais [37]. Existem vários tipos de neurônios, que se diferenciam pela função, tamanho e forma; exemplos típicos

são os neurônios sensoriais, neurônios motores e os neurônios piramidais corticais [84].

Apesar da grande quantidade de formas diferentes, a maioria dos neurônios é constituída por um corpo central, conhecido por corpo celular ou soma, de onde sai uma espécie de cauda chamada axônio e estruturas parecidas com raízes, conhecidas como dendritos ou árvores dendríticas [84]. Um neurônio pode ser visualizado na Figura 2.1 e as partes constituintes são melhor descritas em seguida.




Figura 2.1 – Imagem de um neurônio obtida por um microscópio [67].

**Corpo celular (ou soma):** Esta parte contém todos os componentes necessários da célula, tais como o núcleo (que contém o *DNA*), o retículo endoplasmático e os ribossomos (que constroem as proteínas), e a mitocôndria (que produz a energia). Se o corpo celular morre, o neurônio também morre [66].

**Axônio:** É uma espécie de cauda que o neurônio possui e que transporta a mensagem eletroquímica (impulso nervoso ou potencial de ação) através da célula. Dependendo do tipo de neurônio, os axônios podem ser recobertos com uma camada de mielina, tal qual como um cabo elétrico isolado. A mielina é uma espécie de gordura que ajuda na velocidade de transmissão do impulso nervoso



sobre o axônio. Neurônios mielinizados são encontrados tipicamente em nervos periféricos (neurônios motores e sensoriais), enquanto que os sem mielina são mais comuns no cérebro e na coluna espinhal [66].

**Dendritos:** São pequenas ramificações da célula que fazem conexões com outros neurônios. Dendritos podem ser localizados em uma ou todas as terminações da célula [84].

As partes acima descritas podem ser visualizadas na Figura 2.2.




Figura 2.2 - Estrutura de um neurônio [14].

O neurônio é recoberto por uma camada não condutora, conhecida como membrana celular. Essa camada possui mecanismos que transportam íons entre a parte interna e externa da célula. Os mecanismos de transporte iônico podem funcionar de uma forma ativa, como bombas de íons, ou passiva, através da difusão de íons através da membrana [63]. Esses dois mecanismos criam um desequilíbrio entre as concentrações de diferentes espécies de íons, dentro e fora do neurônio [37]. As mais importantes dentre as espécies iônicas são os íons de Potássio  $K^+$ , Sódio  $Na^+$  e Cloro  $Cl^-$  [84].

A diferença na concentração iônica entre o meio intracelular e o meio extracelular cria uma diferença de cargas elétricas e, portanto, uma voltagem elétrica através da membrana, conhecido como potencial de membrana [63]. Como, por convenção, o potencial fora da célula é definido como zero, o potencial de membrana é negativo, pois a célula neuronal tem excesso de cargas positivas na face externa da membrana e de cargas negativas na sua face interna [63].

### **2.1.1 Transmissão da Informação**

Os neurônios transmitem informação através de sinais elétricos, chamados de potenciais de ação. Estes potenciais são conduzidos através dos axônios e as conexões são realizadas através das sinapses [63].

Para que um potencial de ação ocorra, é necessário que haja uma diminuição da negatividade intracelular, ou seja, que o potencial de membrana aumente. Quando o potencial de membrana atinge um valor acima de um certo limiar, o neurônio disparará um potencial de ação que é essencialmente uma onda de corrente que flui através do corpo celular em direção ao axônio.


Normalmente, a membrana em repouso não permite a ocorrência de um potencial de ação, a não ser que alguma interferência altere seu potencial de repouso, deixando-o menos negativo [63]. Esta interferência pode ser provocada por um potencial de ação proveniente de outro neurônio e transmitido através de conexões sinápticas que são mecanismos de transmissão elétrica de informação entre dois neurônios através de substâncias chamadas de neurotransmissores.

Os neurotransmissores afetam a célula destino de modo específico, alterando o funcionamento da condução iônica através da membrana celular [43]. Isto pode causar um de dois possíveis resultados, que classificam os neurônios em duas classes separadas: o neurotransmissor pode fazer com que o potencial do corpo celular do neurônio receptor se torne menos negativo; isto implica que o potencial de ação veio de um estímulo excitatório; de outra forma, o neurotransmissor pode fazer com que o potencial do corpo celular do neurônio receptor se torne mais negativo, o que sugere que o potencial de ação veio de um neurônio com ação inibitória.

## 2.2 O Cérebro

O cérebro é uma das partes do Sistema Nervoso Central (*SNC*). Ele é o órgão mais desenvolvido da espécie humana, sendo o responsável por todas as funções superiores da espécie, como aprendizado, controle motor e planejamento [31]. Ele é envolvido pelo líquido cerebrospinal que mantém o cérebro em condições de trabalho ótimas e possibilita uma plataforma estável para o cérebro funcionar [65].

Anatomicamente, o cérebro é dividido pela fissura longitudinal em dois hemisférios: o esquerdo e o direito. Através de pesquisas de mapeamento das funções cerebrais, é conhecido que, de uma forma geral, o hemisfério direito recebe sensações e controla o movimento do lado esquerdo do corpo, enquanto que o hemisfério esquerdo recebe sensações e controla o movimento do lado direito do corpo [55], como demonstrado na Figura 2.3. A comunicação entre os dois hemisférios cerebrais é feita, quase que completamente, por uma parte do cérebro chamada de corpo caloso [50].



**Figura 2.3 – Visão superior do Córtex Cerebral. O mapeamento motor do cérebro é feito de uma forma cruzada. Adaptado de [14].**

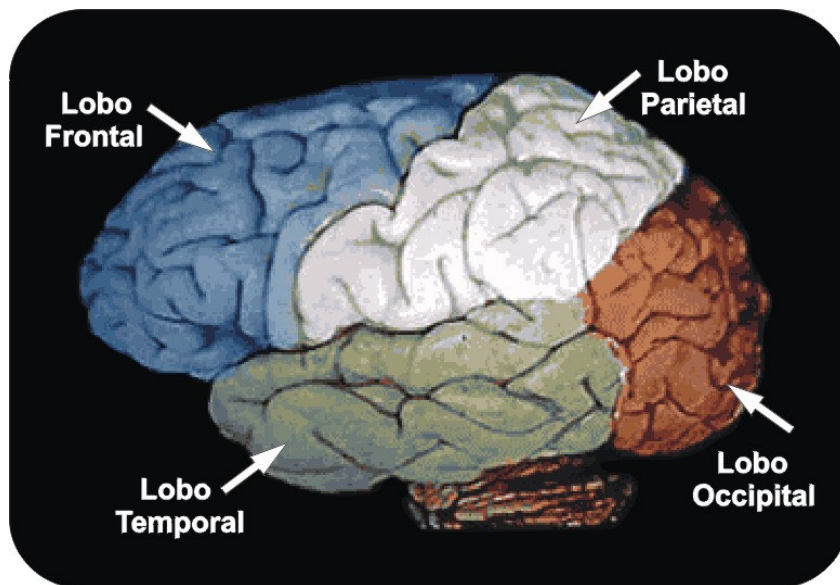
Como veremos adiante, a parte externa do cérebro, conhecida como Córtex Cerebral, é a parte do cérebro mais importante para o estudo das Interfaces Cérebro-Computador. O motivo disto é que, apesar de que todo o cérebro gera atividade elétrica, o córtex cerebral é a parte mais evidente nas técnicas de medição de atividade cerebral [87]. Além disso, este está associado ao processo do pensamento, do armazenamento das nossas memórias e nossa capacidade de aprendizado, seja ele cognitivo ou motor [31]. Por este motivo, dentre todas as partes do sistema nervoso, nos reservaremos ao estudo do córtex.

### 2.3 O Córtex Cerebral

O córtex é uma camada fina (1,5 a 4 mm) de substância cinzenta que cobre a superfície exterior do cérebro [87]. De acordo com [55] trata-se de uma das partes mais importantes do sistema nervoso, segundo a afirmativa: *“No córtex cerebral chegam impulsos provenientes de todas as vias da sensibilidade que aí se tornam conscientes e são interpretadas. Do córtex saem os impulsos nervosos que iniciam e comandam os movimentos voluntários e com ele estão relacionados os fenômenos psíquicos. Durante a evolução, a extensão e complexidade do córtex aumentaram progressivamente, atingindo maior desenvolvimento na espécie humana, o que pode ser correlacionado com o grande desenvolvimento das funções intelectuais nesta espécie.”* [55].

O córtex cerebral humano pode ser classificado sob aspectos anatômicos, filogenéticos, estruturais e funcionais. A importância da classificação para este trabalho envolve somente os critérios funcionais e anatômicos. Remete-se os interessados a informações adicionais para [55].


Como citado anteriormente, o cérebro é formado por dois hemisférios, o esquerdo e o direito. Cada um dos hemisférios cerebral é dividido, anatomicamente, em quatro lobos (vide Figura 2.4): Lobo Frontal, Lobo Parietal, Lobo Temporal e Lobo Occipital.



**Figura 2.4 - Visão lateral do hemisfério esquerdo. Localização dos quatro lobos cerebrais. Adaptado de [14].**

Esta divisão, apesar da importância clínica e da localização de eletrodos, não corresponde a uma divisão funcional, exceto pelo lobo occipital, que parece estar todo, direta ou indiretamente relacionado com a visão [71]. Várias pesquisas em todo o mundo [3] buscam criar um mapeamento da localização das funções cerebrais. As pesquisas iniciaram em 1861 pelo cirurgião francês Broca [58] e desde então foram desenvolvidas tentando-se, desta forma, criar uma divisão funcional.

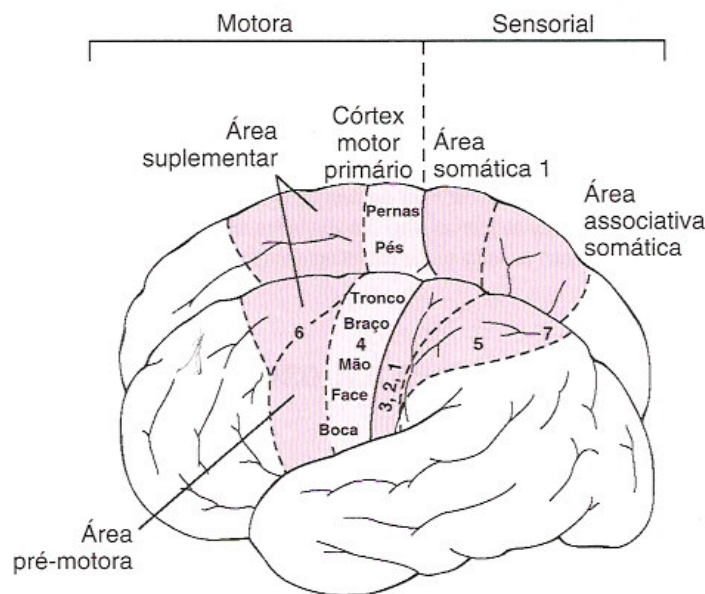
No entanto, a existência de localizações funcionais deve ser considerada como uma especialização funcional de determinada área e não como um centro isolado e estanque. Com isso, temos uma espécie de processamento distribuído que apresenta um centro como referência. Dentre as áreas de especialização do córtex, pode-se citar a área de Broca, responsável pela formação das palavras [55]; o lobo occipital, relacionado com a parte visual; e o córtex somatosensorial, que recebe informação de praticamente todos os sensores da pele (tais como pressão, contato e dor) [87]. Iremos concentrar os estudos na área funcional especializada em tarefas motoras, devido à sua importância no desenvolvimento da ICC. Para mais informações a respeito da divisão funcional favor consultar a Figura 2.5, ou recorrer a [37].



**Figura 2.5 - Localização de áreas funcionais responsáveis por tipos específicos de movimentos [37].**

O Córtex Motor está localizado na área anterior do sulco cortical central, ocupando aproximadamente um terço dos lobos frontais. Esta parte é responsável pelo controle dos movimentos voluntários. O mapeamento desta região em um dos hemisférios se dá com o lado oposto do corpo, de forma que lesões nesta parte do cérebro causa paralisia parcial no lado oposto do corpo [87].


O córtex motor é dividido em outras três áreas: (1) córtex motor primário, (2) área pré-motora e (3) área motora suplementar. A Figura 2.6 apresenta a localização destas áreas.



**Figura 2.6 - Áreas funcionais motoras e somatossensoriais do córtex cerebral [37].**

O córtex motor primário é diretamente relacionado com os movimentos voluntários. Apesar do pouco conhecimento que se tem sobre esta área, Penfield e Rasmussen [21] fizeram um mapeamento das áreas musculares do corpo no córtex motor primário, conforme é apresentado na Figura 2.6.

Essa organização funcional é apresentada de uma forma mais representativa na Figura 2.7. Esse mapeamento foi realizado pela estimulação elétrica das diferentes áreas do córtex motor em pessoas que estavam submetidas a grandes operações neurocirúrgicas. É importante ressaltar, neste ponto, a grande área utilizada para controlar o movimento da mão. Isto pode explicar porque geralmente a tarefa motora de imaginar o movimento das mãos é usada para gerar padrões diferentes no *EEG*.



**Figura 2.7 - Grau de representação dos diferentes músculos do corpo no córtex motor [37].**

A área pré-motora tem por função dar suporte aos movimentos discretos gerados no córtex motor primário. Este suporte corresponde, por exemplo, a mover os ombros e braços para que a mão realize determinada tarefa. Para conseguir tal resultado, a área pré-motora cria uma “imagem motora” do movimento muscular a ser realizado. Os sinais associados a este movimento são enviados ao córtex motor primário, para excitar múltiplos grupos de músculos para a realização da tarefa.

## 2.4 Medição da Atividade Elétrica do Cérebro

O estudo das funções cerebrais humanas dependeu, durante muito tempo, de medidas e observações em animais, já que o uso de ferramentas invasivas tornava perigosas e antiéticas as pesquisas em seres humanos [4]. Atualmente, o desenvolvimento da tecnologia tornou possível a medição de uma forma não-invasiva, o que torna seguro e prático a utilização por seres humanos.



Detalhes anatômicos do cérebro passaram a ser observados sem riscos para o paciente através de técnicas de imagens médicas, como a Tomografia Computadorizada (*TC*) e a Ressonância Magnética (*RM*) [3].

No entanto, o estudo das funções cerebrais nem sempre é possível pela simples análise estrutural. Surgem, então, as neuroimagens funcionais, que procuram mostrar o cérebro em funcionamento. Vários métodos podem ser utilizados para a obtenção da atividade cerebral. Isso inclui, por exemplo, Imagem de Ressonância Magnética Funcional (*IRMf*), Magnetoencefalografia (*MEG*), Tomografia por Emissão de Pósitrons (*PET*, do inglês Positron Emission Tomography) e Eletroencefalografia (*EEG*) [3].

A Eletroencefalografia é o método mais antigo para a detecção de atividade elétrica cerebral, e consiste na medição da diferença de potencial em um par de eletrodos que é fixado na superfície do escalpo. Devido à sua importância para as Interfaces Cérebro-Computador, é dedicado o Capítulo 3 para o estudo desta técnica.

Já com respeito à Magnetoencefalografia (*MEG*), conforme o próprio nome indica, refere-se ao estudo dos campos magnéticos gerados pelo cérebro. A atividade neuronal caracteriza-se pela passagem de corrente elétrica ao longo da sua estrutura, e esta corrente provoca o aparecimento de um campo magnético de baixíssima intensidade. O sinal magnético que é capturado pelo aparelho é produzido pela ativação de cerca de 10 mil neurônios simultaneamente [3].

A maior vantagem da *MEG* está em seu poder de localização das fontes geradoras de atividade elétrica [3]. Com esta técnica é possível localizar, com um erro da ordem de milímetros, a atividade neuronal e, portanto, associar esta localização a uma determinada atividade mental. Como os campos magnéticos a serem medidos possuem baixíssima intensidade, a atividade neuromagnética só pode ser medida adequadamente através de dispositivos supercondutores conhecidos como *SQUID* (do inglês Superconducting Quantum Interference Device) [3].

Há uma relação entre a presença de atividade cerebral em uma determinada região do cérebro e o aumento da quantidade de oxigênio local. Em consequência, durante os estados de atividade cerebral, ocorre uma alteração local da razão entre a Hemoglobina Oxigenada (*oxi-Hb*) e a Hemoglobina Desoxigenada (*deoxi-Hb*). Além disso, sabe-se que a *deoxi-Hb* e a *oxi-Hb* possuem características magnéticas distintas: a primeira é paramagnética e a segunda é diamagnética [34]. Devido a esta alteração, diferentes regiões do cérebro apresentam características magnéticas distintas.

A Imagem Funcional por Ressonância Magnética (*IRMf*, ou do inglês, *fMRI* - functional Magnetic Resonance Image) é uma tecnologia de diagnósticos por imagem que utiliza um potente magneto e ondas de rádio-freqüência para produzir fotos ou “imagens” de estruturas e órgãos internos. Como cada região cerebral apresenta característica magnética diferente, e que, de uma forma indireta, demonstra a presença de atividade cerebral ou não, é possível obter um mapeamento funcional do cérebro [3].

A Tomografia Computadorizada é um método que utiliza radiofármacos, drogas que contêm átomos radioativos (com núcleos instáveis) injetados na corrente sanguínea. Esses núcleos têm a tendência natural de decair para estados de mais baixa energia (mais estáveis), fenômeno geralmente seguido pela emissão de partículas e radiação. No caso da Tomografia por Emissão de Pósitrons (*PET*), os radiofármacos utilizados emitem pósitrons que, ao colidir com elétrons, emitem radiação gama [81] a qual é capturada por sensores que envolvem o paciente. O acúmulo de sinais provenientes de inúmeros sensores determina a localização precisa da área emissora [3].

Todas estas técnicas são bastante empregadas no estudo dos processos cognitivos para se fazer o mapeamento de atividades cerebrais em uma determinada região do cérebro [29]. No entanto, essas técnicas apresentam característica de resolução tempo-espaco diferente, como apresentado na Figura 2.8. Como se pode perceber, o *EEG* apresenta uma ótima resolução temporal, já que o acontecimento de um determinado evento pode ser capturado na ordem de

$10^{-3}$  segundos, enquanto que outras técnicas necessitam de um tempo maior para apresentar a ação de um determinado evento, como exemplo pode-se citar a *TC* que necessita de 0,1 a 1,0 segundo. No entanto, a resolução espacial do sinal *EEG* não é muito satisfatória, uma vez que para a localização do evento há um erro de aproximadamente 27 a 34 mm, enquanto que na *TC* o erro é menor do que 1 cm.




Figura 2.8 - Resolução espacial / temporal dos métodos utilizados para a obtenção da atividade cerebral. Adaptado de [42].

Apesar de todas estas técnicas serem utilizadas para se monitorar a atividade cerebral, somente o *EEG*, que pode ser facilmente adquirido e processado de uma forma mais barata, parece fornecer a possibilidade prática de um canal de comunicação e controle [89]. Apesar da sua baixa resolução espacial, o reconhecimento de atividades cerebrais específicas pode ser melhorado utilizando algoritmos projetados para este fim.

No entanto, de acordo com o exposto anteriormente, as técnicas que aparentemente não fornecem a possibilidade para uso em uma *ICC* não podem ser taxadas como inúteis para tal fim e sim pelo contrário. O avanço da pesquisa em campos da Neurociência que investigam localização de funções cerebrais e que utilizam técnicas tais como a *MEG* e a *PET* influenciam de uma maneira positiva o avanço das *ICCs*.

### 3 ELETROENCEFALOGRAFIA

Desde a antiguidade, o cérebro humano é uma fonte de fascínio para a área médica e filosófica. Com isto e graças a diversos pesquisadores, foi desenvolvido um conhecimento de uma forma lenta e progressiva da fisiologia do cérebro. Apesar disto, o homem não se saciou com o entendimento da construção anatômica do cérebro e passou a querer entender como um órgão tão frágil realiza tantas tarefas complexas. A partir deste momento nasceu um campo de pesquisa multidisciplinar chamado de Neurociência.

A natureza elétrica do sistema nervoso humano já é conhecida por mais de um século [66]. Um dos pioneiros neste estudo foi um jovem estudante alemão chamado Hans Berger (1873 – 1941) que, após um acidente sofrido em 1893, acreditava que os pensamentos humanos poderiam, de alguma forma, ser transmitidos através de telepatia. Esta hipótese foi levantada após sua família ter enviado um telegrama perguntando sobre sua saúde, o que não era comum, justamente no dia em que sua irmã, sem saber dos acontecimentos, relatou que estava certa que o irmão havia sofrido um acidente [5] e, realmente neste dia, ele havia caído do cavalo. Em 1924, Hans Berger usou um equipamento de rádio para amplificar a atividade elétrica do cérebro medida no escalpo humano. Ele mostrou que pequenas correntes elétricas geradas no cérebro podem ser capturadas sem abrir o crânio, e representá-las graficamente em um papel. Para mais informação sobre o histórico do *EEG* consulte [19].

#### 3.1 Introdução

A Eletroencefalografia é uma medida da atividade elétrica gerada pelo cérebro através de eletrodos colocados sobre a superfície do escalpo. A consideração fundamental do sinal *EEG* é que este reflete a dinâmica da atividade elétrica de populações de neurônios. Para que a atividade elétrica possa ser detectável através dos eletrodos no escalpo, os neurônios de uma população

devem ser interconectados e trabalhar em uma espécie de sincronia. Esta população recebe o nome de *massa neural* e é melhor discutida em [82]. Uma massa neural geralmente consiste de  $10^4$  a  $10^7$  neurônios [65].

Estes conjuntos são os que basicamente geram a atividade oscilatória medida pelo sinal eletroencefalográfico. No entanto, como a medição é realizada sobre o couro cabeludo, o processo que gera o *EEG* é muito complexo devido a vários fatores, dentro os quais citamos:

- Ainda não é muito bem entendido o processo de divisão das populações de neurônios discutida acima;
- As camadas do líquido cefalorraquidiano, do próprio cérebro, do crânio e da pele resultam em uma forte atenuação e em um alto espalhamento das diversas componentes das fontes de atividade elétrica cortical e que resultam no potencial gravado sobre o escalpo;
- A variabilidade entre gravações de sinal *EEG* é muito grande;
- A relação sinal-ruído é muito baixa, sendo que em muitas vezes o ruído pode mascarar totalmente o *EEG*.

Desta forma, apesar de ter surgido há muito tempo, como discutido anteriormente, o *EEG* só passou a desempenhar um papel fundamental nos estudos dos processos cerebrais complexos nos últimos anos, com o desenvolvimento de dispositivos eletrônicos mais precisos e técnicas de processamento de sinais eficientes. Atualmente, a sua aplicação clínica é vasta, abrangendo áreas desde o diagnóstico de epilepsias [1][23][35][54][63][80][91] até o estudo de distúrbios do sono [40][46][92].

Quando o sinal é adquirido diretamente sobre a superfície do córtex, este é chamado Eletrocorticograma (*ECoG*). O *ECoG* é um método invasivo que obtém o sinal da atividade elétrica sobre um pequeno grupo de neurônios. Este

método possui a vantagem de uma Relação Sinal-Ruído muito maior e de uma melhor localização da atividade elétrica, no entanto ele normalmente não é utilizado em seres humanos, devido ao fato de ser extremamente invasivo em uma região extremamente frágil. Uma revisão a respeito do uso do *ECoG* para interfaces Cérebro-Computador é feita em [27].

### 3.2 Aquisição do *EEG*

As flutuações de potenciais sobre o escalpo, que refletem a atividade elétrica do cérebro, são adquiridas utilizando pequenos eletrodos metálicos. Apesar do número de eletrodos variar de estudo para estudo, normalmente eles são localizados em posições específicas, de acordo com o sistema internacional de localização de eletrodos 10-20.

A amplitude da voltagem registrada depende de muitos fatores de natureza neurofisiológica, no entanto, como citado em [84], as maiores contribuições para a flutuação de potencial adquirido no escalpo são devidos às variações de potenciais que:

- Ocorrem em regiões próximas ao eletrodo;
- São gerados sobre o córtex por neurônios do tipo piramidal;
- São geradas em uma grande área.

Esta seção discutirá rapidamente os tópicos relacionados à aquisição do sinal, contudo, para maiores informações consulte [24][63][83].

#### 3.2.1 Equipamento

O equipamento que realiza a medição do *EEG* é denominado Eletroencefalógrafo. Quando foi criado, o registro era gravado na superfície de uma tira de papel que se deslocava a uma velocidade constante [80]. Atualmente, existem muitos equipamentos comerciais de *EEG* em uso e, com o avanço da

informática e das técnicas digitais, o registro passou a ser gravado e apresentado de uma forma digital em microcomputadores do tipo *PC*, que podem ser facilmente operados por técnicos.

Basicamente, estes equipamentos são constituídos por eletrodos que adquirem o sinal e por etapas de amplificação, filtragem e digitalização do sinal. A Figura 3.1 apresenta as etapas de processamento de *EEG* e cita algumas características típicas para o uso em uma *ICC*.

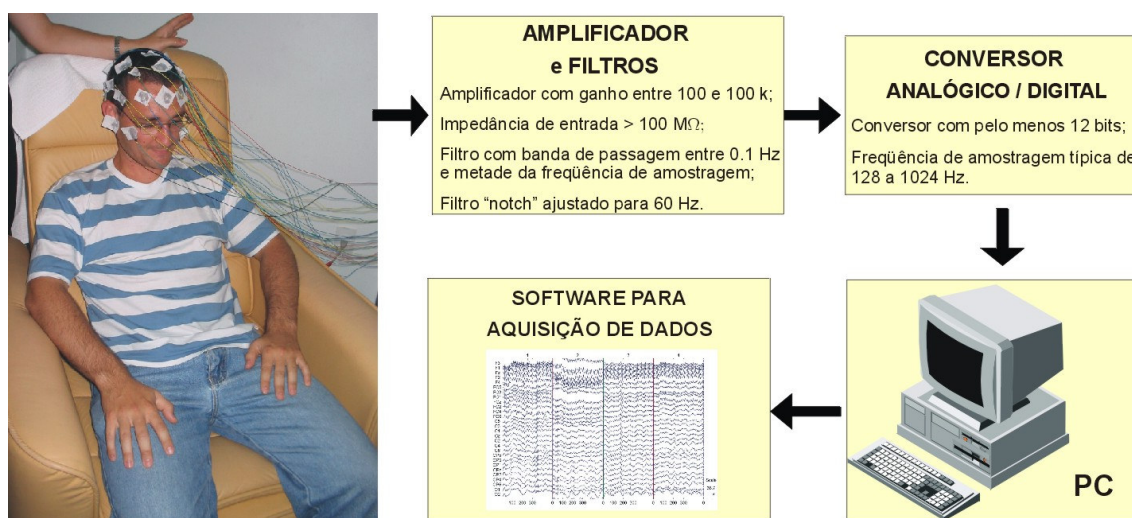



Figura 3.1 - Sistema de aquisição do sinal *EEG*.

### 3.2.2 Eletrodos

O eletrodo é uma pequena placa metálica que, em contato com a pele, captura a atividade elétrica sobre o escalpo, transformando-a em variação de potencial a ser amplificada e digitalizada pelo restante do equipamento. Devido à necessidade de redução do ruído, os eletrodos necessitam de uma atenção especial para a aquisição do sinal *EEG*. Normalmente, é utilizado um gorro de eletrodos para uma melhor fixação no escalpo. Além disso, também é utilizado um gel eletrolítico entre o eletrodo e a pele para melhorar o contato elétrico, diminuindo, desta forma, a impedância entre a interface eletrodo-pele [87].



Por motivos de uma melhor padronização da medição e localização de eletrodos na cabeça, em 1949 a Federação Internacional de Eletroencefalografia e Neurofisiologia Clínica (*IFSECN - International Federation of Societies for Electroencephalography and Clinical Neurophysiology*) criou um padrão que foi adotado internacionalmente e é conhecido como Sistema Internacional 10-20 de Localização de Eletrodos. Este sistema, constituído por 21 eletrodos, padronizou a localização física e a nomenclatura dos eletrodos no escalpo. Com isto, tornou-se possível a comparação de resultados obtidos por pesquisadores de uma forma mais consistente, já que se consegue de uma maneira simples descrever os locais em que foram obtidos os sinais.



**Figura 3.2 – Sistema Internacional 10-20 para a colocação de eletrodos.**

Neste sistema, os eletrodos são dispostos mantendo distâncias proporcionais entre pontos anatômicos específicos (pontos pré-auriculares, glabella e protuberância occipital) [63], que servem como referência para a localização de cada eletrodo. O nome “10-20” é devido à distância que é mantida entre os pontos anatômicos e os eletrodos (10%) e a distância entre os eletrodos (20%). A localização dos eletrodos recebe um rótulo de acordo com a região cerebral em que se encontra o eletrodo: F (Frontal), Fp (Frontoposterior), C (Central), P (Parietal), T (Temporal), O (Occipital). Estas letras são acompanhadas por números ímpares para eletrodos no lado esquerdo do cérebro

e pares para aqueles localizados no lado direito. Quando estes números são substituídos pela letra 'z' o eletrodo está localizado na linha central. Baseado no princípio do sistema 10-20, é comum encontrar modificações para aumentar a resolução do *EEG*, dentre eles pode-se citar o sistema 10-10 e o sistema 10-5 [84].

### 3.3 Artefatos

Por causa da pequena amplitude do sinal medido na superfície do escalpo, o *EEG* é facilmente corrompido por outros sinais elétricos. Estes sinais ruidosos, não desejados, e de origem não cerebral são chamados de artefatos, ou ruídos de artefatos. Para facilitar a interpretação do sinal *EEG*, faz-se necessário minimizar ou, idealmente, remover a presença destes ruídos que apresentam duas fontes principais, a saber: artefatos de origem técnica e artefatos de origem fisiológica.

#### 3.3.1 Artefatos de Origem Técnica

Artefatos de origem técnica são ocasionados devido à interferência elétrica externa ou ao mau funcionamento do aparelho de registro do *EEG* (eletrodos, cabos, amplificador, filtros) [63]. Dentre os principais, podemos citar os seguintes:

**Artefato de Linha:** Interferência eletromagnética proveniente de fontes de tensão AC pode corromper o sinal quando este é transferido dos eletrodos para o amplificador. Este artefato apresenta a frequência típica de 50 ou 60 Hz, dependendo da frequência de alimentação da tensão alternada. Por apresentar frequência definida e estar em uma faixa de frequência que aparentemente não apresenta informação importante no sinal *EEG*, este ruído pode ser filtrado usando filtros corretamente parametrizados. Outras formas para a atenuação desta interferência consistem em usar fios curtos entre o eletrodo e o amplificador,

reduzir a impedância entre o eletrodo e o escalpo (que, de acordo com a Sociedade Americana de *EEG* a impedância individual deve estar abaixo de 5  $K\Omega$  [11] ), ou realizar medições em uma sala blindada.

***Flutuação na impedância do eletrodo:*** Se os eletrodos estiverem mal fixados ou em condição ruim, a impedância do eletrodo ou do contato pode variar. O movimento do cabo que liga os eletrodos ao amplificador e a sudorese podem causar esta variação [63]. Geralmente, este problema é minimizado com o uso de gel eletrolítico para diminuir a impedância de contato e conferindo a impedância com multímetros digitais.

### **3.3.2 Artefatos de Origem Fisiológica**

Os artefatos de origem fisiológica são originados no corpo do próprio paciente. Dentre os principais, podemos citar:

***Artefato de movimento ocular:*** O movimento ocular é produzido pela atividade elétrica nos olhos e este é o ruído predominante na gravação da atividade elétrica cerebral. Geralmente, é solicitado ao paciente para que ele não mova os olhos e nem pisque durante a aquisição do sinal [84].

***Artefato de movimento muscular:*** Artefatos eletromiográficos (sinal elétrico de origem muscular) são encontrados em gravações em que o paciente realizou algum tipo de movimento, particularmente movimentos na cabeça e no pescoço.

***Artefato de Eletrocardiograma:*** A atividade elétrica cardíaca pode ser registrada sobre o escalpo. Geralmente esta interferência é minimizada durante a gravação do *EEG* utilizando-se eletrodos de referência cujo sinal adquirido seja corrompido pela mesma fonte de ruído [11].

### 3.3.3 Remoção do Ruído em *EEG*

Os métodos para a remoção do ruído do *EEG* podem ser classificados como métodos de rejeição ou métodos de subtração. Métodos de rejeição são os que consistem em identificar e descartar as amostras do sinal que estejam contaminadas por atividade ruidosa. Na análise clínica, normalmente a identificação é realizada por médicos com especialização em eletroencefalografia que visualmente identificam se o *EEG* está contaminado e qual foi o tipo de artefato presente no período considerado. Porém, esta técnica é bastante desgastante e atualmente existem abordagens por processamento de sinais que automaticamente identificam e descartam períodos de *EEG* corrompidos. A grande desvantagem deste método é que em um sinal de *EEG* com grande quantidade de ruídos pode sofrer uma perda muito grande de dados.

Os métodos de subtração são baseados na consideração que o sinal de *EEG* capturado sobre o escalpo é uma mistura linear de fontes de sinais diversos, dentre elas a própria atividade elétrica do cérebro e os diversos tipos de ruído. Atualmente, pesquisas envolvendo estes métodos estão em evidência e podem ser divididas em duas diferentes abordagens [84]:

- Filtragem,
- Separação Estatística de Alta Ordem.

O método de remoção do ruído baseado em filtragem consiste em desenvolver um filtro que modele a atividade do artefato e, em seguida, usar este modelo para remover o artefato do sinal de *EEG* corrompido. Isto pode resultar em um filtro passa baixa, passa alta, passa banda ou rejeita faixa. Técnicas de Filtragem Adaptativa são freqüentemente encontradas para tal fim [26], devido ao fato de não se necessitar modelar por completo o ruído, além de o filtro se atualizar de acordo com as características do artefato.

Supondo que um dado sinal seja formado por uma mistura de fontes, a técnica de Separação Estatística de Alta Ordem (*HOS – High Order Statistical Separation*) possibilita a separação das fontes que constituem o sinal sem se

conhecer como ele foi misturado e nem quem são as fontes. Porém, devido à incerteza e variabilidade das gravações de sinal eletroencefalográfico, além da grande quantidade de fontes potenciais envolvidas e a presença significativa de ruído, a separação de fontes se torna um grande problema. Recentemente, várias técnicas têm sido propostas, usando o conceito de Separação Cega de Fontes (*BSS – Blind Source Separation*), as quais exploram a diferença em termos da *HOS* entre as fontes a fim de se distinguir quais são aquelas provenientes do cérebro e quais são artefatos. Como exemplo pode-se citar a Análise por Componentes Independentes (*ICA*, do inglês *Independent Component Analysis*) [38][20][51] e a Análise por Fração de Sinal (*SFA – Signal Fraction Analysis*) [47].

### **3.4 Características Estatísticas do Sinal *EEG***

As sucessivas camadas existentes entre o cérebro e o escalpo atenuam fortemente a amplitude do sinal cerebral. Sabe-se que a intensidade das ondas cerebrais gravadas sobre a superfície do cérebro possui amplitude de aproximadamente 10 mV, enquanto que o sinal adquirido sobre o escalpo possui uma amplitude máxima de 100  $\mu$ V [87]. Tanto a amplitude quanto a frequência do sinal *EEG* é altamente dependente do grau de atividade cerebral do córtex. Desta forma, a amplitude do sinal gravado sobre o escalpo pode variar entre 10 e 100  $\mu$ V e a frequência pode variar entre 0,5 e 100 Hz [87].

Assim sendo, um bom conhecimento a respeito do sinal *EEG* pode ajudar as pesquisas em *ICC*. De acordo com Bayliss [5], apesar do que já é conhecido no assunto, ainda restam muitas questões a respeito da natureza do eletroencefalograma. Pesquisas em todo o mundo buscam uma formulação para este tipo de sinal, sendo que em algumas são sugeridos modelos para o *EEG* [82]. No entanto, tais pesquisas não conseguiram chegar a um resultado conclusivo e, em alguns casos, resultados conflitantes são encontrados.

O *EEG* pode ser caracterizado como uma série temporal medida em um sistema dinâmico que representa a atividade cerebral. Como a maioria das técnicas de processamento de sinais aplicada em *ICC* assume a *estacionariedade* do conjunto de dados, devemos atentar para este fato: podemos considerar o *EEG* como um sinal estacionário?

Um sinal é considerado estacionário no sentido estrito (*SSS – Strict Sense Stationarity*) quando as suas propriedades estatísticas, tanto as de baixa quanto as de alta ordem, não variam com o tempo. No entanto, esta condição é dificilmente encontrada na prática. Normalmente, são considerados apenas os momentos de até 2ª ordem. Esta é uma definição mais fraca para a estacionariedade e é chamada de Estacionariedade no Sentido Amplo (*WSS – Wide Sense Stationarity*) [41]. De acordo com [33], um processo estacionário *SSS* é *WSS*, enquanto que um processo *WSS* pode ser não estacionário no sentido estrito. No entanto, para o restante deste trabalho usaremos o termo estacionário para referenciar a um processo *WSS*.

Para que um sinal  $x(t)$  possa ser considerado *WSS*, devemos ter:

- A função média  $E\{x(t)\}$  ou  $m_X(t)$  constante para todo  $t$ .
- A função de autocorrelação deve ser independente de deslocamentos no tempo:  $E\{x(t) \times x(t-\tau)\} = r_X(\tau)$ , para todo  $t$ .

Diversos trabalhos analisam a estacionariedade do sinal *EEG*, onde é demonstrado que o sinal pode ser considerado estacionário em curtos períodos de tempo. No entanto, o tamanho do período de tempo em que o sinal pode ser considerado estacionário é altamente dependente da quantidade de dados utilizados para o estudo, do tipo de análise que está sendo realizada e as medidas que caracterizam os dados [9]. Com isto, são encontrados trabalhos que demonstram que o *EEG* pode ser considerado estacionário desde alguns segundos até minutos [9]. Assim, uma vez que a gravação de *EEG* utilizada neste trabalho possui épocas com duração de 0,5 segundo e, de acordo com o estudo desenvolvido em [68] e [77], o sinal a ser processado neste trabalho poderá ser considerado *WSS*.

A consideração anterior é importantíssima, pois grande parte das técnicas de processamento digital de sinais e de reconhecimento de padrões só podem ser aplicadas para sinais estacionários.

Uma vez determinada as características estatísticas do sinal *EEG*, analisaremos agora quais as propriedades do sinal *EEG* que podem ser usadas em uma *ICC*. As propriedades do *EEG* que discriminam as funções cerebrais, e que são usadas como um mecanismo de entrada para uma *ICC*, podem ser categorizadas nos seguintes grupos:

- Atividade Rítmica Cerebral;
- Potenciais Relacionados a Eventos (*ERP* – *Event-Related Potentials*);
- Desincronização Relacionada a Eventos (*ERD* - *Event-Related Desynchronization*) e Sincronização Relacionada a Eventos (*ERS* – *Event-Related Synchronization*).

A seguir discutiremos estas propriedades.

### 3.4.1 Atividade Rítmica do Cérebro

A análise do *EEG* é complexa, principalmente devido à grande quantidade de informação capturada por cada eletrodo. Com bilhões de neurônios gerando o *EEG*, este sinal é apresentado como oscilações não periódicas e não estacionárias. Porém, a análise clínica do *EEG* [63][24], assim como o estudo dos estágios de sono [46], faz uso da análise do comportamento em frequência. Dependendo do nível de consciência, pessoas com normalidade no sinal de *EEG* apresentam diferentes atividades rítmicas em suas ondas cerebrais, provocando alterações no espectro de frequência. Estes ritmos são afetados por diferentes ações e pensamentos, por exemplo, o planejamento de um movimento pode bloquear ou atenuar o ritmo Mu [13] .

As principais faixas de frequência usadas no *EEG* são apresentadas na Tabela 3.1 e descritas logo em seguida.

**Tabela 3.1 - Ritmos de frequência no EEG.**

Ritmo	Frequência (Hz)
Delta ( $\delta$ )	0.1 a 4
Teta ( $\theta$ )	4 a 8
Alfa ( $\alpha$ )	8 a 13
Mu ( $\mu$ )	10 a 12
Beta ( $\beta$ )	14 a 30

- **RITMO DELTA:** Ondas de *EEG* abaixo de 4 Hz (geralmente entre 0.1 a 3.5 Hz) são classificadas como ondas Delta [87]. Apresentam amplitude abaixo de 100  $\mu$ V e, em adultos, são associadas com estágio de sono profundo. Em uma pessoa adulta acordada, o aparecimento do Ritmo Delta pode indicar doenças cerebrais.
- **RITMO TETA:** Ondas Teta são ondas entre 4 e 8 Hz. Em adultos normais, ondas Teta são encontradas em estado de sonolência e sono leve. Para algumas pessoas, o Ritmo Teta é encontrado sobre a região frontal quando a pessoa realiza atividades mentais, tais como a solução de problemas [65].
- **RITMO ALFA:** A Federação Internacional de Eletroencefalografia e Neurofisiologia clínica propôs a seguinte definição para o Ritmo Alfa: *“Ritmo entre 8 e 13 Hz, ocorrendo em pessoas acordadas sobre as regiões posteriores do cérebro, geralmente com maior voltagem sobre as áreas occipitais. A amplitude é variável, mas é quase sempre abaixo de 50  $\mu$ V em adultos. É melhor visto com os olhos fechados e sob condições de*



*relaxamento físico e inatividade mental. É bloqueado ou atenuado por atenção, principalmente visual, e esforço mental.”*[65].

- RITMO MU: A frequência do ritmo Mu é entre 10 e 12 Hz, e a amplitude abaixo de 50  $\mu\text{V}$ . É um ritmo associado com atividades motoras e é melhor adquirido sobre o córtex motor. O Ritmo Mu diminui com o movimento ou a intenção de se mover. Apesar da frequência e a amplitude do Ritmo Mu serem similar ao Ritmo Alfa, o Ritmo Mu é topograficamente e fisiologicamente diferente do Ritmo Alfa, principalmente porque este último é gravado sobre a área occipital do córtex. O fato de que pensamentos a respeito da realização de movimentos podem bloquear o Ritmo Mu o tornou importante para as pesquisas em ICC.
- RITMO BETA: Qualquer atividade rítmica na banda de frequência de 14 a 30 Hz é considerada como Ritmo Beta e raramente sua amplitude é superior a 30  $\mu\text{V}$ . Ele pode ser encontrado principalmente sobre a região frontal e parietal do córtex [87]. Um ritmo beta central pode ser bloqueado por atividade motora e estimulação tátil.

Os ritmos discutidos acima podem ser observados na Figura 3.3.

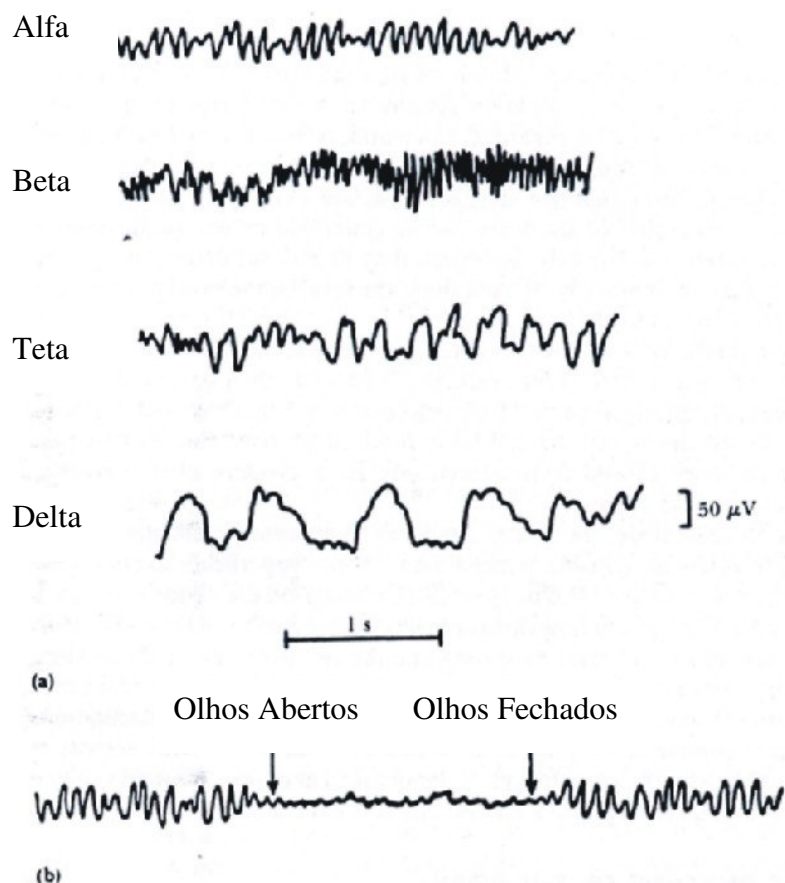


Figura 3.3 - (a) Ritmos do Sinal EEG. (b) Mudança do Ritmo Alfa para uma descarga assíncrona quando o paciente abre os olhos [87].

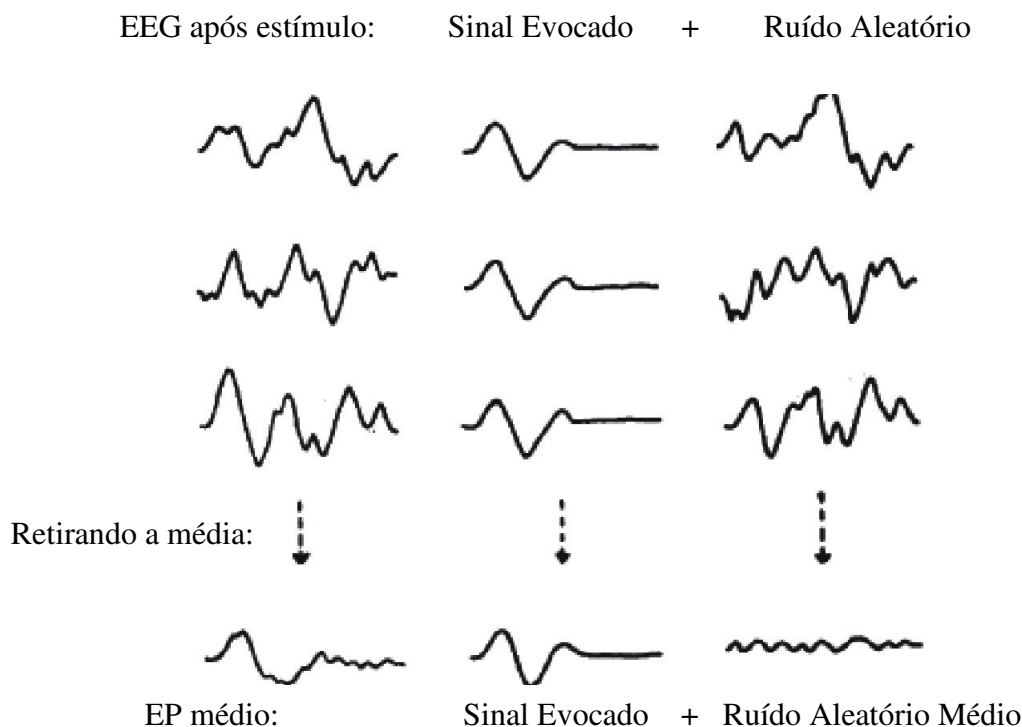
### 3.4.2 Potenciais Relacionados a Eventos

Potencial Relacionado a Evento (*ERP - Event-Related Potential*) é a mudança de potencial eletroencefalográfico em resposta a um evento particular (estímulo). Normalmente, a gravação do *EEG* é feita referenciando-se o tempo ao estímulo, ou seja, é definida uma época que começa a ser gravada antes e termina após o estímulo [18]. Por exemplo, a gravação da época pode começar *100 ms* antes do estímulo e finalizar *500 ms* após. Dentro desta época existem variações na voltagem que são especificamente relacionadas à resposta ao estímulo. São essas variações que constituem o *ERP*.

As amplitudes do *ERP* são freqüentemente muito menores do que a atividade espontânea do *EEG*, tipicamente por um fator de 10, tornando o *ERP*

praticamente irreconhecível no sinal de *EEG* sem processamento [84]. Por isso, técnicas de análise por média são comumente empregadas para a detecção de *ERP*. A relação sinal-ruído do sinal pode ser melhorada utilizando a média de várias repetições do *EEG*. Para isto, é considerado que o aparecimento do *ERP* tem um tempo de atraso mais ou menos fixo em relação ao estímulo, enquanto que a flutuação espontânea de *EEG* é relativamente aleatória no momento em que o estímulo ocorreu, comportando-se como um ruído aditivo [72]. Este processo pode ser visualizado na Figura 3.4. É importante notar que este tipo de abordagem, que é a mais adotada, somente apresenta informação sobre amplitude [69].

Os Potenciais Evocados (*EP – Evoked-Potentials*) formam um subconjunto do *ERP* que ocorrem como resposta a um certo estímulo físico (geralmente visual ou auditivo). O *EP* possui características que dependem do tipo de estímulo; por exemplo, o Potencial Evocado Visual (*VEP – Visual Evoked-Potential*) varia na mesma frequência que a luz estimulante [30]. Como outros exemplos de *EP* pode-se citar o *AEP (Auditory Evoked-Potential)* [76], que é um *EP* que acontece em resposta a um estímulo sonoro, e o *P300* [76], que é um *EP* que ocorre cerca de 300 *ms* após o estímulo.



**Figura 3.4 - Análise do ERP através da média das épocas. Adaptado de [79].**

O Potencial Relacionado a Movimentos (*MRP – Movement-Related Potential*) é um *ERP* da ordem de  $1 \mu\text{V}$ , gerado como resposta a um desejo cognitivo de realizar um movimento dos membros, e é capturado sobre áreas do cérebro relacionadas a esta função (Córtex Motor). Devido à sua importância para este trabalho, ele será melhor discutido no Capítulo 5.

### 3.4.3 Dessincronização / Sincronização Relacionada a Eventos.

A sincronia da população de neurônios pode aumentar ou diminuir em resposta a um estímulo [50]. Normalmente, quando uma população neuronal encontra-se em um estado de não ativação, os neurônios começam a trabalhar em uma espécie de sincronia. Quando o conjunto é ativado por um estímulo, o ritmo sincronizado é suprimido, gerando uma dessincronização [72]. A Dessincronização Relacionada a Eventos (*ERD – Event-Related Desynchronization*) pode ser entendida como uma atenuação na amplitude de um ritmo específico no *EEG*. Já a Sincronização Relacionada a Eventos (*ERS –*

*Event - Related Synchronization*) é um aumento na amplitude de um ritmo específico no *EEG* [36].

Para medir a *ERD/ERS*, Pfurtscheller e Lopes da Silva [72] descrevem o método clássico com os seguintes passos:

- Filtragem passa-banda sobre a faixa de frequência desejada para todas as épocas relacionadas a eventos;
- Obtenção das amostras de energia, elevando as amostras do sinal ao quadrado;
- Cálculo da média das épocas;
- Cálculo da média móvel exponencial sobre amostras no tempo para suavização do sinal apresentado no gráfico e redução da variabilidade.

## 4 INTERFACES CÉREBRO-COMPUTADOR

Uma Interface Cérebro-Computador (*ICC*) ou, no inglês, *Brain-Computer Interface (BCI)*, é um sistema que possibilita a interação entre um usuário com o meio externo, por meio do controle consciente de seus pensamentos. Através do processamento do sinal cerebral, ela fornece uma via de comunicação direta entre o cérebro e o computador, sem a necessidade do uso de músculos periféricos.

Atualmente, considera-se que as pesquisas em Interfaces Cérebro-Computador se iniciaram com a descoberta do *EEG* (descrito por Hans Berger em 1929 [89]). As primeiras aplicações foram desenvolvidas em 1970 e, em 2004, existiam mais que 40 grupos de pesquisas em *ICC* em todo o mundo [89].

No primeiro encontro internacional dedicado à pesquisa em *ICC*, ocorrido em *Rensselaerville*, Nova York, em Junho de 1999, uma definição formal do termo *ICC* foi estabelecida da seguinte forma:

*“A Brain-Computer Interface is a communication system that does not depend on the brain’s normal output pathways of peripheral nerves and muscles”* [89].

Desta definição, pode-se entender que uma *ICC* envolve a monitoração da atividade cerebral (através das tecnologias de imagem cerebral), de forma a detectar alterações de padrões nos sinais provenientes do cérebro (através de algoritmos de processamentos de sinais), com o objetivo de transformar as alterações detectadas em uma forma de comunicação com o mundo exterior. Em uma *ICC*, mensagens e comandos são expressos não por contrações musculares como acontece com os meios de comunicações usuais, mas através dos sinais gerados eletrofisiologicamente dentro do cérebro.

De acordo com esta definição, uma *ICC* deve ser capaz de detectar as vontades e os comandos do usuário enquanto ele se mantém em silêncio e imobilizado. Naturalmente, as pessoas que sofrem de Esclerose Lateral

Amiotrófica, de Esclerose Múltipla, de tumores na Medula Espinhal, ou de qualquer outro tipo de deficiência física que a impossibilite de movimentação dos músculos, enquanto mantém a capacidade cognitiva intacta, são as que mais se beneficiarão deste sistema. No entanto, todas as pessoas poderão obter proveito destes tipos de sistemas. Ampliando o horizonte de visão, não é difícil imaginar o possível uso desta tecnologia para fins multimídia, tais como simuladores de realidade virtual e jogos, assim como para aplicações militares. Consulte [5] para maiores detalhes sobre as possíveis aplicações para *ICCs*.

A atividade cerebral pode ser monitorada usando qualquer uma das técnicas de imagem cerebral. Entretanto, devido às características citadas abaixo, atualmente o *EEG* é a única técnica de imagem cerebral que pode implementar uma *ICC* de uma forma prática:

- Alta resolução temporal (a atividade cerebral pode ser detectada assim que aconteceu);
- Baixo custo em relação às outras técnicas;
- Portátil, podendo, diferentemente de outras técnicas, ser facilmente implementada em um meio móvel;
- Possibilidade de implementação em tempo real.

Por isto, praticamente todas as pesquisas em *ICC* existentes hoje em dia são baseadas no *EEG* [88].

A idéia de usar a atividade cerebral, representada pelo *EEG*, para comunicação e controle é extraordinária. Os mecanismos cerebrais têm sido amplamente estudados. Conseqüentemente, a classificação de sinais cerebrais poderia parecer trivial. Por que então as pesquisas em *ICCs* não tem conseguido atingir resultados tão bons quanto aos das pesquisas em mapeamento cerebral? Na maioria das pesquisas sobre a atividade funcional do cérebro, é usada a média

sobre dezenas a centenas de sinais cerebrais relacionados a um evento. Nas *ICCs* isso não pode ser utilizado, pois resultaria em um tempo extremamente grande. Por isso, a classificação deve ser realizada após cada época, e é extremamente complicado extrair o sinal de controle da sopa elétrica que é o *EEG*, mesmo quando o usuário está totalmente dedicado a uma tarefa mental específica [84].

#### **4.1 Abordagens de *ICC***

Uma *ICC* ideal seria um sistema no qual a pessoa pensaria no seu comando e o sistema o detectaria de uma forma automática. No entanto, este sistema ainda não é possível no estado da arte atual. Desta forma, as pesquisas se baseiam no conhecimento atual do cérebro para projetar a *ICC*, obtendo duas diferentes abordagens. A primeira é chamada Abordagem de Reconhecimento de Padrões e é baseada em tarefas mentais cognitivas. A segunda é chamada Abordagem do Condicionamento do Operador e é baseada na auto-regulação do sinal *EEG*.

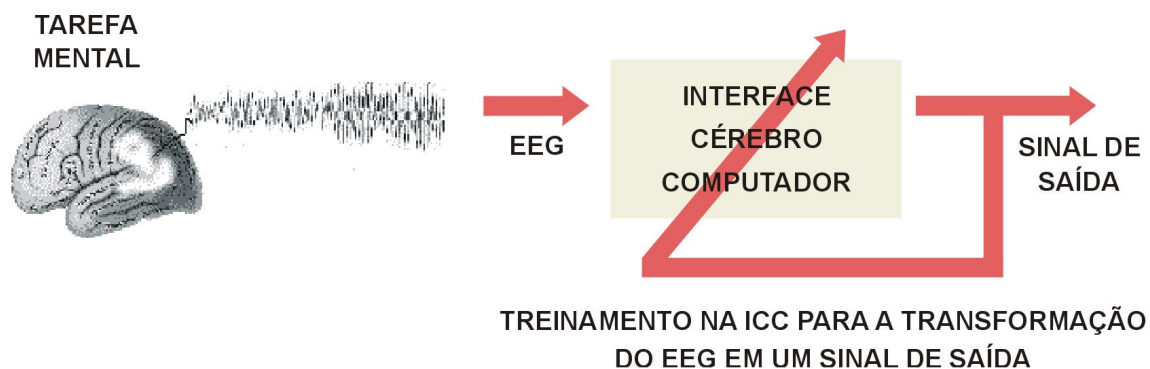
##### **4.1.1 Abordagem de Reconhecimento de Padrões**

O cérebro humano é organizado funcionalmente, conforme discutido na Subseção 2.3. Algumas *ICCs* são baseadas nestas divisões funcionais para gerar padrões diferentes no *EEG*, em resposta a tarefas cognitivas distintas. Tais tarefas devem ativar áreas corticais diferentes e produzir padrões diferentes e distintos no *EEG*. As *ICCs* baseadas na Abordagem de Reconhecimento de Padrões incluem o *ABI* (*Adaptive Brain Interface*) [60] [61], as pesquisas realizadas por Keirn e Aunon [44] e o grupo de pesquisa em *ICC* de Oxford [70].

Tarefas mentais, tais como imaginação motora, tarefas visuais, aritméticas e repouso são as atividades mentais mais utilizadas por uma *ICC* com esse tipo de abordagem. O objetivo da escolha de diferentes tarefas mentais é a obtenção de padrões diferentes no *EEG*. Desta forma, uma *ICC* passaria a funcionar como um sistema de codificação/decodificação do sinal de *EEG*. Para



transmitir uma intenção, o usuário codifica a sua vontade, realizando uma determinada tarefa mental, e a *ICC* decodifica o sinal recebido, reconhecendo os padrões gerados no sinal *EEG* e o associando ao desejo do usuário. Desta forma, o treinamento é realizado apenas na *ICC*, que deve ser capaz de reconhecer os padrões gerados pelo usuário, conforme pode ser visto na Figura 4.1.



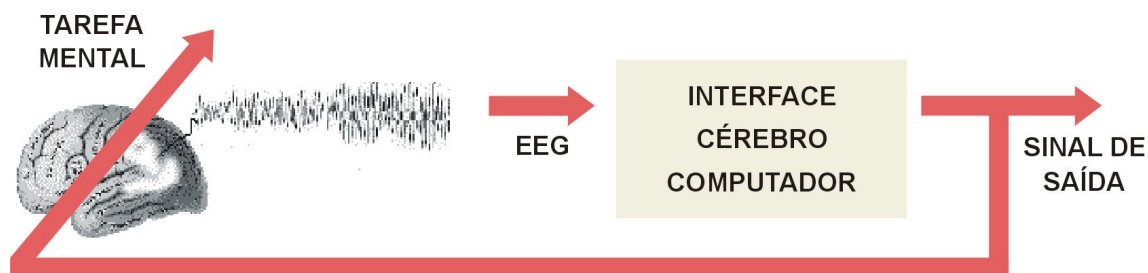
**Figura 4.1 - ICC com abordagem de reconhecimento de padrões.**

É importante notar que para produzir diferentes padrões no *EEG*, as tarefas mentais escolhidas devem ser fáceis de serem realizadas e devem ativar diferentes partes do cérebro. Portanto, um conhecimento melhor das tarefas cognitivas e de sua localização no córtex é preponderante para o sucesso das pesquisas em *ICC*. Por exemplo, a tarefa de imaginação motora é amplamente utilizada [15] [74], pois é conhecido que a imaginação do movimento da mão direita ativa o córtex motor esquerdo e a imaginação do movimento da mão esquerda ativa o córtex motor direito [43].

#### **4.1.2 Abordagem de Condicionamento do Operador**

Nesta abordagem, a *ICC* é projetada para reconhecer um certo padrão no sinal de *EEG*, enquanto que o operador é treinado para auto-regular o *EEG* e gerar os padrões usados pela *ICC*, seguindo o esquema proposto na Figura 4.2. Os padrões gerados mais comuns, e que demonstram poderem ser controlados, são os Potenciais Corticais Lentos (*SCP – Slow Cortical Potential*) [7] e a auto-regulação dos Ritmos  $\mu$  e  $\beta$  [90]. As atividades cerebrais que podem ser

reguladas na abordagem de condicionamento do operador foram descobertas empiricamente por estudos que investigavam os efeitos do *biofeedback* [84], que é a realimentação do efeito do ritmo *EEG*, realizada por algum sistema, para que o usuário possa ter conhecimento da resposta do padrão gerado, podendo assim, interagir com o sistema.



TREINAMENTO DO USUÁRIO PARA O CONTROLE DO EEG

Figura 4.2 - ICC com abordagem de condicionamento do operador

A grande dificuldade da abordagem de condicionamento do operador deve-se à necessidade de que o usuário realize demoradas sessões de treinamento em um ambiente de realimentação (através do *biofeedback*) para adquirir a habilidade de auto-regular o sinal *EEG*. Entretanto, segundo estudos desenvolvidos em [7] e [90], nem todas as pessoas adquirem a habilidade da auto-regulação do *EEG*.

Em um estudo desenvolvido por Kubler [49], existem três elementos essenciais para o aprendizado com sucesso da auto-regulação do *EEG*:

- Realimentação da atividade do *EEG* em tempo-real;
- Reforço positivo do comportamento correto;
- Esquema individual para que sejam apresentadas tarefas cada vez mais difíceis, à medida que o aprendizado aconteça.

Neste tipo de abordagem, é altamente necessária uma equipe multidisciplinar para o desenvolvimento dos resultados, pois grande parte da importância das técnicas de reconhecimento de padrões é transferida para o

treinamento do usuário [22], onde médicos e psicólogos estabelecem o melhor procedimento para o treinamento.

## 4.2 Classificação de Interfaces Cérebro Computador

Apesar das *ICCs* serem classificadas sob as duas abordagens anteriormente discutidas, diversos outros fatores as classificam, de acordo com a taxonomia apresentada na Tabela 4.1. O objetivo desta seção é demonstrar as diversas possibilidades de implementação de uma *ICC* para uma posterior classificação do sistema construído.

**Tabela 4.1 - Classificação das *ICCs*.**

<p><b>Invasivo</b> × <b>Não-Invasivo</b></p>	<p>Em <i>ICCs</i> invasivas, a atividade elétrica cerebral é medida dentro da cabeça, sobre a superfície cerebral, fazendo uso de eletrodos implantáveis. Já as <i>ICCs</i> não-invasivas fazem uso do sinal gravado sobre o escalpo e são as mais estudadas e utilizadas. Para exemplos em <i>ICCs</i> invasivas consulte [45] e [52].</p>
<p><b>Síncrona</b> × <b>Assíncrona</b></p>	<p>Uma <i>ICC</i> pode ser comandada quando a atividade mental é produzida por um estímulo externo (síncrona) ou pode ser comandada de acordo com a vontade do usuário, ou seja, o usuário decide, com controle total, quando e qual atividade mental deve ser gerada (assíncrona). A <i>ICC</i> síncrona oferece uma forma menos natural de controle, pois deve aguardar um estímulo externo para depois tomar a decisão, no entanto, elas apresentam um índice de acerto maior. Para exemplos da <i>ICC</i> síncrona consulte [74].</p>
<p><b>Online</b> × <b>Offline</b></p>	<p>Somente as <i>ICCs</i> que possuem a capacidade de trabalhar online podem suprir as reais necessidades de <i>ICCs</i>. O processamento de sinal, extração de características, a classificação e o controle do dispositivo que está sendo controlado são feitos em tempo real. No entanto, é comum a utilização de estudos offline para simulações teóricas de sistemas para <i>ICCs</i>, com o intuito de facilitar as investigações exploratórias sobre os dados. O desempenho de um estudo offline pode ser comparado com um estudo online, desde que todo o EEG gravado é usado.</p>
<p><b>Paradigma</b></p>	<p>A classificação quanto ao paradigma utilizado refere-se a qual tipo de imaginação ou tarefa mental que o usuário deve realizar para gerar a atividade cerebral relacionada ao comando. Esta escolha depende de qual neuromecanismo a <i>ICC</i> usará como entrada. Os neuromecanismos mais comuns são o <i>SCP</i>, os Ritmos <math>\mu</math> e <math>\beta</math>, o P300, o <i>MRP</i> e o <i>VEP</i>. Exemplos de paradigmas que podem ser citados e que geram estes neuromecanismos são a imaginação motora, tarefas aritméticas, espaciais e visuais.</p>

### 4.3 Estado da Arte de ICCs

Devido à grande quantidade de grupos de pesquisas e de trabalhos recentemente publicados nesta área, uma revisão sobre as diversas abordagens e diversas medidas de desempenho poderia se tornar ineficiente. Por esta razão, será dada relevância para os trabalhos de grupos de pesquisas que possuem uma abordagem mais próxima da que adotaremos para este trabalho. Além disso, para mais informações pode-se recorrer à Tabela 6.5 (Capítulo 6, página 97).

- Pesquisa no Wadsworth Center (Estados Unidos).

Este grupo de pesquisa iniciou sua atividade em 1986 e Jonathan Wolpaw é seu principal pesquisador [84]. A ICC desenvolvida por este grupo é baseada na auto-regulação do ritmo  $\mu$  (8-12 Hz) e do ritmo  $\beta$  central (13-28 Hz).

Em [90] é usada a atividade elétrica adquirida no escalpo sobre o córtex sensorimotor para uma ICC baseada na Abordagem por Condicionamento do Operador. Desta forma, é realizado o treinamento do usuário em sessões que utilizem a realimentação da informação para que o usuário possa aprender a controlar os ritmos presentes no *EEG*. A realimentação é realizada através de um cursor presente no centro da tela de um computador, em que cada tentativa o usuário tenta mover o cursor do centro da tela para a parte superior ou inferior da imagem. Esta pesquisa resultou em um sistema com realimentação contínua e que é capaz de controlar a posição do cursor.

- Pesquisa na Universidade de Graz (Áustria).

Os principais pesquisadores deste grupo são G. Pfurtscheller, C. Neuper e A. Schlögl, sendo que o projeto de uma ICC na Universidade de Graz, Áustria, começou em 1991 [73]. O paradigma que é usado é a detecção de *ERD / ERS* dos ritmos  $\mu$  e  $\beta$  durante a imaginação motora. Como pode ser observado em [73], a abordagem usada é uma combinação de reconhecimento de padrões com

condicionamento do operador e a *ICC* deste grupo pode ser classificada como não-invasiva, on-line e síncrona.

Em estudos anteriores, o grupo baseava-se na distinção entre duas classes de imaginação motora. Porém, o estudo realizado em 2001 baseia-se na distinção entre cinco diferentes tarefas mentais. O procedimento resume-se ao operador se sentar em frente a um monitor de vídeo, cuja função é apresentar um símbolo relacionado a uma das cinco tarefas mentais. Após a apresentação da tarefa, o usuário realiza a tarefa mental de acordo com o símbolo apresentado, até a finalização do experimento (8 segundos).

O *EEG* é gravado com 29 eletrodos, filtrado entre 0,5 e 30 Hz e digitalizado com uma taxa de amostragem de 256 Hz. É importante notar que amostras contaminadas por *EOG* (sinal proveniente do movimento do globo ocular) e *EMG* (sinal proveniente da atividade elétrica muscular, tais como piscadas de olhos) são descartadas. A taxa de erros encontrada foi em torno de 8%, utilizando-se como classificador a técnica Análise por Discriminante Linear (*LDA – Linear Discriminant Analysis*) e como extrator de características a técnica dos Coeficientes Auto-Regressivos Adaptativos.

- Pesquisa na Universidade de Berlim (Alemanha).

Os principais pesquisadores deste grupo são K. R. Muller e B. Blankertz. O paradigma que é utilizado por este grupo de pesquisa é a detecção do *MRP* (Movement Related Potential, melhor explicado na subseção 5.2) através da imaginação do movimento dos dedos. Demonstrou-se que é possível predizer a lateralidade do movimento a ser realizado antes da execução do mesmo. Um exemplo deste trabalho pode ser obtido em [10], onde pode-se verificar que a abordagem adotada é a de Reconhecimento de Padrões, pois não há qualquer forma de realimentação da informação para o usuário.

As principais características da pesquisa deste grupo é a pequena quantidade de dados utilizados para a classificação, realizada por meio de

gravações com durações menores que 1 segundo, e a alta taxa de acerto, que fica em torno de 85%.

- Pesquisa na Universidade de Tübingen (Alemanha).

O principal interesse de pesquisa deste grupo e de seu maior investigador, Niels Birbaumer, são os potenciais corticais lentos ou *SCPs*. Durante a década de 1990, eles desenvolveram uma *ICC* chamada de *TTD* – *Thought Translation Device*, ou traduzindo, Dispositivo de Tradução do Pensamento.

A abordagem utilizada é a de Auto-Regulação dos potenciais de baixa frequência e no trabalho descrito em [7] foi concluído que, com treino, a maioria das pessoas podem desenvolver a habilidade de auto regular este ritmo. A classificação foi utilizada para que um paciente pudesse escrever uma carta apenas através do pensamento [7].

## 5 SISTEMA IMPLEMENTADO

O estudo desenvolvido neste trabalho é baseado na Competição Internacional de *ICC* que ocorreu durante o ano de 2003 (*Brain Computer Interface Competition - 2003*). Nesta competição, diversos grupos de pesquisa de todo o mundo participaram com o intuito de comparar resultados e técnicas de reconhecimento de padrões, aplicados em banco de dados disponibilizados pelos organizadores. Como uma das grandes dificuldades em *ICC* é a comparação do desempenho de classificação de diversas técnicas, esta competição teve resultados excelentes e deve ser repetida em 2005.

A competição foi organizada por renomados pesquisadores em *ICC* e seus respectivos grupos de pesquisa, tais como Niels Birbaumer (Tübingen), Jonathan R. Wolpaw (Albany), Gert Pfurtscheller e Alois Schlögl (Graz), Klaus-Robert Müller, Benjamin Blankertz e Gabriel Curio (Berlim). Devido à diversidade de abordagens existentes, cada grupo propôs seu próprio conjunto de dados, os quais foram baseados em várias características do sinal *EEG*, tais como a auto-regulação de potenciais corticais lentos (SCPs), auto regulação do ritmo  $\mu$  e/ou ritmo Beta-Central, o Paradigma P300 e a Imaginação Motora.

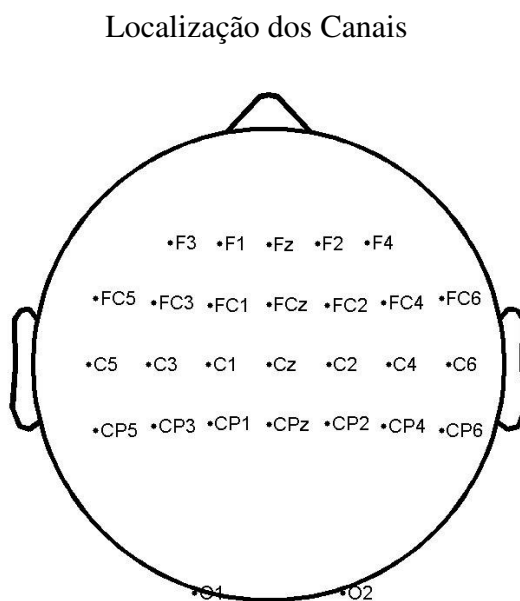
Cada conjunto de dados consiste em um número de tentativas de atividade espontânea de *EEG*, uma parte rotulada (dados de treinamento) e outra parte sem rótulo (conjunto de testes), e o objetivo é classificar corretamente os dados. O classificador foi treinado usando o conjunto de treinamento que maximiza a medida de desempenho para as classificações corretas no conjunto de teste. Os participantes da competição puderam escolher o conjunto de dados e o paradigma subsequente que mais se aproximasse da sua linha de pesquisa.

Destarte, foi desenvolvido um estudo que buscou a escolha do conjunto de dados mais apropriado para este trabalho. Levando-se em consideração as características de cada um dos conjuntos de dados, foi escolhido o banco de dados da Universidade de Berlim para ser usado neste estudo. As vantagens deste banco de dados, que foram levadas em consideração, são as seguintes:

- Facilidade com que o experimento pode ser implementado, uma vez que o usuário só necessita imaginar o movimento do dedo da mão direita ou do dedo da mão esquerda para gerar um padrão.
- Cada época foi gravada em apenas 0,5 segundos, ou seja, em um sistema real teríamos duas classificações para cada segundo.
- Como são disponibilizados 28 canais de *EEG*, pode-se estudar como cada um destes canais contribuem para uma taxa de acerto maior.

### 5.1 Formatação do Banco de Dados

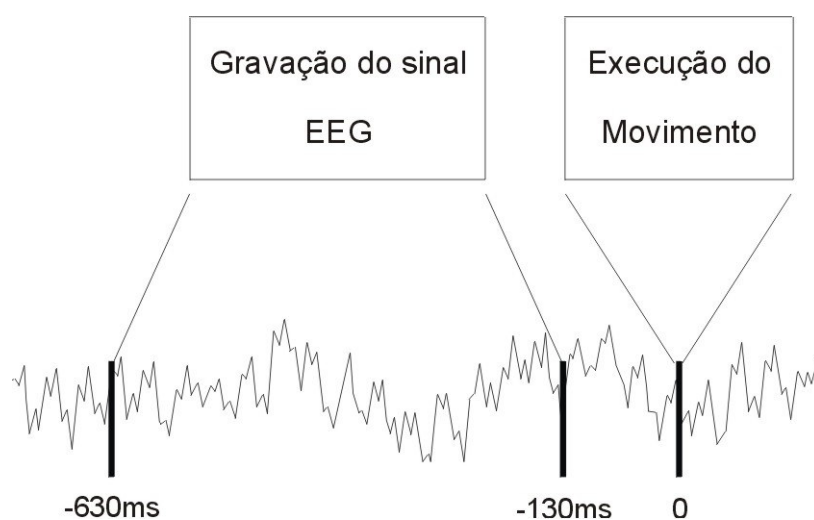
O conjunto de dados utilizado consiste em 316 épocas para treinamento e 100 épocas para teste. Cada época foi gravada com 28 canais, de acordo com o Sistema Internacional 10-20, e distribuídos conforme é apresentado na Figura 5.1.



**Figura 5.1 - Posição dos eletrodos do Banco de Dados utilizado.**



A duração de cada gravação é de 500 milisegundos e é finalizado 130 ms antes da execução do movimento, como pode ser observado pelo diagrama de tempo da Figura 5.2. Cada época do conjunto de treinamento foi rotulada de acordo com o movimento imaginado, onde o rótulo 0 (zero) foi dado para o movimento da mão esquerda e o rótulo 1 (um) foi dado para o movimento da mão direita. Considerando as características extraídas do conjunto de treino, deve ser realizada a classificação das 100 épocas do conjunto de teste. A taxa de acertos no conjunto de testes é a medida de desempenho adotada para este banco de dados, conforme os padrões definidos na Competição de Interfaces Cérebro Computador de 2003 [11].



**Figura 5.2 - Temporização para a gravação da época.**

O objetivo então é classificar a lateralidade do movimento do dedo de uma forma assíncrona, onde a imaginação é feita a qualquer tempo e à vontade do operador. O estudo deste banco de dados fornecerá um ótimo conhecimento sobre os paradigmas, os neuromecanismos de entrada e a implementação de um sistema de reconhecimento de padrões para a detecção dos estados mentais.

O paradigma a ser utilizado é a imaginação do movimento do dedo da mão esquerda ou da mão direita, ou seja, é um caso dos Potenciais Relacionados a Movimentos (*MRP – Movement Related Potential*).

## 5.2 Potenciais Relacionados a Movimentos (*MRP*)

O *MRP* é um tipo de potencial relacionado a eventos (*ERP*). Normalmente, ele aparece como resposta a um desejo cognitivo de realizar uma tarefa motora ou de se observar uma tarefa motora. Devido ao cruzamento lateral existente no mapeamento cerebral (lado direito do cérebro controla o lado esquerdo do corpo e vice-versa), o *MRP* é marcado pelo domínio contra-lateral [18], ou seja, uma tentativa de movimentar um dado membro faz com que a alteração neste potencial manifeste-se no hemisfério oposto do cérebro.

Diversos tipos de eventos podem provocar mudanças na atividade neuronal que são disparadas pelo evento [72] e que ocorrem em um tempo mais ou menos fixo em relação ao estímulo. Para a detecção destas mudanças, técnicas de média são comumente usadas. A consideração usada é que a mudança no *EEG* tem um tempo de atraso mais ou menos fixo em relação ao estímulo, enquanto que a atividade normal do *EEG* funciona como um ruído. O procedimento de obtenção da média melhora a relação sinal-ruído e as características desta atividade podem ser adquiridas no domínio do tempo, como discutido na subseção 3.4.2. Entretanto, é conhecido que certos eventos podem bloquear ou dessincronizar um certo ritmo do *EEG*. Essas mudanças na atividade eletroencefalográfica são disparadas em um tempo mais ou menos fixo em relação ao evento, mas geralmente não estão em fase e, por isto, não podem ser extraídos por um método linear simples, tal como retirar a média. Por outro lado, estas modificações representam mudanças em faixas de frequências específicas no *EEG* e resultam em aumento ou diminuição da potência em determinadas bandas de frequência, como discutido na subseção 3.4.3. Neste trabalho,

abordaremos o *MRP* sob estas duas formas, no domínio do tempo e no domínio da frequência.

O Potencial de Bereitschafts (*BereitschaftsPotential* – *BP*) é a característica mais marcante do *MRP* no domínio do tempo. O *BP* é uma variação do nível *CC*, para um valor mais negativo, durante a realização da tarefa mental. O *BP* para o banco de dados utilizado neste trabalho pode ser observado na Figura 5.3.(b). Sua aquisição pode ser feita com máxima amplitude sobre o córtex motor. É importante notar na Figura 5.3.(b) que o *BP* pode ser observado usando a análise por média, onde ele é facilmente percebido devido à diminuição da amplitude do sinal. Contudo, como pode ser visualizado na Figura 5.3.(a), ele é praticamente imperceptível para análise por época única, devido à sua pequena amplitude.

No domínio da frequência, observam-se variações eletrofisiológicas associadas ao *MRP* que resultam em aumento ou diminuição da amplitude de certas bandas de frequência. O aumento da amplitude é conhecido como sincronização relacionada a eventos (*Event-Related Synchronization* – *ERS*) e a diminuição da amplitude é conhecida como dessincronização relacionada a eventos (*Event-Related Synchronization* – *ERD*) e foram melhor discutidos na subseção 3.4.3. A preparação de movimentos é tipicamente acompanhada por um *ERD* no Ritmo Mu (10-12Hz) e Beta Central (15-20Hz) e, após a realização do movimento, acontece um *ERS* [75]. Além da forma de onda, a Figura 5.3 (b) também ilustra a representação do escalpo com curvas de níveis que evidenciam, sobre o escalpo, o decrescimento do potencial.

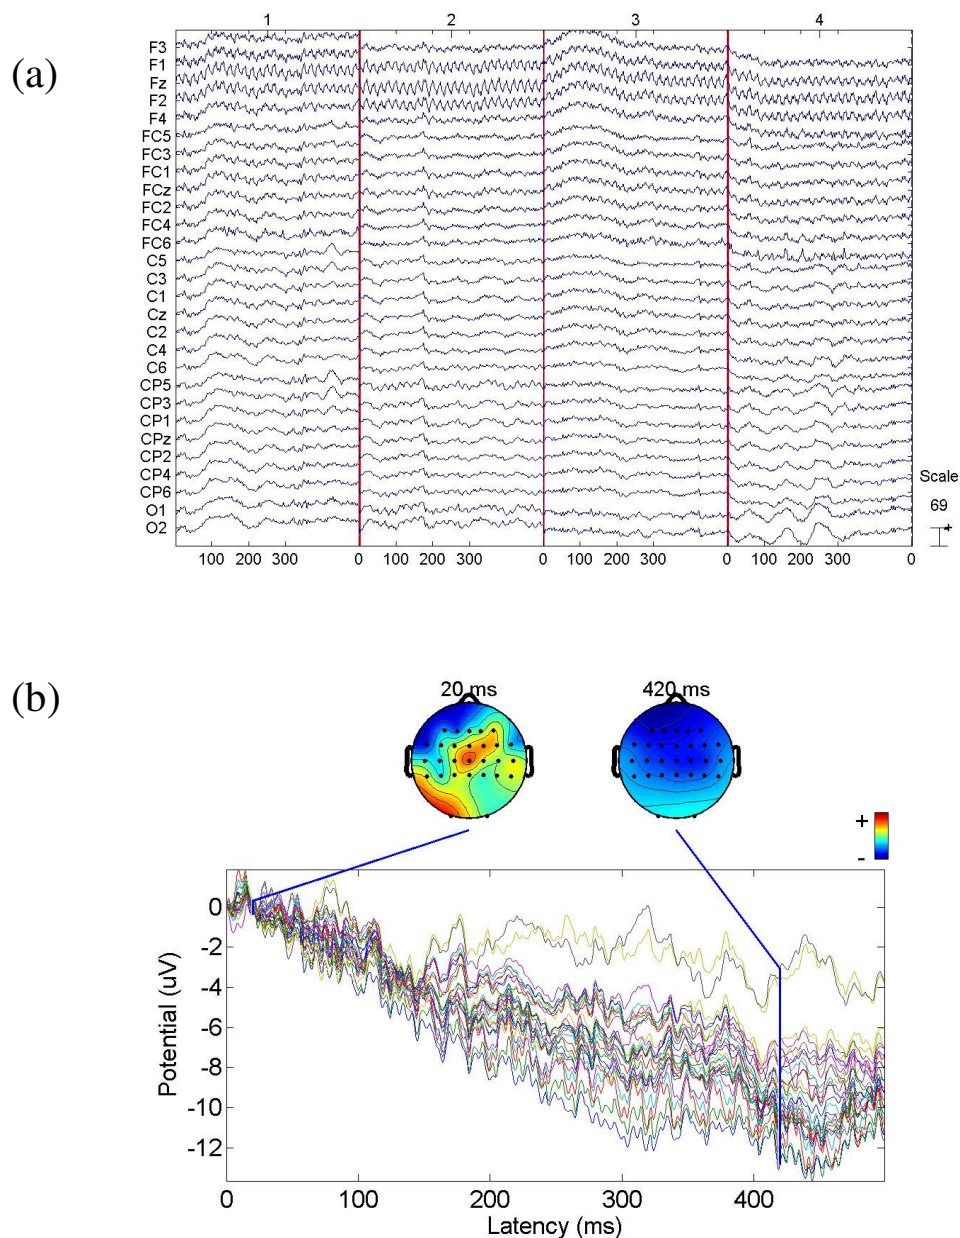


Figura 5.3 - EEG com 28 canais representando a tarefa de movimentar o dedo da mão esquerda.

(a) Análise por Época Única. (b) Análise por *EEG* médio.

A grande dificuldade na análise do *MRP* é a detecção deste sinal no *EEG* em um experimento único. A presença de ruídos e da própria atividade natural do *EEG* faz com que o *MRP* seja praticamente imperceptível em uma análise por época única. Desta forma, é necessário a aplicação de métodos para aumentar a relação sinal/ruído (*SNR*) e fazer com que o *MRP* seja detectável.

### 5.3 Análise das Características do *EEG* no Banco de Dados de Berlim

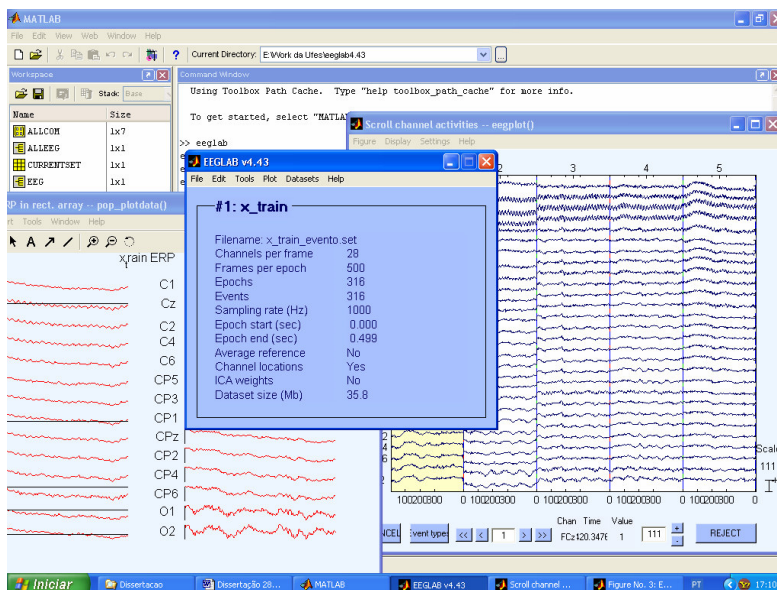
Para a implementação de um sistema de reconhecimento de padrões, fez-se necessário o estudo das classes a serem identificadas. O objetivo deste estudo é entender qual característica deve ser buscada para que, com base nesta informação, o classificador possa identificar a qual classe uma determinada amostra pertença.

Para este trabalho serão atribuídas duas diferentes classes:

- Imaginação do movimento do dedo da mão esquerda, a qual, por motivo de simplicidade, chamaremos tarefa E;
- Imaginação do movimento do dedo da mão direita, a qual chamaremos de tarefa D.

Estas classes serão classificadas com base nas características extraídas do *MRP*. Estas características foram discutidas na Subseção 5.2 e serão analisadas por classes nesta seção.

Para a análise dos dados, foi utilizado o Toolbox de acesso gratuito chamado de EEGLAB, desenvolvido sobre a plataforma MATLAB<sup>®</sup> (The Mathworks, Inc.). Tal sistema foi desenvolvido por Arnaud Delorme e Scott Makeig [25] para o processamento de conjuntos de dados de *EEG* com qualquer número de canais. Ele incorpora funções de visualização dos dados, pré-processamento dos sinais, análise por componentes independentes (*ICA*, do inglês *Independent Component Analysis*) e decomposição tempo/frequência. O EEGLAB é distribuído gratuitamente no endereço <http://www.sccn.uscd.edu/eeglab/>. A tela principal, assim como alguns gráficos criados no EEGLAB podem ser vistos na Figura 5.4. Para maiores informações consulte [25].



**Figura 5.4 - Visualização do EEGLAB. Ações podem ser executadas através da Interface Gráfica (GUI, do inglês Graphic User Interface) ou através da janela de linha de comando do MATLAB.**

### 5.3.1 Potencial de Bereitschafts

O *BP* é uma característica que é adquirida no domínio do tempo e que se traduz como um potencial que diminui sua amplitude de forma lenta, antes que seja realizado o movimento imaginado. De acordo com [21], um potencial negativo do *EEG* pode ser relacionado à atividade de áreas do córtex, enquanto a positividade é relacionada à inatividade destas áreas corticais. Como os membros do corpo humano são controlados pelo lado contralateral do cérebro, é certo que deva existir mais atividade e, portanto, mais negatividade no lado oposto ao movimento. Isto pode ser verificado através da Figura 5.5, que representa a análise por média do sinal de *EEG*, onde para a tarefa D foi obtida a média de 157 gravações e para a tarefa E foi obtida a média de 159 gravações, ambas com 28 canais. A figura também ilustra a representação do escalpo com curvas de níveis que evidenciam a amplitude do sinal para os diversos eletrodos. Atente para o fato de que cerca de 140 ms antes da execução do movimento é possível distinguir, na Figura 5.5.(a), um centro de sinal negativo no lado esquerdo do cérebro para a tarefa D e, na Figura 5.5.(b), um centro de sinal negativo no lado direito do cérebro para a tarefa E. Nesta figura, os sinais positivos sobre o

escalpo são representados pela cor vermelha e, os sinais negativos, com a cor azul. Desta forma, os centros de negatividade são representados por círculos na tonalidade azul.

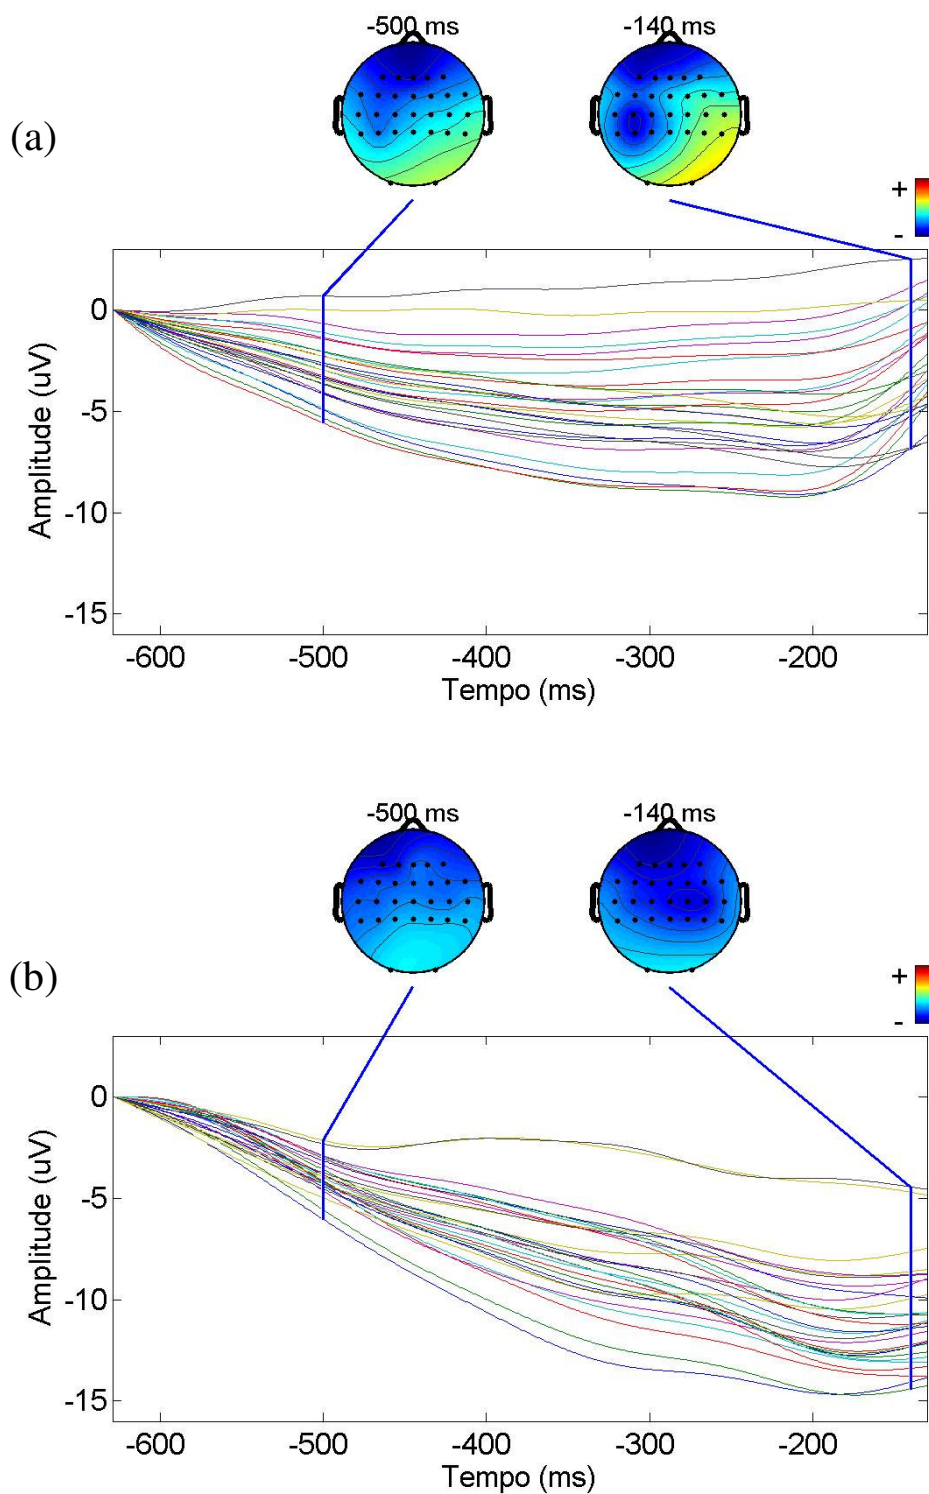


Figura 5.5 - Distribuição sob o escalpo do Potencial de Bereitschafts obtido utilizando a análise por média. (a) Movimento do dedo da mão direita. (b) Movimento do dedo da mão esquerda.

Para a obtenção do *BP*, o *EEG* é filtrado usando um filtro Passa Baixa, com frequência de corte de 7 Hz. Como o *BP* é um potencial de baixa amplitude, ele é quase que completamente mascarado pelo ruído e por outras fontes não relacionadas ao movimento, como pode ser verificado na Figura 5.6. Desta forma é necessário a utilização de outras características para a classificação do *EEG*.


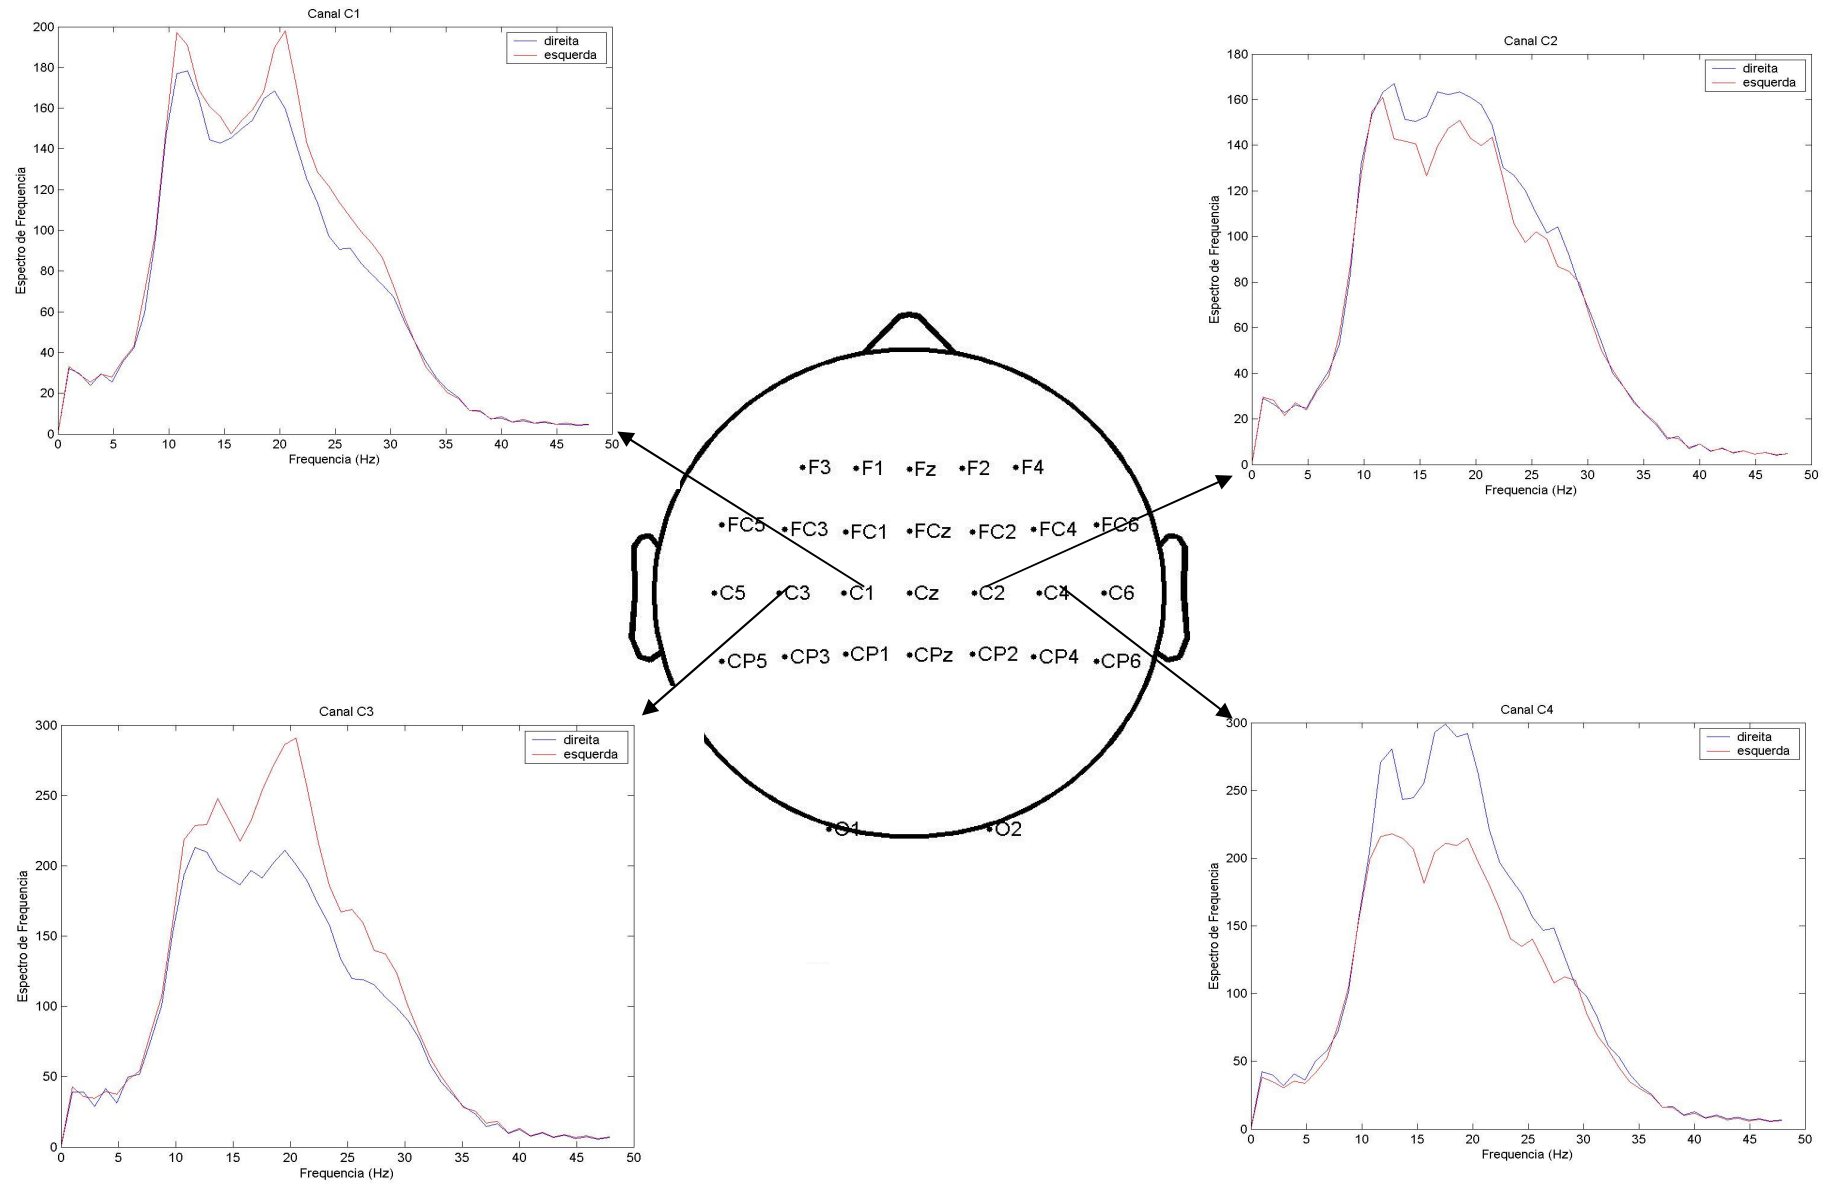


Figura 5.6 - Sinal de EEG representando a tarefa E, com o *BP* totalmente corrompido.

### 5.3.2 Dessincronização Relacionada a Eventos

O *ERD* representa uma troca na atividade elétrica do *EEG* e que resulta em uma diminuição da potência do sinal em uma dada banda de frequência. Normalmente, a imaginação de tarefas motoras resulta em um *ERD* no lado contralateral à imaginação da tarefa. Isto pode ser constatado através da Figura 5.7.





**Figura 5.7 – Visualização do Espectro de Frequência dos Sinais dos Canais C1, C2, C3 e C4.**

A figura apresenta apenas os canais que são mais representativos para esta característica. Observe que a imaginação motora de movimentar o dedo da mão direita apresenta uma amplitude de frequência menor para o lado esquerdo do cérebro, e a recíproca acontece para o lado direito do cérebro. Vale ressaltar que o sinal apresentado na figura foi obtido após calcular o espectro de Fourier para todas as gravações, e depois foi calculada a média do sinal no espectro da frequência. Para a análise de experimento único, estas características não são muito claras, necessitando de utilizar técnicas de processamento de sinais para extrair tal característica.

#### **5.4 Visão Geral do Sistema Implementado**

Uma vez conhecidas as características que devem ser extraídas do sinal, passou-se então a pesquisar técnicas de processamento de sinais que fossem capazes de extrair tais informações para que a classificação pudesse ser realizada. Faz-se necessário que tais técnicas amplifiquem as diferenças existentes entre as características das classes. Dessa forma, deve-se evitar utilizar somente características ligadas à representatividade do sinal, empregando-se também aquelas que primam pela discriminabilidade entre as classes. Além disso, é interessante que as técnicas projetem os dados em um espaço com uma menor dimensionalidade, uma vez que pode se tornar muito custoso treinar um classificador em um ambiente com dimensionalidade elevada [32].

Para a etapa de classificação, foi necessário o desenvolvimento de uma heurística, a fim de que os paradigmas *BP* e *ERD* fossem tratados sob diferentes metodologias. Por isso, como podemos acompanhar pela Figura 5.8, foi implementado um sistema em que os diferentes paradigmas são tratados sob diferentes técnicas. É importante salientar que este sistema foi obtido após inúmeros testes com diferentes técnicas, mas somente aquelas efetivamente utilizadas aparecem do diagrama de blocos.

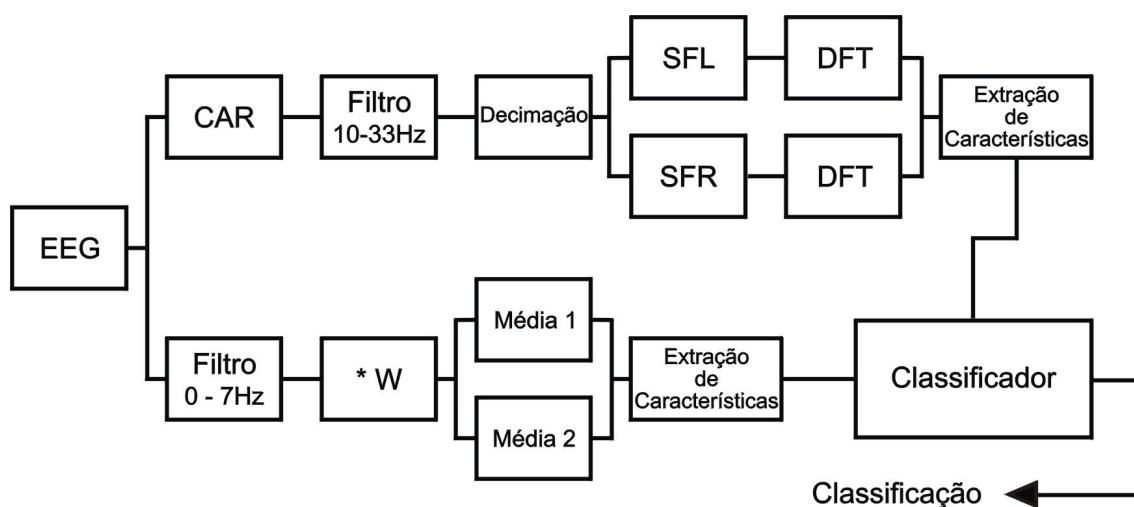


Figura 5.8 - Sistema implementado.

Cada um dos blocos apresentados na Figura 5.8 será melhor descrito oportunamente.

A medida de desempenho oficial utilizada na competição, para se comparar os resultados, foi a taxa de acertos. Com o objetivo de alcançar uma maior taxa de acertos, podemos observar na Figura 5.8 que neste trabalho o classificador utiliza duas fontes de informações. O caminho superior é relacionado ao *ERD*, e as sucessivas etapas de processamento de sinais e extração de características objetivam tornar esta característica a mais discriminativa possível. Já o caminho inferior busca representar o *BP*. A seguir, discutiremos cada uma das etapas envolvidas no sistema implementado neste trabalho.

### 5.5 Extração de características do *ERD*

A primeira característica é derivada do *ERD*, que se manifesta como uma atenuação da amplitude do sinal de *EEG* nos Ritmos Mu e Beta Central. Em uma primeira etapa, é utilizado um filtro espacial chamado de *CAR* (do inglês, Common Average Reference). Após esta etapa, aplicamos um filtro temporal e um processo de decimação para obtermos um conjunto de dados mais reduzido.

Entretanto, apesar de já termos reduzido a quantidade de dados através da decimação, faz-se necessário a diminuição da ordem espacial dos dados, que ainda é de dimensão 28. Para isto, é utilizada a técnica *CSSD* (do inglês, *Common Spatial Subspace Decomposition*), que realiza a projeção dos 28 canais em uma direção que é a mais discriminativa para a separação das classes. Após a obtenção da projeção dos dados em duas direções, uma que é a mais discriminativa para a tarefa E e a outra que é mais discriminativa para a tarefa D, é calculado o espectro de frequência do sinal projetado. A extração de características é utilizada para adequarmos o conjunto de dados para entrada no classificador.

### **5.5.1 Filtragem Espacial e Temporal dos Dados.**

A filtragem espacial e temporal dos dados pode melhorar o sinal de controle do *EEG*, através da diminuição do ruído e da redução da ação de outras fontes não relacionadas com a atividade motora [59].

A filtragem temporal implica na eliminação de faixas de frequência indesejáveis para o sinal. Para o estudo do *ERD*, foi utilizado um filtro *FIR* Passa-banda. Após a realização de diversas simulações da melhor faixa de frequência, concluiu-se que a banda de frequência de 10 a 33 Hz foi a que demonstrou melhores resultados para o conjunto de dados utilizado. É importante salientar que esta banda de frequência engloba os ritmos MU (10-12 Hz) e BETA (14-30 Hz), que são relacionados a atividades motoras.

Conforme já foi discutido anteriormente, o *EEG* é o resultado da mistura de inúmeras fontes, espacialmente distribuídas no cérebro, atuando simultaneamente. Sabe-se que algumas destas fontes são relacionadas à tarefa mental e outras não. A denominação “filtragem espacial” diz respeito à eliminação de fontes não desejáveis para a classificação dos dados.

Para este estudo, optou-se por utilizar uma filtragem espacial simples e rápida [59]. O *CAR* é uma técnica de filtragem espacial que realiza a subtração,

amostra a amostra, da média dos sinais dos eletrodos em cada um dos canais obtidos, através de uma referência comum, normalmente a orelha [59]. A equação para mudança da referência pode ser visualizada através da Equação 5.1, onde  $V_i^{RC}$  é o potencial entre o  $i$ -ésimo eletrodo e a referência,  $n$  é o número de canais e  $V_i^{CAR}$  é o potencial do  $i$ -ésimo eletrodo utilizando a referência pela média comum. Este cálculo deve ser realizado amostra por amostra do sinal de *EEG*.

$$V_i^{CAR} = V_i^{RC} - 1/n \sum_{j=1}^n V_j^{RC} . \quad (5.1)$$

Como a média comum prioriza os sinais que estão presentes em uma grande quantidade de eletrodos, e a subtração leva à eliminação destes sinais, podemos afirmar que o *CAR* funciona como uma espécie de Filtro Espacial Passa Alta, ou seja, ele acentua componentes com distribuições altamente localizadas. Por outro lado, as componentes que estão presentes na maioria dos eletrodos são eliminadas.

### 5.5.2 Decomposição Espacial em Subespaços Comuns

Após a realização dos dois processos de filtragem, foi realizada a decimação do sinal, a fim de se obter um sinal com taxa de amostragem menor e, portanto, com um número menor de amostras, uma vez que a duração do sinal foi mantida. Vale ressaltar que a taxa de amostragem do sinal antes da decimação era de 1000 Hz e após a decimação é de 100 Hz.

Como discutido anteriormente, o *EEG* é composto por uma mistura de fontes que são espacialmente espalhadas, devido às sucessivas camadas entre a fonte e o escalpo. A principal consideração feita é que a variação do potencial  $x_i(t)$  em um eletrodo  $i$ , pode ser modelada como:

$$x_i(t) = \sum_{j=1}^Q m_{ij} s_j(t) + u_i(t) \quad (5.2)$$

onde  $Q$  é o número de fontes ativas,  $s_j(t)$  é forma de onda de potencial da fonte  $j$ ,  $m_{ij}$  é o fator que acopla a fonte  $j$  com o eletrodo  $i$  e  $u_i(t)$  é um ruído medido no eletrodo  $i$ . Se o sinal de EEG for obtido na forma digital, a equação 5.2 pode ser escrita usando a notação matricial:

$$X = MS + U, \quad (5.3)$$

onde  $M$  é a matriz de mistura entre as fontes,  $S$  é a matriz contendo os sinais das fontes e  $U$  é uma matriz com ruído. Na prática, é impossível determinar os fatores  $M$ ,  $S$  e  $U$  da equação acima, porque não é conhecida sequer a quantidade de fontes que geram o sinal  $X$  [85].

Técnicas de Separação Cega de Fontes, ou *BSS* (do inglês, *Blind Source Separation*) [38],[47] podem ser utilizadas para obter as prováveis fontes da matriz  $S$ . No entanto, para a análise do *ERP*, é necessário um método que seja capaz de extrair as componentes em um contexto que maximize a discriminabilidade, ou seja, extrair as componentes que são relacionadas a uma condição das demais componentes. O método da Decomposição Espacial em Subespaços Comuns (*Common Spatial Subspace Decomposition – CSSD*) [85] é então utilizado para solucionar o problema acima. Este método é baseado na diagonalização simultânea de duas matrizes [32] e é capaz de projetar os dados originais em dois outros espaços. Em um dos espaços, as características relacionadas à tarefa D são amplificadas, enquanto que as características relacionadas à tarefa E são reduzidas. No outro espaço, ocorre o contrário do descrito anteriormente.

Chamaremos de  $X_D$  e  $X_E$  os sinais de *EEG* que possuem dimensão  $N$  (canais) por  $T$  (amostras) que se referem à tarefa de imaginar o movimento do dedo da mão direita e da mão esquerda, respectivamente. Desta forma, a gravação de um dado ponto no tempo pode ser representado como um ponto em um espaço Euclideano de dimensão  $N$  e, toda a gravação de *EEG* pode ser vista como uma distribuição de  $T$  pontos. Os sinais  $X_D$  e  $X_E$  podem ser modelados usando fontes simultaneamente ativadas:

$$\begin{aligned} X_D &= [C_D \quad C_C] \begin{bmatrix} S_D \\ S_C \end{bmatrix} \\ X_E &= [C_E \quad C_C] \begin{bmatrix} S_E \\ S_C \end{bmatrix}, \end{aligned} \quad (5.4)$$

onde  $S_D$  e  $S_E$  são os sinais das fontes que são respectivamente relacionadas às tarefas de movimentar o dedo da mão direita e o dedo da mão esquerda.  $S_C$  representa as fontes correspondentes à atividade elétrica natural, que são comum a ambas as condições. Assumindo que  $S_D$  consiste de  $m_D$  fontes e  $S_E$  consiste de  $m_E$  fontes, então  $C_D$  e  $C_E$  são matrizes constituídas por  $m_D$  e  $m_E$  padrões espaciais, que realizam a mistura entre as fontes. O padrão espacial é um vetor  $N \times 1$  e descreve a distribuição nos sensores superficiais de uma fonte específica.

O objetivo do *CSSD* é estimar filtros espaciais  $F_D$  e  $F_E$ , os quais serão usados para extrair as atividades das fontes  $S_D$  e  $S_E$  relacionadas às tarefas motoras, da seguinte forma:

$$\begin{aligned} S_D &= F_D X_D \\ S_E &= F_E X_E, \end{aligned} \quad (5.5)$$

onde  $F_D$  é o filtro espacial correspondente ao movimento do dedo da mão direita e  $F_E$  é o filtro espacial correspondente ao movimento do dedo da mão esquerda.

Os filtros espaciais são obtidos através dos dados do conjunto de treino. Como a parte constante do sinal de *EEG* foi removida pela filtragem na frequência, a média da distribuição é zero. Então, procuraremos por informação no momento de segunda ordem, ou de uma forma mais conhecida, a partir da matriz de covariância. A matriz de covariância espacial do *EEG* pode ser estimada da seguinte forma:

$$\begin{aligned} R_D &= X_D X_D^T \\ R_E &= X_E X_E^T, \end{aligned} \quad (5.6)$$

onde  $X^T$  é a transposta da matriz  $X$ .

A partir da equação (5.6), é realizada uma estimativa amostral da matriz de covariância espacial, calculada da seguinte forma:

$$\overline{R}_D = \frac{1}{N_D} \sum_{i=1}^{N_D} R_D(i) \quad \overline{R}_E = \frac{1}{N_E} \sum_{i=1}^{N_E} R_E(i) \quad (5.7)$$

onde  $N_D$  e  $N_E$  são o número de épocas no conjunto de treino, referente às tarefas de movimentar o dedo da mão direita e dedo da mão esquerda, respectivamente.

É sabido que toda matriz de covariância, sendo real e simétrica, pode ser fatorada na sua forma quadrática [32], estando assim associada a uma matriz diagonal de autovalores  $\Lambda$  (neste caso, dita ser semi-definida positiva). Assim sendo, é realizada a fatoração da soma das matrizes de covariância  $\overline{R}_D$  e  $\overline{R}_E$  no produto de matrizes de autovetores e autovalores:

$$R = \overline{R}_D + \overline{R}_E = U_o \Lambda U_o^T, \quad (5.8)$$

onde  $U_o$  é a matriz de autovetores e  $\Lambda$  é a matriz diagonal de autovalores. Então, as matrizes  $\overline{R}_D$  e  $\overline{R}_E$  podem ser transformadas através da matriz de branqueamento  $W$ :

$$W = \Lambda^{-1/2} U_o^T, \quad (5.9)$$

$$\begin{aligned} Y_D &= W \overline{R}_D W^T \\ Y_E &= W \overline{R}_E W^T \end{aligned} \quad (5.10)$$

É importante notar que os sinais  $Y_D$  e  $Y_E$  apresentam as seguintes propriedades:

- Eles possuem autovetores comuns:

$$Y_D = U \Lambda_D U^T \quad Y_E = U \Lambda_E U^T \quad (5.11)$$

- Organizando os elementos diagonais da matriz de autovalores  $\Lambda_D$  na ordem decrescente e  $\Lambda_E$  na ordem crescente, o autovetor associado ao maior autovalor em  $\Lambda_D$  terá, em contrapartida, o



menor autovalor associado em  $\Lambda_E$ . Com isto, a soma dos autovalores correspondentes sempre será 1:

$$\Lambda_D + \Lambda_E = I \quad (5.12)$$

Definindo o primeiro autovetor da matriz  $U$  como  $U_D$  ( $1 \times N$ ) e o último autovetor como  $U_E$  ( $1 \times N$ ), teremos os autovetores ótimos, no sentido da discriminabilidade, para distinguir os dois tipos de tarefas mentais. Desta forma, os filtros espaciais  $F_D$  e  $F_E$  são obtidos da seguinte forma:

$$\begin{aligned} F_D &= U_D^T W \\ F_E &= U_E^T W \end{aligned} \quad (5.13)$$

Com os filtros espaciais, poderemos estimar os sinais temporais associados à tarefa de movimentar o dedo da mão direita ou da mão esquerda, da seguinte forma:

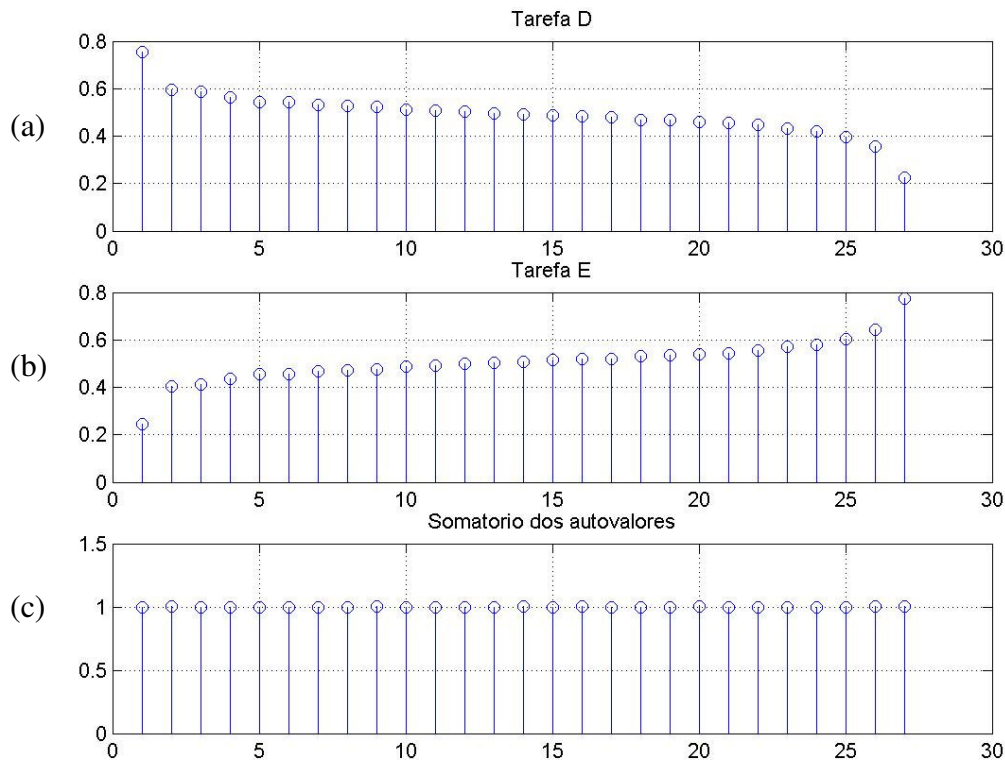
$$\begin{aligned} S_D &= F_D X \\ S_E &= F_E X \end{aligned} \quad (5.14)$$

onde  $X$  é uma época do sinal de *EEG*. Teoricamente, para movimentos do dedo da mão esquerda,  $S_E$  será muito mais forte do que  $S_D$  e, para movimentos do dedo da mão direita, o resultado será o oposto.

Para este algoritmo, deve-se atentar para alguns pontos. Para sinais sem ruído ou outras interferências, as matrizes de autovalores  $\Lambda_D$  e  $\Lambda_E$  devem possuir a seguinte forma:



Com isto, conforme pode-se visualizar na Figura 5.9, apenas uma fonte foi utilizada para a representação de  $S_D$  e  $S_E$ . Na Figura 5.9, pode-se observar os autovalores associados a cada um dos autovetores da tarefa do tipo D e do Tipo E, além do resultado obtido com a somatória dos autovalores da tarefa D e da tarefa E.



**Figura 5.9 - Autovalores da matriz de Covariância Branqueada. (a) Autovalores associados à tarefa D. (b) Autovalores associados à tarefa E. (c) Autovalores associados à matriz de covariância branqueada, correspondente à somatória dos autovalores da tarefa D e da tarefa E.**

Para o nosso sistema,  $X$  é uma matriz com dimensão  $28 \times 50$ . Como os filtros espaciais  $F_D$  e  $F_E$  possuem dimensão  $1 \times 28$ , o sinal de saída para cada filtro possui dimensão  $1 \times 50$ . A Figura 5.10 demonstra a entrada e saída dos filtros, obtido através da equação (5.14). A interpretação da técnica *CSSD* é que ela calcula dois filtros, onde cada filtragem realiza uma projeção sobre duas direções: uma que maximiza a covariância para a tarefa D e a outra maximiza a

covariância para a tarefa E. No exemplo da Figura 5.10, foi utilizado uma tarefa do tipo E, o que pode ser concluído observando a saída dos filtros espaciais.

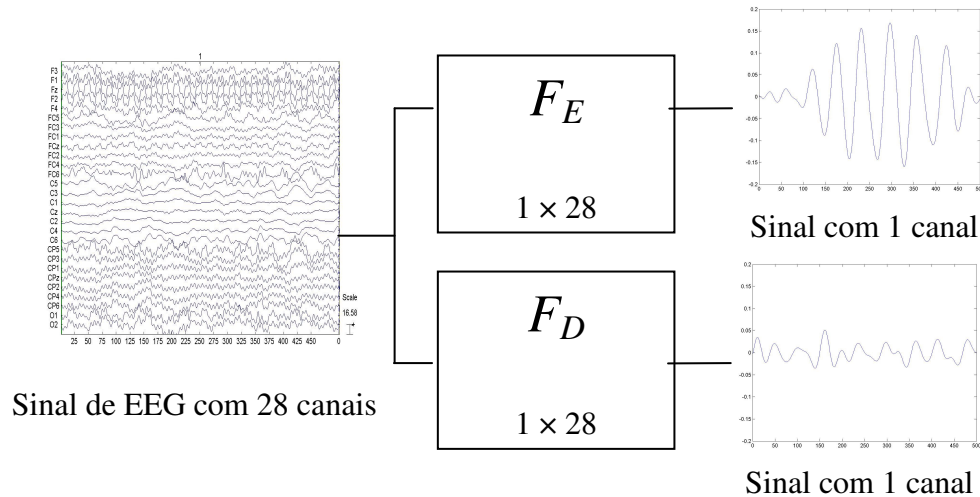


Figura 5.10 - Filtragem Espacial.

### 5.5.3 Análise no Domínio da Frequência

A preparação e planejamento de movimentos resulta em um *ERD* do Ritmo Mu (10-12Hz) e do Ritmo Beta Central (14-20Hz) no lado contralateral do movimento [75]. Para o *ERD*, esperamos extrair características no domínio da frequência para que o classificador possa distinguir as tarefas mentais. Após a etapa do *CSSD*, obtemos um sinal com variância maximizada para gravações associadas a um determinado tipo de tarefa mental e um sinal com variância minimizada para gravações associadas a outros tipos de tarefas mentais.

Na classificação de sinais *EEG* associados a tarefas mentais, é importantíssima a informação em frequência para se determinar se ocorreu ou não o *ERD*. Por este motivo, foi utilizado o espectro de potência obtido através da Transformada Discreta de Fourier (*Discret Fourier Transform - DFT*),


calculada por meio de seu algoritmo rápido denominado de *FFT* (*Fast Fourier Transform*). Dado um espectro de frequência hipotético  $y(\omega)$ , a densidade espectral de energia é obtida fazendo-se:

$$S(\omega) = |y(\omega)|^2 = y(\omega)y^*(\omega), \quad (5.16)$$

onde \* indica o operador conjugado complexo e  $|.|$  é o módulo. Por definição, o espectro de energia é uma medida real da energia espectral, ou seja, da energia por unidade de frequência. O espectro de frequência  $y(\omega)$  é normalmente complexo, enquanto que a densidade de energia espectral inclui a informação contida nas partes imaginária e real do espectro de frequência e será sempre real.

Para o sistema implementado, foi calculada a densidade espectral usando uma *FFT* de 64 pontos para um sinal com taxa de amostragem  $f_s$  de 100 Hz. Com isto, a resolução espectral é de 1,56 Hz. Desta forma, foi calculada a densidade espectral para os dois sinais provenientes dos dois filtros espaciais. Diversas simulações demonstraram que ao invés de se utilizar todos os pontos obtidos pela *FFT* para treinar o classificador e gerar a classificação, era melhor retirar a média dos pontos 6 a 21 da *FFT*, que correspondem às componentes de frequência situadas entre 9,36 Hz a 32,76 Hz.

A etapa de cálculo da média é realizada no bloco intitulado “Extração de Características” do diagrama de blocos mostrado na Figura 5.8. Após este bloco, podemos observar, através da Figura 5.11, como se comporta a separação das classes em um plano cartesiano, em função das características obtidas por este processo.



**Figura 5.11 - Distribuição das classes, após a etapa de extração de características do ERD.**

É importante salientar que existe uma região, próxima da origem, em que será muito difícil para o sistema gerar uma classificação precisa. Possivelmente, as épocas que geraram estes pontos não podem ser classificadas com precisão, utilizando como neuromecanismo o *ERD*. Por este motivo, foi desenvolvido um outro sistema de extração de características e que funciona em paralelo com este, de forma que, quando o classificador não obtém uma saída que demonstra certeza na classificação, esta buscará informação na extração de característica do *BP*.

## 5.6 Extração de Características do *BP*

A segunda característica utilizada é derivada do Potencial de Bereitschaftst, ou *BP*, que se manifesta como um potencial decrescente lento.

Para a classificação de tal característica, foi buscado um extrator de características que maximize a informação contida na parte final da gravação, uma vez que esta é a porção do sinal que possui a informação proveniente do decrescimento do potencial devido ao *BP*. Várias tentativas foram realizadas procurando atender tal objetivo. Após tal tarefa, foi encontrado como melhor forma de classificação do *EEG* baseado no *BP* o esquema indicado pelo diagrama de blocos da Figura 5.12.





Figura 5.12 - Extração de características do BP.

Pode-se observar que primeiramente o *EEG* passa por um filtro *FIR* passa-baixa com frequência de corte em 7 Hz. Desta forma, apenas as componentes de baixa frequência, relacionadas ao *BP*, são utilizadas no restante do sistema.

Sabendo-se que a parte final do sinal possui mais informação sobre o *BP*, buscou-se por uma função que ressaltasse tal informação. Assim sendo, optou-se por uma função janela descrita pela equação (5.17), que tem como objetivo maximizar a queda na parte final do sinal. A função  $W(n)$  pode ser visualizada pela Figura 5.13.

$$W(n) = 1 - \cos\left(\frac{n\pi}{500}\right) \quad (5.17)$$



**Figura 5.13 - Janela W(n).**

Para obtermos uma medida da taxa de decaimento do sinal, foram definidas duas características, C1 e C2, como valores médios para cada eletrodo. A característica C1 é a média no início da gravação (amostras de 1 a 80), e a característica C2 é a média obtida no final de cada gravação (amostras de 420 a 500). A média foi utilizada, devido à propriedade de suavização da curva e para a obtenção de um valor que caracterize o sinal. A diferença entre as características C1 e C2 é uma boa medida para caracterizar a variação da amplitude do sinal, e isso é realizado no bloco “Extração de Características” da Figura 5.12. Com isto, o sistema de extração de característica do *BP* obteve como vetor de característica para cada gravação um vetor de dimensão  $28 \times 1$ .



## 5.7 Classificador

A informação que o classificador empregado neste sistema usa para gerar seu resultado é proveniente de duas características, o *ERD* e o *BP*. Diversos grupos de pesquisa também têm trabalhado usando estas informações para a classificação, sendo que alguns deles trabalham com cada uma destas informações individualmente [10], [84], enquanto que outros trabalham com a informação das fontes de uma forma paralela e dando a mesma medida de importância para as duas [53],[86].

No entanto, percebe-se através do estudo do sinal em questão, que nem sempre os neuromecanismos de entrada (*BP* e *ERD*) atuam simultaneamente em uma mesma gravação. Sendo assim, não se consegue a melhor classificação considerando apenas uma das características, uma vez que a informação contida na característica desprezada não irá contribuir para a taxa de acertos. Também é possível perceber que utilizar as duas características em um só classificador também pode ser prejudicial, principalmente no tocante a que este se baseará sempre nas duas informações para se gerar a classificação.

Destarte, neste trabalho foi desenvolvido uma heurística em que a classificação é realizada em duas etapas, conforme o fluxograma apresentado na Figura 5.14. Esta heurística é utilizada uma vez que a discriminabilidade entre as classes foi aperfeiçoada com as técnicas de extração de características empregadas.

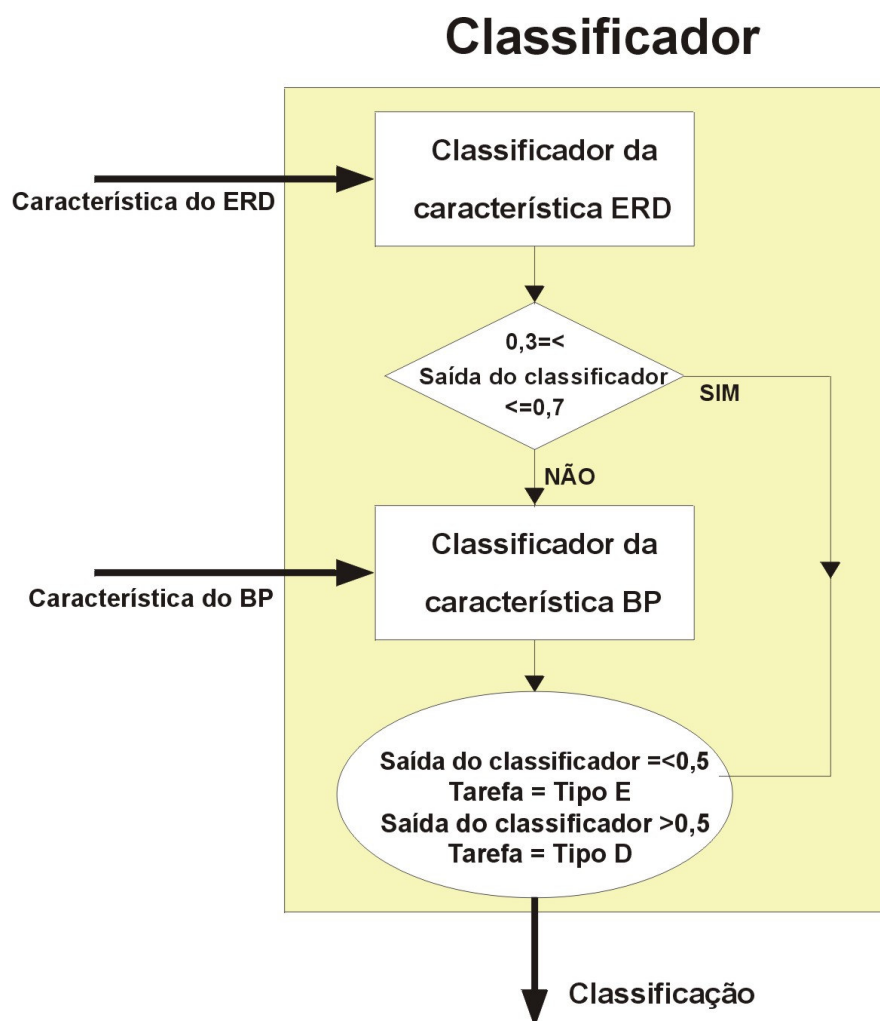


Figura 5.14 - Fluxograma do classificador de padrões.

Como primeiro critério de classificação, foi utilizada a informação proveniente do *ERD* que, durante as simulações com o conjunto de treino, demonstrou gerar melhores resultados. Depois de realizada esta primeira etapa de classificação, caso a saída não demonstre, com um grau de certeza elevado, a qual classe determinada amostra pertence, o sistema realiza a classificação baseada na informação do *BP*. Esta metodologia levou o sistema a melhorar a taxa de acertos em cerca de 5%. Essa melhora é explicada devido à grande variabilidade do sinal *EEG*, sendo que em algumas gravações o sinal pode ser mais bem caracterizado pelo *BP* ou pelo *ERD*.

Como classificador, foram utilizadas duas importantes e conhecidas técnicas de classificação: a Análise por Discriminante Linear (*LDA*, do inglês, *Linear Discriminant Analysis*) e uma Rede Neural Perceptron Multicamadas (*MLP*, do inglês, *Multilayer Perceptron Neural Network*). Estes dois classificadores foram escolhidos, pois é conhecido que a *MLP* é um aproximador universal de funções, sendo então possível aprender a função discriminante e realizar razoavelmente bem a separação entre as classes. Já a *LDA* foi empregada com o intuito de poder mensurar o quão separável as classes se tornaram após a extração de características. As tabelas do resultado obtido, utilizando estas e outras técnicas, podem ser visualizadas no Capítulo 6.

Conveniente se faz em afirmar a grande utilização das Redes Neurais Artificiais (*RNAs*) nesta área de pesquisa [16] [57], e, além do proposto, esta técnica possui as seguintes características que são interessantes para a utilização em ICCs [17]:

- **Generalização:** Refere-se ao fato de a *RNA* produzir saídas adequadas para entradas que não estavam presentes durante o treinamento, o que é de suma importância em ICCs, uma vez que não é possível a gravação de um banco de dados com todas as combinações possíveis de gravação de *EEG*.
- **Aprendizado:** Como já discutido, as redes *MLP* são conhecidas como aproximadoras universais de funções, o que contribui para aprender a função de separação entre as classes.
- **Não Linearidade:** Permite a modelagem, por uma *RNA*, de um sistema físico não linear.
- **Mapeamento de Entrada-Saída:** A *RNA* aprende dos exemplos, contendo dados de entrada e seus respectivos dados de saída, construindo um mapeamento de entrada e saída.

- Adaptabilidade. As *RNAs* possuem a capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente.
- *Implementação em VLSI*. A natureza paralela da *RNA* a torna adequada para implementação em tecnologia de integração em larga escala.

Apesar das *RNAs* apresentarem as características citadas acima, que correspondem e atendem a requisitos básicos das *ICCs*, também foram realizadas simulações utilizando como classificador o *LDA*. Como já discutido anteriormente, o motivo da utilização desta técnica é demonstrar que as sucessivas etapas de extração de características separaram bem as classes, sendo possível uma boa classificação utilizando um classificador mais simples como o *LDA*.

Para maiores informações sobre *LDA*, consulte [32], e para informações sobre *RNAs*, consulte [8], [17], ou [39].

## 6 RESULTADOS OBTIDOS

Neste capítulo discutiremos os resultados obtidos empregando as técnicas anteriormente explanadas. Além disso, serão feitas comparações com resultados obtidos por outros grupos de pesquisa.

### 6.1 Resultados Obtidos

Os experimentos foram realizados no MATLAB<sup>®</sup>, utilizando implementação própria para as funções utilizadas no sistema de reconhecimento de padrões, excetuando a rede neural artificial, onde foi utilizada a implementação do *toolbox* do MATLAB<sup>®</sup>.

Originalmente, os sinais foram disponibilizados em dois conjuntos, sendo um de treinamento e um de testes. Esta separação foi feita para evitar a utilização do conjunto de testes durante a etapa de treinamento. Com isto, pôde-se verificar a capacidade do classificador em generalizar o aprendizado para amostras que até a fase de testes não eram conhecidas.

Desta forma, durante as etapas de treinamento, foi utilizado como parâmetro de testes o próprio conjunto de treino, através do procedimento chamado *Validação Cruzada* [32]. Neste procedimento, uma parcela do conjunto de treinamento é excluída e o treino do classificador é realizado com as amostras remanescentes. Após o treino, as amostras excluídas são testadas pelo classificador. Esta operação é repetida N vezes, onde para cada vez é separado um conjunto de teste aleatoriamente. Neste trabalho, o conjunto de treino foi separado em 20% para testes e os outros 80% para treino. A principal vantagem deste método é o fato de minimizar a dissimilaridade entre o conjunto de treino e o conjunto de teste original [32]. A taxa de acertos é obtida através da divisão do número de classificações corretas pelo número de amostras.

O resultado da classificação obtido através de uma *RNA* depende da inicialização dos pesos sinápticos da rede neural e do próprio procedimento de treinamento, o que pode levar a uma classificação ótima, sub-ótima ou até

mesmo ao não aprendizado da rede [8]. Por isso, para a obtenção de um resultado que demonstre a taxa de classificação da rede neural independente destes fatores, o procedimento de treino e teste foi realizado 100 vezes e a taxa de acertos demonstrado neste trabalho refere-se à média destes 100 treinamentos.

Foram treinadas duas redes neurais Perceptron Multicamadas com algoritmo de retropropagação, usando o método de Levenberg-Marquardt [39]. A rede utilizada para a característica *BP* foi estruturada com 28 entradas, uma camada oculta e uma camada de saída com um neurônio. Já a rede utilizada para a característica *ERD* foi estruturada com 2 entradas, uma camada oculta e uma camada de saída com um neurônio. A função de ativação utilizada nos neurônios ocultos foi a *tansig* e nos neurônios de saída a *logsig*.

A Tabela 6.1 demonstra o resultado obtido, modificando o número de neurônios da camada oculta, e utilizando o procedimento *Validação Cruzada*.

**Tabela 6.1 – Taxa de acertos para números diferentes de neurônios na camada oculta.**

Número de Neurônios na Camada Oculta		Taxa de Acertos (%)
<i>BP</i>	<i>ERD</i>	
4	4	85,0±2,0
4	3	85,1±2,5
4	2	84,8±2,0
4	1	83,1±2,0
3	4	83,9±2,9
3	3	85,0±2,4
3	2	83,9±2,4
3	1	83,1±2,0
2	4	84,2±5,0
2	3	84,8±1,7
2	2	84,7±2,1
2	1	86,5±2,0
1	4	86,0±1,9
1	3	86,1±3,0
1	2	85,6±2,5
1	1	87,1±1,9

Como se pode observar, o melhor resultado foi obtido utilizando-se um neurônio na camada oculta nas duas redes. Isto pode ser explicado devido à característica de que com poucos neurônios a rede tem uma capacidade maior de generalizar o seu resultado, enquanto que com mais neurônios a rede tem a tendência de decorar mais com base nos dados utilizados no treinamento.

A Tabela 6.2 demonstra a melhor taxa de acertos obtida com a *RNA* e a taxa de acertos obtida, utilizando o classificador *LDA*. Lembrando que foi utilizado o procedimento *Validação Cruzada* com o conjunto de treino. Da mesma tabela, podemos observar que a taxa de acertos para a rede neural e para a *LDA* é próxima. Isto foi conseguido devido à alta capacidade da separação das técnicas de extração de características, o que vem a corroborar o resultado obtido de poucos neurônios na camada oculta da *RNA*.

**Tabela 6.2 - Taxa de acertos obtida com o conjunto de treino utilizando o método *Validação Cruzada*.**

<b>Classificador</b>	<b>Taxa de Acertos</b>
<i>MLP</i>	87,1 %
<i>LDA</i>	83 %

Como exemplo e para fins de comparação, em [84] o grupo da Universidade de Dublin – Irlanda – utilizou o mesmo banco de dados para um sistema de classificação. O melhor resultado obtido pelo grupo foi alcançado utilizando-se como extrator de características a Análise da Potência por Banda de Frequência e como classificador a *LDA*. A comparação pode ser observada pela Tabela 6.3, onde também é apresentado o resultado do grupo da Universidade de Tsinghua [86]– China. Este grupo obteve os melhores resultados da competição de *ICC* para o banco de dados da Universidade de Berlim, conforme pode ser observado na Tabela 6.5.

Tabela 6.3 - Comparação entre os resultados obtidos.

<b>Grupo de Pesquisa</b>	<b>Taxa de Acertos</b>
<i>Dublin</i> [84]	73 %
<i>Tsinghua</i> [86]	92,98 %
<i>UFES</i>	87,1 %

Com a análise desta tabela, pode-se concluir que a Universidade de Tsinghua obteve um resultado excepcional e que o resultado obtido neste trabalho é melhor do que o obtido na Universidade de Dublin. Deve-se atentar ao fato de que os resultados de [86] foram obtidos utilizando-se o próprio conjunto de treino, podendo haver distorções no resultado final quando o banco de dados de testes for utilizado.

Após a obtenção desta boa taxa de acertos, foram realizadas classificações com o banco de dados de testes, a fim de obter um resultado final para a correta comparação com outros grupos. A Tabela 6.4 demonstra tais resultados.

Tabela 6.4 - Taxa de acertos utilizando o banco de testes.

<b>Classificador</b>	<b>Taxa de Acertos</b>
<i>MLP</i>	85,75 %
<i>LDA</i>	73 %

A comparação entre a Tabela 6.2 e a Tabela 6.4 leva-nos a concluir que os poucos neurônios utilizados na *MLP* fez com que a *RNA* possuísse uma boa capacidade de generalização, o que ficou bem claro com a pequena diferença entre os valores obtidos com o conjunto de treino e o conjunto de testes. No entanto, apesar da significativa taxa de acertos obtidos com a *LDA*, demonstrada



na Tabela 6.2, o resultado da Tabela 6.4 mostrou que esta técnica não obteve um bom resultado classificando informações que até então não fazia parte do seu conhecimento.

Por fim, a Tabela 6.5 representa os resultados obtidos pelos 10 grupos de pesquisa que alcançaram as melhores taxas de acerto, utilizando este banco de dados durante a competição, além do resultado obtido por este trabalho.

**Tabela 6.5 - Comparação entre as taxas de acerto.**

<i>Universidade / País</i>	<i>Taxa de Acertos (%)</i>	<i>Extração de Características</i>	<i>Classificador</i>
UFES, Brasil.	85,75	2 características obtidas da DFT e CSSD para o ERD, análise do decaimento para o BP	MLP
Tsinghua, China.	84	3 características obtidas do CSSD e FDA	MLP
Toronto, Canadá.	81	188 características de diversos tipos e escolhido pela análise exploratória de dados	Classificador de Bayes.
Lausanne, França.	77	PCA dos 8 primeiros coeficientes de Fourier (0 -14Hz)	Discriminante de Fisher
Taiwan, Taiwan.	75	50ms finais dos sinais filtrados com um filtro passa baixa com corte em 5Hz	SVM
Massachussets, EUA.	75	1 característica do decaimento entre o 1° e o 2° segmento e energia do ritmo beta.	Classificador Linear
Tübingen, Alemanha.	73	3 primeiros componentes do PCA com um algoritmo genético para seleção do canal.	SVM Sigmóide
Taiwan, Taiwan.	73	Várias centenas de características selecionadas por uma SVM linear.	SVM não-linear

Tübingen, Alemanha.	71	ICA/PCA com algoritmo genético para seleção de canal.	Rbf SVM
Dublin, Irlanda.	69	Técnicas de Fourier com coeficiente Auto-Regressivos Exogênicos.	LDA
Tübingen, Alemanha.	68	2 primeiros componentes do PCA com um algoritmo genético para seleção do canal.	SVM Linear

## 7 CONCLUSÕES E PROJETOS FUTUROS

Neste trabalho foram abordados assuntos relevantes ao estudo das *ICCs*. As etapas envolvidas desde a geração do sinal *EEG* até a correta classificação leva-nos à conclusão de que o uso prático das *ICCs* depende de uma cooperação interdisciplinar entre neurocientistas, engenheiros, programadores e psicólogos, para o desenvolvimento de aplicações apropriadas.

Um banco de dados contendo gravações de *EEG* baseadas no paradigma experimental de auto-imaginação da movimentação do dedo da mão esquerda ou direita foi utilizado para gerar atividade elétrica cerebral distinguível, com o objetivo de prever qual movimento será realizado. As características do conjunto de dados utilizado neste estudo representaram uma grande dificuldade para o processo de reconhecimento de padrões. Pode-se citar, como exemplo, a curta duração da janela de tempo em que os dados foram capturados e utilizados para a classificação.

Os resultados demonstram que o algoritmo proposto é efetivo para a classificação, sendo que, como pode ser observado através da leitura deste trabalho, diversas variáveis da extração de características influenciam fortemente a taxa de acertos; dentre elas citam-se as seguintes:

- Freqüência de corte do filtro Passa Baixa do *BP*.
- Freqüência de corte do filtro Passa Faixa do *ERD*.
- Número de componentes do filtro espacial obtido com o *CSSD*.
- Escolha das componentes da *DFT* a serem utilizadas para o classificador.
- Componentes no primeiro e segundo intervalos a serem usadas no cálculo da média, utilizada no bloco do *BP*.

Em uma boa parte do desenvolvimento deste trabalho, o autor esteve empenhado no objetivo final de gerar uma boa classificação e, desta forma, preocupando-se com todo o sistema de classificação. Inúmeras modificações foram feitas com o intuito de atingir tal meta, o que levou o autor aos valores das variáveis demonstradas durante este texto. No entanto, seria adequado que em trabalhos futuros fossem desenvolvidos estudos, a fim de descobrir como cada uma das variáveis enumeradas acima influenciam na classificação final.

Nota-se que a heurística utilizada durante a classificação elevou a taxa de acertos, atingindo, desta forma, bons resultados. Assim sendo, conclui-se que ao se realizar a classificação baseada em dois paradigmas diferentes, primeiro deve-se classificar utilizando o paradigma mais discriminativo para o conjunto de dados. No entanto, caso esta classificação não seja bem conclusiva, deve-se realizar a classificação utilizando o segundo paradigma.

Também seria interessante a implementação de um classificador utilizando uma *RNA* com função de base radial, ou *RBF* (do inglês *Radial Basis Function*), uma vez que, do ponto de vista estatístico, esta rede modela a função densidade de probabilidade [8], apresentando bons resultados em problemas de reconhecimento de padrões.

Sugere-se que as rotinas implementadas neste trabalho sejam utilizadas para a classificação de dados em um sistema de tempo real, com o objetivo de demonstrar a aplicação prática das *ICCs*.

Em tempo, é importante salientar a necessidade de, em um trabalho futuro, se realizar uma pesquisa sobre as tarefas mentais a serem utilizadas. Sem dúvida, um melhor entendimento do cérebro e dos processos relacionados às tarefas mentais pode contribuir de uma maneira bastante positiva para a implementação de uma *ICC* a ser utilizada no dia a dia. Além disso, este mesmo estudo deve contemplar uma análise a respeito dos melhores canais para a extração do *EEG*. Este é um problema bastante custoso, uma vez que deve ser realizada uma análise combinatória dos canais de *EEG* disponíveis. Para a

simplificação deste problema, exige-se o uso de heurísticas para manter o número de combinações em um patamar aceitável.

Apesar da boa taxa de acertos obtida neste trabalho, ainda é cedo para se julgar o futuro das *ICCs*. No entanto, é fato que este tipo de pesquisa ainda se encontra em seu início, sobretudo na Universidade Federal do Espírito Santo, onde agora se forma um grupo com o objetivo de somar forças para o estudo das *ICCs* e futura obtenção de um protótipo de uma cadeira de rodas comandada pelo sinal *EEG*. É notório que este trabalho vem muito a somar a estas pesquisas.

## REFERÊNCIAS

- [1] AGARWAL, R. e GOTMAN, J. **Long-Term EEG Compression for Intensive Care Settings**. IEEE Engineering in Medicine and Biology Magazine, Vol. 20, Iss.5, pp. 23-29, 2001.
- [2] ALLINSON, B. **P3 or not P3: Toward a Better P300 BCI**. Tese de Doutorado, University of California, San Diego, EUA, 2003.
- [3] ARAÚJO, D. B., et al. **Imagens do Cérebro em Ação**, Ciência Hoje, Vol. 33, No. 197 pp. 28-35.
- [4] AZEVEDO, A. P., et al. **Proposta de Controle de uma Cadeira de Rodas Robotizada Através de Processamento de Sinais EEG**. Iberdiscap 2004. III Congreso Iberoamericano de Tecnología de Apoyo a la discapacidad. San José, Costa Rica, pp. 33-37, 2004.
- [5] BAYLISS, J. D. **A Flexible Brain-Computer Interface**. Tese de Doutorado. University of Rochester, New York, EUA, 2001.
- [6] BETKE, M. et al., **The camera mouse: visual tracking of body features to provide computer access for people with severe disabilities**. IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 10, No. 1, March 2002.
- [7] BIRBAUMER, N. et al. **The thought translation device (TDD) for completely paralyzed patients**. IEEE Transactions on Rehabilitation Engineering, Vol. 8, N. 2, pp. 190-193. Junho, 2000.
- [8] BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York: Oxford University Press, 1995.
- [9] BLANCO, S. et al. **Stationarity of the EEG Series**. IEEE Engineering in Medicine and Biology, pp. 395-399. Julho, 1995.
- [10] BLANKERTZ, B., CURIO, G., MÜLLER, K. R. **Classifying Single Trial EEG: Towards Brain Computer Interfacing**. Advances in Neural Information Processing Systems, Iss. 14, 2002. MIT Press.
- [11] BLANKERTZ, B., et al. **“BCI Competition 2003”** (2003) <http://ida.first.fraunhofer.de/~blanker/competition/>

- [12] BRITTENHAM, D.M. **Artifacts, Activities Not Arising from the Brain.** Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.
- [13] CHENG, M. et al. **Mu Rhythm-based cursor control: an offline analysis.** *Clinical Neurophysiology*, N.115, pp.745-751, 2004.
- [14] CHUDLER, E. H. **The Functional Divisions of the Cerebral Cortex.** <http://faculty.washington.edu/chudler/introb.html>, 2004. Visitado em 26/01/2005.
- [15] CINCOTTI, F. et al. **Brain Computer Interface: the Use of Low Resolution Surface Laplacian and Linear Classifier for the Recognition of Imagined Hand Movements.** Proceedings of the 23<sup>rd</sup> Annual EMBS International Conference. Istanbul, Turquia. Outubro, 2001.
- [16] CINCOTTI, F. et al. **Comparison of Different Feature Classifiers for Brain Computer Interfaces.** Proceedings of the 1<sup>st</sup> International IEEE EMBS Conference on Neural Engineering. Capri Island, Itália. Março, 2003.
- [17] CÔCO, K.F. **Classificação Neural de Doenças Cardíacas baseada na Energia dos Coeficientes Wavelet.** Dissertação de Mestrado, Vitória – 2003.
- [18] COLES, M.G.H. e RUGG, M.D. **Event-Related Brain Potentials: an Introduction.** Em RUGG, M.D. e COLES, M.G.H. **Electrophysiology of Mind Event-Related Brain Potentials and Cognition.** Oxford Psychology Series. Setembro, 1996.
- [19] COLLURA, T. F. **History and Evolution of Electroencephalographic Instruments and Techniques.** *Clinical Neurophysiology*, Vol. 10, N. 4, pp. 476-504, 1993. APUD [84].
- [20] COMON, P. **Independent Component Analysis, a New Concept?** *Signal Processing*, Vol. 36, n.3, pp. 287-312. Abril, 1994.
- [21] CREUTZFELDT, O. **Cortex Cerebri: Performance, Structural, and Functional Organization of the Cortex.** Oxford University Press. Oxford, New York, 1995. APUD [84].
- [22] CURRAN, E.A. e STOKES, M.J. **Learning to Control Brain Activity: A Review of the Production and Control of EEG Components for Driving**

- Brain-Computer Interface (BCI) Systems.** Brain and Cognition. Vol. 51, pp.326-336. 2003.
- [23] DALY, D.D. **Epilepsy and Syncope.** Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.
- [24] DELAMONICA, E.A. **Electroencefalografia.** Editorial El Ateneo. Buenos Aires.
- [25] DELORME, A. e MAKEIG, S. **EEGLAB: an Open Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis.** Journal of Neuroscience Methods, pp. 9-21, 2004.
- [26] DINIZ, P.S.R. **Adaptive Filtering. Algorithms and Practical Implementation.** Kluwer Academic Publishers, 1997.
- [27] DONOGHUE, J.P. **Connecting Cortex to Machines: Recent Advances in Brain Interfaces.** Nature Neuroscience Supplement, Vol.5, Novembro, 2002.
- [28] DUDA, R. O.; HART, P. E. e STORK, D. G. **Pattern Classification.** 2 ed. New York: John Wiley & Sons Inc., 2001.
- [29] EBRAHIMI, T., VESIN, J.M. e GARCIA, G. **Brain Computer Interface in Multimedia Communication.** IEEE Signal Processing Magazine, Vol. 20, N.1. Janeiro, 2003.
- [30] EPSTEIN, C.M. **Visual Evoked Potentials.** Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.
- [31] FISCHER, J. **Uma Abordagem Prática Neuropedagógica como Contribuição para a Alfabetização de Pessoas Portadoras de Necessidades Educativas Especiais.** Tese de Doutorado. Universidade Federal de Santa Catarina, Florianópolis, 2001.
- [32] FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**, 2 ed. Academic Press, 1990.
- [33] GARCIA, A.L. **Probability and Random Processes for Electrical Engineering.** 2ª ed. Addison-Wesley Publishing Company, 1994.



- [34] GATTASS, R. et al. **Fundamentos da Ressonância Magnética Funcional**. Cérebro e Mente. N. 13, Agosto, 2001.
- [35] GEVA, A. B. e KEREM, D. H., **Forecasting Generalized Epileptic Seizures from the EEG Signal by Wavelet Analysis and Dynamic Unsupervised Fuzzy Clustering**. IEEE Transactions on Biomedical Engineering, Vol. 45, N. 10, pp. 1205 – 1216, October 1998.
- [36] GRAIMANN, B. et al. **Visualization of Significant ERD/ERS Patterns in Multichannel EEG and ECoG data**. Clinical Neurophysiology. Vol. 113, pp. 43-47, 2002.
- [37] GUYTON, A. C. e HALL, J. E. **Tratado de Fisiologia Médica**. 10ª Edição. Editora Guanabara Koogan SA, 2002.
- [38] HAN, J. e PARK, K.S. **Independent Component Analysis for Identification and Minimization of EOG Artifacts in EEG Recordings**. Proceedings of the First Joint BMES/EMBS Conference. Atlanta, EUA. Outubro, 1999.
- [39] HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2 ed. Porto Alegre: Bookman, 2001.
- [40] HUANG, L., SUN, Q. e CHENG, J. **Novel Method of Fast Automated Discrimination of Sleep Stages**. Proceedings of the 25<sup>th</sup> Annual International Conference of the IEEE EMBS. Cancun, México, Setembro, 2003.
- [41] HYVÄRINEN, A., KARHUNEN, J. e OJA, E. **Independent Component Analysis**. John Wiley & Sons Inc., 2001.
- [42] INVERSO, S. A. **Chess Brain-Computer Interface Design and Optimization for Low-Bandwidth and Errors**. Dissertação de Mestrado. University of Rochester, New York, EUA, 2003.
- [43] KANDEL, E. R., SCHWARTZ, J. H. e JESSELL, T. M. **Principles of Neural Science**. 3ª Edição. Prentice-Hall International Inc., 1991.
- [44] KEIRN, Z.A. e AUNON, J.I. **A New Mode of Communication between Man and his Surroundings**. IEEE Transactions of Biomedical Engineering. Vol. 37, N. 12, pp. 1209-1214. 1990.

- [45] KENEDY, P.R. et al. **Direct Control of a Computer from Human Central Nervous Systems.** IEEE Transactions on Rehabilitation Engineering. Vol.8, N.2, pp.198-202, 2000.
- [46] KIM, B.Y. e PARK, K.S. **Automatic Sleep Stage Scoring System Using Genetic Algorithms and Neural Network.** Proceedings of the 22<sup>nd</sup> Annual EMBS International Conference. Chicago, EUA, julho, 2000.
- [47] KNIGHT, J.N. **Signal Fraction Analysis and Artifact Removal in EEG.** Dissertação de mestrado. Colorado, EUA, 2003.
- [48] KOSTOV, **Machine Learning Methods in Assistive Technologies,** IEEE International Conference on Systems, Man, and Cybernetics, Vol. 4, pp. 3729-3734, outubro, 1998.
- [49] KUBLER, A. et al. **Brain-Computer Communication: Unlocking the Locked In.** Psychological Bulletin. Vol. 127, N.3, pp. 358-375. 2001. Apud [84].
- [50] LAITINEN, L. **Neuromagnetic Sensorimotor Signals in Brain Computer Interfaces.** Dissertação de Mestrado. Helsinki University of Technology, Espoo, 2003.
- [51] LEE, T.W., GIROLAMI, M. e SEJNOWSKI, T.J. **Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Sub Gaussian and Super Gaussian Sources.** Neural Computation, Vol.11, pp. 417-441, 1999.
- [52] LEVINE, S.P. et al. **A Direct Brain Interface Based on Event-Related Potentials.** IEEE Transactions on Rehabilitation Engineering. Vol.8, N.2, pp.180-185, 2000.
- [53] LI, Y., GAO, X., LIU, H., GAO, S. **Classification of Single-Trial Electroencephalogram during Finger Movement.** IEEE Transactions on Biomedical Engineering. Vol.51, N.6, pp.1019-1025, Junho, 2004.
- [54] LIU, H.S., ZHANG, T. e YANG, F.S. **A Multistage, Multimethod Approach for Automatic Detection and Classification of Epileptiform EEG.** IEEE Transactions on Biomedical Engineering, Vol. 49, N. 12, pp. 1557 – 1566, 2002.

- [55] MACHADO, A. B. M. **Neuroanatomia Funcional**. 2<sup>a</sup> Edição. Editora Atheneu, São Paulo, 2000.
- [56] MARQUES, J. S. **Reconhecimento de Padrões, Métodos Estatísticos e Neurais**. Editora IST Press, Lisboa – PT, 1999.
- [57] MASIC, N., PFURTSCHELLER, G. e FLOTZINGER, D. **Neural Network-Based Predictions of Hand Movements using Simulated and Real EEG Data**. *Neurocomputing*, N.7, pp 259-274, 1995.
- [58] MAZZIOTTA, J. et al. **A Four-Dimensional Probabilistic Atlas of the Human Brain**. *Journal of the American Medical Informatics Association*, Vol. 8, N.5, pp. 401-430, 2001.
- [59] McFARLAND, D.J. et al. **Spatial Filter Selection for EEG-based Communication**. *Electroencephalography and Clinical Neurophysiology*. N.103, pp. 386-394, 1997.
- [60] MILLÁN, J.R. e MOURIÑO, J. **Asynchronous BCI and local Neural Classifiers: An Overview of the Adaptive Brain Interface Project**. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. Vol.11, N.2, pp.159-161, junho, 2003.
- [61] MILLÁN, J.R., HAUSER, A. e RENKENS, F. **Adaptive Brain Interfaces – ABI: Simple Features, Simple Neural Network, Complex Brain-Actuated Devices**. 14<sup>th</sup> International Conference on Digital Signal Processing, 2002, Vol. 1, pp. 297-300, julho, 2002.
- [62] MILLÁN, J.R. et al. **Relevant EEG features for the classification of spontaneous motor-related tasks**. *Biol Cybern.*, Vol. 86, Iss. 2, pp. 89-95, 2002.
- [63] MONTENEGRO, M.A., CENDES, F., GUERREIRO, M.M, GUERREIRO, C.A.M., **EEG na Prática Clínica**. São Paulo, Lemos Editorial, 2001.
- [64] NIEDERMEYER, E. e DA SILVA, F. L. **Electroencephalography: Basic Principles, Clinical Applications and Related Fields**. Baltimore, Lippincott Williams & Wilkins. Vol. 4, 1999.
- [65] NYKOPP, T. **Statistical Modeling Issues for the Adaptive Brain Interface**. Dissertação de Mestrado. Helsinki University of Technology, Espoo, 2001.

- [66] OCHOA, J. B. **EEG Signal Classification for Brain Computer Interface Applications**. Projeto de Graduação. Ecole Polytechnique Federale de Lausanne, Lausanne, 2002.
- [67] OHARA, P. et al. **Nervous System: Form and Function**. Disponível em: <http://128.218.123.161/Pages/Anatomy103/Neurohistology/nissl-slides.html>. Visitado em 26/01/2005.
- [68] PARDEY, J., ROBERTS, S. e TARASSENKO, L. **A Review of Parametric Modeling Techniques for EEG Analysis**. Medical Engineering & Physics. Vol. 18, No. 1, pp. 2-11, 1996.
- [69] PENNY, W.D. et al. **Event-Related Brain Dynamics**. Trends in Neurosciences. Vol. 25, No. 8. Agosto, 2002.
- [70] PENNY, W.D. et al. **EEG-Based Communication: A Pattern Recognition Approach**. IEEE Transactions on Rehabilitation Engineering. Vol. 8, N.2. Junho, 2000.
- [71] PERRY, B. D. **Brain Structure and Function: Basics of Organization**. The ChildTrauma Academy. [www.childtrauma.org](http://www.childtrauma.org). Visitado em 26/01/2005.
- [72] PFURTSCHELLER, G. e LOPES DA SILVA, F. H. **Event-Related EEG/MEG Synchronization and Desynchronization: Basic Principles**. Clinical Neurophysiology, Vol. 110, pp. 1842-1857, 1999.
- [73] PFURTSCHELLER, G. et al. **Current Trends in Graz Brain-Computer Interface (BCI) Research**. IEEE Transactions on Rehabilitation Engineering, Vol. 8, N. 2, pp. 216-219, junho, 2000.
- [74] PFURTSCHELLER, G. et al. **EEG-Based Discrimination Between Imagination of Right and Left Hand Movement**. Electroencephalography and Clinical Neurophysiology. Vol. 103, pp. 642-651, 1997.
- [75] PFURTSCHELLER, G. e NEUPER, C. **Motor Imagery and Direct Brain-Computer Communication**. Proceedings of the IEEE, Vol.89, pp.1123-1134. 2001.
- [76] PICTON, T.W. **Auditory Evoked Potentials**. Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.

- [77] POPIVANOV, D. e MINEVA, A. **Testing Procedures for Non-Stationarity and Non-Linearity in physiological signals.** *Mathematical Biosciences*, Vol. 157, pp. 303-320, 1999.
- [78] RAUBER T. W., **Pattern Recognition.** JAI'97– XVII Congresso da Sociedade Brasileira de Computação, 1997, Anais da XVI Jornada de Atualização em Informática. Pp. 260-265. Brasília, Brasil. 1997.
- [79] RUGG, M.D. e COLES, M.G.H. **Electrophysiology of Mind Event-Related Brain Potentials and Cognition.** Oxford Psychology Series. Setembro, 1996.
- [80] SABBATINI, R. M. E. **Mapeando o Cérebro.** *Cérebro e Mente*. N. 3, Setembro, 1997.
- [81] SABBATINI, R. M. E. **Tomografia PET: Uma Nova Janela para o Cérebro.** *Cérebro e Mente*. N. 1, Março, 1997.
- [82] SAMPSON, T. **Correlations in Stochastically Modeled EEG.** Dissertação de Mestrado. University of Waikato, 2002.
- [83] SHARBROUGH, F.W. **Electrical Fields and Recording Techniques.** Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.
- [84] SMITH, R. C. **Electroencephalograph based Brain Computer Interface.** Dissertação de Mestrado, University College Dublin, Irlanda, 2004.
- [85] WANG, Y., BERG,P. e SCHERG,M. **Common Spatial Subspace Decomposition Applied to Analysis of Brain Responses Under Multiple Task Conditions: a Simulation Study.** *Clinical Neurophysiology*, Vol.110, pp. 604-614, 1999.
- [86] WANG, Y. et al. **BCI Competition 2003 – Data Set IV: An Algorithm Based on CSSD and FDA for Classifying Single-Trial EEG.** *IEEE Transactions on Biomedical Engineering*. Vol.51, N.6, pp.1081-1086, Junho, 2004.
- [87] WEBSTER, J. G. **Medical Instrumentation, Application and Design.** 3ª Edição. John Wiley & Sons, Inc., 1998.

- [88] WOLPAW, J. R. et al. **Brain-Computer Interfaces for Communication and Control**. Clinical Neurophysiology. Vol. 113, pp. 767-791, 2002.
- [89] WOLPAW, J. R. et al. **Brain-Computer Interface Technology: A Review of the First International Meeting**. IEEE Transactions on Rehabilitation Engineering, Vol. 8, N. 2, pp. 164-173, junho, 2000.
- [90] WOLPAW, J.R. et al. **Brain-Computer Interface Research at the Wadsworth Center**. IEEE Transactions on Rehabilitation Engineering. Vol 8, N.2, pp. 222-226, 2000.
- [91] YAMAGUCHI, C. **Wavelet Analysis of Normal and Epileptic EEG**. Proceedings of the Second Joint EMBS/BMES Conference. Houston, EUA. Outubro, 2002.
- [92] ZHANG, X.S. e ROY, R.J. **Derived Fuzzy Knowledge Model for Estimating the Depth of Anesthesia**. IEEE Transactions on Biomedical Engineering, Vol. 48, N.3. Março, 2001.
- [93] ZIFKIN, B.G. e CRACCO, R.Q. **An Orderly Approach to the abnormal EEG**. Em DALY, D.D. e PEDLEY, T.A. **Current Practice of Clinical Electroencephalography**, 2ª Edição, Raven Press Ltd., New York, 1990.