

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**



TESE DE DOUTORADO

**Redes Neurais Artificiais para o Reconhecimento de Padrões de EEG
Durante o Movimento e Imaginação do Movimento das Mãos**

Marilú Gomes Netto Monte da Silva

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**REDES NEURAIAS ARTIFICIAIS PARA O
RECONHECIMENTO DE PADRÕES DE EEG
DURANTE O MOVIMENTO E IMAGINAÇÃO
DO MOVIMENTO DAS MÃOS**

por

MARILÚ GOMES NETTO MONTE DA SILVA

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de Doutor em Engenharia Elétrica.

**ORIENTADOR: PROF. DR. MARCO AURÉLIO BENEDETTI
RODRIGUES**

Recife, Junho de 2014.

© Marilú Gomes Netto Monte da Silva, 2014

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

S586r

Silva, Marilú Gomes Netto Monte da.

Redes neurais artificiais para o reconhecimento de padrões de EEG durante o movimento e imaginação do movimento das mãos / Marilú Gomes Netto Monte da Silva. - Recife: O Autor, 2014.

xiii, 132 folhas, il., gráfs.

Orientador: Prof. Dr. Marco Aurélio Benedetti Rodrigues.

Tese (Doutorado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2014.

Inclui Referências e Apêndices.

1. Engenharia Elétrica. 2. Eletroencefalograma. 3. Processamento de sinais bioelétricos. 4. Interface cérebro máquina. 5. Wavelet. 6. Redes neurais artificiais dinâmicas. I. Rodrigues, Marco Aurélio Benedetti. (Orientador). II. Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2014-200



Universidade Federal de Pernambuco
Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
TESE DE DOUTORADO

MARILÚ GOMES NETTO MONTE DA SILVA

TÍTULO

**“REDES NEURAIS ARTIFICIAIS PARA O
RECONHECIMENTO DE PADRÕES DE EEG DURANTE O
MOVIMENTO E IMAGINAÇÃO DO MOVIMENTO DAS MÃOS”**

A comissão examinadora composta pelos professores: MARCO AURÉLIO BENEDETTI RODRIGUES, DES/UFPE; RENATO EVANGELISTA DE ARAUJO, DES/UFPE; JOÃO HENRIQUE RANHEL RIBEIRO, DES/UFPE; ROSA AMÁLIA FIREMAN DUTRA, DEB/UFPE e MARCELO CAIRRÃO ARAUJO RODRIGUES, DFF/UFPE sob a presidência do primeiro, consideram a candidata **MARILÚ GOMES NETTO MONTE DA SILVA APROVADA.**

Recife, 30 de junho de 2014.

CECILIO JOSÉ LINS PIMENTEL

Coordenador do PPGE

MARCO AURÉLIO BENEDETTI

RODRIGUES

Orientador e Membro Titular Interno

JOÃO HENRIQUE RANHEL RIBEIRO

Membro Titular Externo

RENATO EVANGELISTA DE ARAUJO

Membro Titular Interno

ROSA AMÁLIA FIREMAN DUTRA

Membro Titular Externo

MARCELO CAIRRÃO ARAUJO RODRIGUES

Membro Titular Externo

Dedicatória

Dedico este trabalho a Deus, provedor de nossa existência e racionalidade, e a minha família:

- a meus pais Aimar e Maria de Lourdes, por todo esforço na minha criação sempre dando os melhores exemplos possíveis;
- a meu irmão Ismael, companheiro de toda vida;
- ao meu amado esposo João Marcelo, que divide comigo todas as emoções e obstáculos desta vida;
- a meu querido filho Leoni Kurt, que enche cada vez mais meu coração de alegria e orgulho.

Agradecimentos

Sou grata extensivamente às pessoas que, de alguma forma, contribuíram para a realização desta tese, em especial:

- Agradeço primeiramente ao Prof. Marco Aurélio Benedetti Rodrigues, meu orientador, por ter aceitado me orientar no doutorado, pela disposição na busca dos recursos, pela colaboração intensa para a minha formação intelectual, por todas as discussões abertas e confiança depositada, pela amizade e companheirismo desenvolvido, entre outras coisas.
- à Profa. Fernanda Alencar, ao Prof. Hélio Magalhães de Oliveira, ao Prof. Renato Evangelista de Araujo, ao Prof. Tomaz de Carvalho Barros, ao Prof. Tsang Ing Ren, ao Prof. Valdemar Rocha e ao Prof. Cecílio Pimentel, pela base concebida nas disciplinas cursadas durante o mestrado e doutorado;
- à Banca Examinadora da qualificação composta pelos professores Marco Aurélio Benedetti Rodrigues, Fernando Mendes de Azevedo e Carlos Julio Tierra Criollo, pela colaboração através das suas críticas e sugestões;
- à Banca Examinadora da tese composta pelos professores Marco Aurélio Benedetti Rodrigues, João Henrique Ranhel Ribeiro, Rosa Amalia Fireman Dutra, Renato Evangelista de Araujo e Marcelo Cairrão Araujo Rodrigues pela colaboração através das suas críticas e sugestões
- ao CNPQ pelo suporte financeiro dado;
- a toda minha família pelo apoio emocional e compreensão, em especial ao meu esposo João Marcelo e meu irmão Ismael pela ajuda dada;
- aos amigos que sempre me apoiaram. Não tendo como citar o nome de todos, gostaria de destacar Eline Quadros, Dianne Bezerra, Andréa Tenório, Alana Elza, e aos que cursaram comigo as disciplinas do programa;
- a todos os voluntários que disponibilizaram parte do seu tempo para a aquisição dos sinais bioelétricos, sem seus sinais e cooperação não haveria pesquisa.

Resumo de Tese apresentada à UFPE como parte dos requisitos necessários
para a obtenção do grau de Doutor em Engenharia Elétrica.

Redes Neurais Artificiais para o Reconhecimento de padrões de EEG durante o Movimento e Imaginação do Movimento das mãos

Marilú Gomes Netto Monte da Silva

Junho / 2014

Orientador: Prof. Dr. Marco Aurélio Benedetti Rodrigues.

Área de Concentração: Comunicação – Processamento de sinais digitais.

Palavras-chave: Eletroencefalograma, Processamento de sinais bioelétricos, Interface Cérebro Máquina, Wavelet, Redes Neurais Artificiais dinâmicas.

Número de Páginas: 145.

O registro de eletroencefalograma (EEG) é uma das principais ferramentas para a Interface Cérebro Máquina (ICM), permitindo que um indivíduo controle dispositivos eletrônicos, utilizando padrões da atividade cerebral. Várias técnicas têm sido propostas para identificar a dessincronização relacionada ao evento (ERD), que ocorre no ritmo μ do EEG, durante a imaginação do movimento (IM) e movimento. O principal problema da maioria das técnicas é a necessidade da análise de vários trechos do EEG, o que aumenta o tempo necessário para a detecção de eventos, tornando-as inviáveis para a aplicação em uma ICM em tempo real. Desta forma, este trabalho teve por objetivo o desenvolvimento de técnicas e algoritmos para detecção do movimento e IM das mãos por meio da análise de EEG, de apenas um trecho, para futura aplicação em ICM. Os algoritmos desenvolvidos são baseados em técnicas de processamento de sinais para eliminação de artefatos biológicos, separação dos ritmos do EEG, e de detecção de padrões. Esses algoritmos usam a Transformada Wavelet (TW), Redes Neurais Artificiais (RNA) e outras ferramentas matemáticas. Utilizando uma RNA estática obteve-se uma eficiência de 49% na classificação dos eventos. Com a utilização de uma RNA dinâmica, 72%, e ainda, obteve-se 77% de eficiência com a implementação de uma RNA dinâmica adaptativa. As ferramentas utilizadas são promissoras, podendo ser facilmente aplicadas na detecção de padrões do movimento e IM, tornando viável sua utilização em ICM.

Abstract of thesis presented to UFPE as a partial fulfillment of the requirements for the degree of Doctor in Electrical Engineering.

Artificial Neural Networks for EEG Pattern Recognition during Movement and Movement Imagination of hands

Marilú Gomes Netto Monte da Silva

Junho / 2014

Supervisor(s): Marco Aurélio Benedetti Rodrigues, Prof. Dr..

Area of Concentration: Communication – Digital Signal Processing.

Keywords: Electroencephalogram, Processing bioelectric signals, Brain Machine Interface, Wavelet, Neural Networks.

Number of Pages: 145.

The record electroencephalogram (EEG) is one of the main methods for Brain Machine Interface (BMI), allowing a person control electronic devices, using patterns of brain activity. Various techniques have been proposed to identify the event-related desynchronization (ERD) that occurs in the EEG mu rhythm during the movement imagination (IM) and movement. The main problem with most techniques is the need for analysis of various stretches of the EEG, which increases the time required to detect events, making it infeasible to implement in a real-time BMI. This work aims to develop techniques and algorithms for movement and IM of hands detection of volunteers by analysis of EEG, only using a stretch, for future application in BMI. The developed algorithm is based on signal processing techniques for the elimination of biological artifacts, separation of EEG rhythms, and detection patterns. These algorithms use Wavelet Transform (TW), Artificial Neural Networks (RNA) and other mathematical methods. Using a static RNA, it was obtained an efficiency of 49% in the classification of events. Using a dynamic RNA, 72%, and there it was obtained 77% efficiency by implementing an adaptive dynamic RNA. The methods are promising and can be easily applied in the detection of movement and IM patterns, making feasible their use in BMI.

Sumário

LISTA DE FIGURAS.....	VIII
LISTA DE TABELAS.....	XII
LISTA DE SÍMBOLOS E SIGLAS	XIII
1 INTRODUÇÃO.....	1
1.1 OBJETIVOS	3
1.2 ESTRUTURA DA TESE.....	4
2 BIOPOTENCIAIS E SINAIS BIOELÉTRICOS.....	6
2.1 ORIGEM DE BIOPOTENCIAIS	6
2.1.1 <i>Tipos de Biopotenciais</i>	12
2.1.2 <i>Sinais Bioelétricos</i>	13
2.1.2.1 EEG.....	13
2.1.2.2 EMG.....	14
2.1.2.3 EOG	16
3 SINAIS ELETROENCEFALOGRÁFICOS E ICM.....	18
3.1 SINAL DE ELETROENCEFALOGRAFIA.....	18
3.1.1 <i>Controle cortical sobre a função motora</i>	23
3.1.2 <i>Atividades evocadas e induzidas</i>	26
3.2 INTERFACE CÉREBRO MÁQUINA (ICM)	27
3.2.1 <i>Partes de uma ICM</i>	29
3.2.2 <i>Técnicas existentes</i>	30
4 FUNDAMENTAÇÃO TEÓRICA.....	33
4.1 TRANSFORMADA WAVELET (TW)	33
4.1.1 <i>Transformada Wavelet Contínua (CWT)</i>	34
4.1.2 <i>Transformada Wavelet Discreta (DWT)</i>	40
4.2 DENSIDADE ESPECTRAL DE POTÊNCIA.....	42
4.3 REDES NEURAIS ARTIFICIAIS	43
4.3.1 <i>Neurônios Artificiais</i>	44
4.3.2 <i>Função de Ativação</i>	46
4.3.3 <i>Número de Camadas de uma RNA</i>	47
4.3.4 <i>RNA Feedforward e Algoritmo Backpropagation</i>	47
4.3.5 <i>RNA Dinâmica</i>	49
5 RECONHECIMENTO DO MOVIMENTO E IM.....	50
5.1 AQUISIÇÃO DO SINAL DE EEG	51
5.2 PRÉ-PROCESSAMENTO DOS SINAIS.....	56
5.2.1 <i>Eliminação de Artefatos</i>	58
5.2.1.1 <i>Eliminação de padrões com características de EOG</i>	60
5.2.1.2 <i>Eliminação de padrões com características de EMG</i>	65
5.2.2 <i>Separação dos Ritmos do EEG com Wavelet</i>	69
5.2.3 <i>Energia do Sinal</i>	73
5.2.4 <i>Densidade Espectral de Potência do EEG</i>	75
5.3 RNAs PARA O PROCESSAMENTO DO EEG.....	77
5.3.1 <i>RNA Estática (RNAE)</i>	78
5.3.2 <i>RNA Dinâmica I (RNADI)</i>	82
5.3.1 <i>RNA Dinâmica Auto Adaptativa Supervisionada (RNAD2)</i>	86
6 RESULTADOS.....	93
6.1 AQUISIÇÃO E BANCO DE DADOS.....	93
6.1 RESULTADOS DAS ETAPAS DE PRÉ-PROCESSAMENTO	96
6.2 RESULTADOS DO RECONHECIMENTO DO MOVIMENTO E IM PELAS RNAs DESENVOLVIDAS	102

6.2.1	<i>Análise da RNAE</i>	105
6.2.2	<i>Análise da RNAD1</i>	107
6.2.3	<i>Análise da RNAD2</i>	110
7	CONCLUSÃO E TRABALHOS FUTUROS	116
	REFERÊNCIAS	119
	APÊNDICE	127
1	TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO	128
2	FICHA DE AVALIAÇÃO	131

Lista de Figuras

Figura 2.1 – Estrutura da membrana celular. Fonte: Modificada de: <i>http://mediateca.cl/500/imagenes%20biologia/celulas/membrana%20celular.htm</i> , visitado em 17/05/2014.....	7
Figura 2.2 – Concentração dos íons no meio intra e extracelular e os processos de difusão e bomba de Na^+ - K^+ . Fonte: autor.....	8
Figura 2.3 – Despolarização da membrana de uma célula nervosa (neurônio),mostrando a propagação do impulso nervoso e repolarização da membrana.Fonte:Modificada de: <i>http://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso3.php</i> , visitado em 17/05/2014.	10
Figura 2.4 – Estrutura de um neurônio. Fonte: Modificado de: <i>http://www.infoescola.com/sistema-nervoso/neuronios/</i> , visitado em 17/05/2014.	11
Figura 2.5 – Transmissão do impulso nervoso entre neurônios, fenda sináptica. Fonte: <i>http://arquivos.unama.br/nead/graduacao/ccbs/fisioterapia/3semestre/fisiologia_exer cicio/html/unidade3/unidade_3_page_3.html</i> , visitado em 17/05/2014.	11
Figura 2.6 – Sinal de EEG capturado no canal C3 no momento do movimento da mão entre os instantes de tempo 2 e 5s. Fonte: autor.	14
Figura 2.7 – Aquisição de sinal de EMG, com os eletrodos posicionados no grupo flexor de punho e dedos do antebraço direito, pra detecção do movimento da mão. Fonte: autor.	15
Figura 2.8 – Sinal de EMG capturado com um equipamento de EEG, mostrando 6 momentos em que ocorreu contração muscular (regiões com maior amplitude). Fonte: autor.	16
Figura 2.9 – Sinal de EOG capturado no eletrodo acima do olho esquerdo, durante o movimento de olhar para cima duas vezes. Sinal capturado com um equipamento de EEG. Fonte: autor.....	16
Figura 2.10 – Posicionamento dos eletrodos para a aquisição do sinal de EOG. Fonte: autor.	17
Figura 3.1 – Sistema Internacional 10-20 de posicionamento de eletrodos de EEG. Fonte: Modificado de: <i>http://www.neurosoft.com.br/_suporte.php?p=100</i> , acessado em: 04/06/2014	19
Figura 3.2 – Visão anatômica do cérebro identificando os lobos: frontal, parietal, temporal e occipital. Fonte: Modificado do Atlas de Fisiologia Humana de Netter, capítulo 2 de Neurofisiologia.	19
Figura 3.3 – Sinal de EEG capturado na região occipital mostrando a diferença de amplitude e frequência com olho aberto e olho fechado (circulado em vermelho). Fonte: autor.	20
Figura 3.4 – Ritmos separados de EEG espontâneo capturado na região occipital: (a) delta, (b) teta, (c) alfa e (d) beta. Fonte: autor.....	22
Figura 3.5 – É apresentado em (a) o mapa arquitetônico de Brodmann e em (b) a representação do córtex motor. Fonte:Modificado de GUYTON [12].....	23

Figura 3.6 – Planejamento do movimento. Fonte:Modificado de KANDEL et al. [6].	24
Figura 3.7 – Em (a) homúnculo sensorial e em (b) homúnculo motor. Fonte: KANDEL [6].	25
Figura 3.8 – Diagrama básico de uma ICM. Fonte: autor, e parte Modificado de: http://www.neurosoft.com.br/_suporte.php?p=100 , acessado em: 04/06/2014.	30
Figura 4.1 – Exemplos de wavelet mãe: Haar, Daubechies, Symlet, Coiflet e DMeyer, respectivamente. Adquirido na Wavelet Toolbox do MATLAB®.	33
Figura 4.2 – Gráfico da wavelet db4 e uma senóide, mostrando a aproximação por sua oscilação máxima. Adquirido na Wavelet Toolbox do MATLAB®.	36
Figura 4.3 – Sinal de EEG adquirido em O1, onde podem ser observadas três regiões de maior amplitude referentes ao evento olhos fechados, circulado em vermelho, e quatro de menor amplitude referente a olhos abertos.Fonte: autor.	37
Figura 4.4 – Faixas de frequência do sinal de EEG capturado na região occipital, (a) delta, (b) teta, (c) alfa e (d) beta. Fonte: autor.	38
Figura 4.5 – CWT das bandas (a) alfa e (b) beta, do EEG capturado no canal O1. Fonte: autor.	39
Figura 4.6 – Escalograma da banda alfa. Fonte: autor.	40
Figura 4.7 – (a) Processo de decomposição do sinal e (b) processo de reconstrução. Fonte: autor.	41
Figura 4.8 – Decomposição do sinal $x[n]$, passando pelos filtros $g[n]$ e $h[n]$ e em seguida sendo subamostrado de 2, gerando os detalhes ($D_1, D_2, D_3, \dots, D_n$) e as aproximações ($A_1, A_2, A_3, \dots, A_n$). Fonte:Modificada de OLIVEIRA [53].	42
Figura 4.9 – Modelo de neurônio artificial. Fonte: modificada de BRAGA [61].	45
Figura 4.10 – Estrutura simples de uma rede feedforward. Fonte: autor.	47
Figura 5.1 – Esquema geral da metodologia utilizada. Fonte: autor e parte Modificado de: http://www.neurosoft.com.br/_suporte.php?p=100 , acessado em: 04/06/2014.	50
Figura 5.2 – Voluntário preparado para aquisição de EEG Fonte: autor.	52
Figura 5.3 – Posicionamento dos eletrodos de EEG. Fonte: autor.	53
Figura 5.4 – Equipamento marcador desenvolvido (a esquerda) interligado ao equipamento de EEG (a direita). Fonte: autor.	54
Figura 5.5 – (a) Sinal gerado pelo marcador com região circulado em vermelho referente ao movimento, e (b) sinal de EEG capturado no ponto F3 durante um movimento. Fonte: autor.	54
Figura 5.6 – A esquerda observa-se as telas geradas para a sincronização com os eventos. E a direita o procedimento do protocolo de aquisição de cada sessão. Fonte: autor.	55
Figura 5.7 – Protocolo do movimento efetuado por cada voluntário. Fonte: modificada de: http://cinesiologiaemfisioerapia.blogspot.com.br/2011_08_01_archive.html , acessado em 15/06/2014.	56
Figura 5.8 – Exemplos do valor absoluto de sinais de EEG capturados em F3, em indivíduos diferentes, em (a) com artefato de grande amplitude e em (b) sem artefatos evidentes. Fonte: autor.	59
Figura 5.9 – Trecho de sinal de EEG que possui artefato de piscada: (a) sinal original, e (b) aproximação A5 por decomposição wavelet. Fonte: autor.	61
Figura 5.10 – (a) EOG original, (b) filtrado com MM e (c) depois de retirada a tendência do sinal. Fonte: Imagem retirada de SANTOS et al. [4].	62
Figura 5.11 – Função exponencial utilizada como expansora dos trechos com maior valor, e compressora para os trechos com menor valor, conforme tracejado. Fonte: autor.	63
Figura 5.12 – Sinal de EEG: (a) A5 e (b) envoltória do sinal (a). Fonte: autor.	63
Figura 5.13 – Reconhecimento de padrão de EOG em um sinal de EEG. Fonte: autor	64

Figura 5.14 – Eliminação de artefato de EOG em um sinal de EEG: (a) sinal original com artefato (picos com maior amplitude), (b) sinal após eliminação do artefato, (c) trecho ampliado de (a) mostrando um padrão de artefato de EOG, e em (d) trecho (c) após eliminação de artefato. Fonte: autor.	64
Figura 5.15 – Sinal de EEG com artefato muscular: (a) sinal original, e (b) detalhe D2. Fonte: autor.	66
Figura 5.16 – Circuito detector de envoltória com analogia para o EMG. Fonte: autor.	67
Figura 5.17 – Envelope do sinal de EEG com artefato de EMG, calculado com o método baseado em um circuito demodulador. Fonte: autor.	68
Figura 5.18 – Reconhecimento de padrão para o sinal de EEG com artefato de EMG: (a) classificação utilizando o limiar de 3σ , e (b) após filtro da mediana. Fonte: autor.	68
Figura 5.19 – Eliminação de artefato de EMG em um sinal de EEG: (a) trecho de um sinal original com artefato, (b) sinal após eliminação do artefato. Fonte: autor.	69
Figura 5.20 – Espectrograma da banda alfa extraída por filtragem (a) no tempo com filtro passa-faixa do tipo FIR, e (b) decomposição com wavelet, AMR. Fonte: autor.	70
Figura 5.21 – Sinal de EEG (a) original, e ritmos (b) delta, (c) teta, (d) alfa, (e) beta e (f) gama, por meio de decomposição wavelet. Fonte: autor.	71
Figura 5.22 – Sinal de EEG (a) original e (b) apenas a banda mi separada por decomposição wavelet, detalhe D4. Fonte: autor.	72
Figura 5.23 – Ritmo mi do EEG capturado em C3: (a) espontâneo, (b) movimento e (c) IM. Fonte: autor.	72
Figura 5.24 – EEG espontâneo capturado em C3: (a) ritmo mi e (b) sua energia. Fonte: autor.	73
Figura 5.25 – EEG capturado em C3: (a) ritmo mi durante o movimento, (b) energia de (a), (c) ritmo mi durante IM, e (d) energia de (c). Fonte: autor.	74
Figura 5.26 – (a) Energia calculada em C3 e (b) sinal resultante do pré-processamento. Fonte: autor.	75
Figura 5.27 – PSD calculada para os canais C3 (azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.	76
Figura 5.28 – PSD calculada para o movimento (azul) e EEG espontâneo (vermelho): (a) capturado em C3 e (b) capturado em C4. Fonte: autor.	77
Figura 5.29 – Energia do sinal capturado em C3, em (a) original e em (b) subamostrado de vinte pontos. Fonte: autor.	79
Figura 5.30 – Estrutura da RNAE desenvolvida. Fonte: autor.	80
Figura 5.31 – Padrões de treinamento para a RNAE: (a) movimento ou IM, (b) EEG basal (variação isolada), (c) movimento, (d) EEG basal e (e) EEG basal. Fonte: autor.	81
Figura 5.32 – Estrutura da rede RNAD1. Fonte: autor.	83
Figura 5.33 – Em azul o sinal de entrada da RNAD1 e em vermelho o padrão desejado, marcando o espaço temporal que ocorreu o movimento. Fonte: autor.	84
Figura 5.34 – Estrutura da RNAD2, mostrando a unidade de treinamento e a unidade de controle do treinamento adaptativo. Fonte: autor.	87
Figura 5.35 – Em azul o sinal de entrada da RNAD2 e em vermelho o padrão desejado. Fonte: autor.	88
Figura 5.36 – Diagrama do funcionamento da unidade de controle adaptativo. Fonte: autor.	91
Figura 6.1 – Em (a) sinal marcador que indica o instante de tempo que se deve iniciar e finalizar o evento, e (b) sinal de EEG capturado em F3 durante o movimento, com partes circuladas em vermelho, possivelmente relacionadas a PE visual. Fonte: autor.	94

Figura 6.2 – Em (a) sinal com marcador de movimento. Registro de EEG nos canais (b) F3, (c) F4, (d) C3, (e) C4, (f) P3 e (g) P4. Fonte: autor.	95
Figura 6.3 – Esquema geral do algoritmo de pré-processamento. Fonte: autor.	96
Figura 6.4 – Diagrama geral do algoritmo de eliminação de artefato de EOG. Fonte: autor.	97
Figura 6.5 – Eliminação de artefato de EOG em um sinal de EEG: (a) sinal original com artefato e (b) sinal após eliminação do artefato. Fonte: autor.	97
Figura 6.6 – Diagrama geral do algoritmo de eliminação de artefato de EMG. Fonte: autor.	98
Figura 6.7 – Eliminação de artefato de EMG em um sinal de EEG: (a) sinal original com artefato, e (b) sinal após eliminação do artefato. Fonte: autor.	98
Figura 6.8 – Energia do ritmo mi do canal C3 durante IM: (a) sinal que gerou padrão de ERD, e (b) não foi gerado. Fonte: autor.	99
Figura 6.9 – Voluntário destro. PSD calculada para os canais C3(azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.	100
Figura 6.10 – Possivelmente voluntário canhoto. PSD calculada para os canais C3(azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.	101
Figura 6.11 – Exemplo de reconhecimento pela RNAE: (a) e (b) em azul o sinal original a ser analisado, e em vermelho a janela percorrendo o sinal, e em (c) e (d) os pontos de saída da rede gerados janela a janela. Fonte: autor.	106
Figura 6.12 – Exemplo de reconhecimento pela RNAD1, estando em vermelho a saída da rede e em azul o sinal de entrada: (a) sinal original, (b) e (c) sinais de outros dois voluntários. Fonte: autor.	109
Figura 6.13 – Processo de calibração e validação da RNAD2. Fonte: autor.	112
Figura 6.14 – Exemplo de reconhecimento pela RNAD2, estando em vermelho a saída da rede e em azul o sinal de entrada: (a) voluntário que participou do treinamento inicial, (b) dia diferente para o voluntário (a), (c) e (d) outro voluntário para o primeiro e para o segundo dia. Fonte: autor.	113

Lista de Tabelas

Tabela 5.1 – <i>Lista de frequências relacionadas a cada nível de decomposição para um sinal de 250 Hz de frequência de amostragem.</i>	57
Tabela 5.2 – <i>Formas de reconstruir o sinal de EEG evidenciando os artefatos de EOG e EMG a partir das aproximações e/ou detalhes.</i>	61
Tabela 5.3 – <i>Separação dos ritmos do EEG, a partir da reconstrução utilizando detalhes.</i>	70
Tabela 5.4 – <i>Padrões de entrada e saída para o treinamento da RNAE.</i>	81
Tabela 5.5 – <i>Padrões de entrada e saída para o treinamento da RNAD1.</i>	85
Tabela 5.6 – <i>Padrões de entrada e saída para o treinamento da RNAD2.</i>	89
Tabela 6.1 – <i>Resultado (percentual de acerto) da interpretação da mão de origem do movimento e da IM pelo sistema simbólico SS.</i>	101
Tabela 6.2 – <i>Parte da tabela gerada automaticamente pelo algoritmo de análise de saída da RNAE, acrescentando as colunas de análise dos dados.</i>	107
Tabela 6.3 – <i>Resultado da análise dos resultados do reconhecimento realizado pela RNAE.</i>	107
Tabela 6.4 – <i>Resultado da análise dos resultados do reconhecimento realizado pela RNAD1.</i>	110
Tabela 6.5 – <i>Resultado geral da análise dos resultados do reconhecimento realizado pela RNAD2, para ambos os dias de teste.</i>	114

Lista de Símbolos e Siglas

IHM – Interface Homem Máquina
ICM – Interface Cérebro Máquina
BMI – Brain Machine Interface
ECG – Eletrocardiograma
EMG – Eletromiograma
EEG – Eletroencefalograma
EOG – Eletrooculograma
ECoG – Eletrocorticograma
ELA – Esclerose Lateral Amiotrófica
AMP – Atrofia Muscular Progressiva
ELP – Esclerose Lateral Primária
PBP – Paralisia Bulbar Progressiva
IM – Imaginação do Movimento
PRE – Potencial Relacionado a Evento
AMR – Análise Multiresolucional
HPF – High filter pass (filtro passa-alta)
LPF – Low filter pass (filtro passa-baixa)
MM – Moving Average (Média Móvel)
RC – Resistor-Capacitor
AM – Modulação em Amplitude
PSD – Densidade Espectral de Potência
RNA – Rede Neural Artificial
RNAE – Rede Neural Artificial Estática
RNAD – Rede Neural Artificial Dinâmica
MSC – Magnitude Quadrática da Coerência
VP – Verdadeiro-Positivo
VN – Verdadeiro-Negativos
FP – Falso-Positivo
FN – Falso-Negativo
SNC – Sistema Nervoso Central
fMRI – Ressonância Magnética Funcional
PE – Potencial Evocado
SS – Sistema Simbólico

CAPÍTULO 1

Introdução

A utilização de novas técnicas na aquisição, processamento e análise de sinais bioelétricos, têm contribuído para a melhoria dos processos de monitoramento fisiológico de indivíduos e realização de diagnósticos e prognósticos mais precisos na área médica. A análise dos sinais bioelétricos tem possibilitado a comunicação entre os sistemas biológicos e equipamentos, promovendo um tipo de Interface Homem Máquina (IMH). Essa interface vem tornando possível o acionamento de equipamentos por pessoas com problema de motricidade, desde a simples dificuldade de mobilidade a doenças degenerativas nos neurônio motores.

Entre os sinais bioelétricos, o eletromiograma (EMG), que pode ser utilizado na identificação de patologias musculares por meio da observação da atividade elétrica muscular em diferentes estágios de ativação [1], também pode ser utilizado em uma IHM, por exemplo, para o acionamento de uma prótese [2]. O eletrooculograma (EOG) que tem por objetivo avaliar a função motora ocular [3], pode ser utilizado, por exemplo, no acionamento de uma garra mecânica [4], ou controle do cursor do mouse de um computador [5].

Em relação ao sinal bioelétrico proveniente da atividade cerebral, o eletroencefalograma (EEG) [6], existem muitos estudos e aplicações clínicas. O EEG vem se mostrando útil em avaliações diagnósticas de várias doenças neurológicas, algumas das quais possuem padrões eletroencefalográficos característicos, como por exemplo, diagnósticos de encefalites, diagnóstico do sono [7], abscessos cerebrais e epilepsia [8].

Porém, os sinais de EEG são de difícil interpretação, uma vez que representam a atividade de bilhões de neurônios, transmitidos através dos tecidos, fluidos e escalpo. Apenas algumas características podem ser facilmente interpretadas. No traçado original do EEG, sem nenhum processamento digital, é possível ver pontos que podem auxiliar na identificação de pequenas ou grandes doenças epiléticas. A análise do espectro de frequência do EEG pode revelar mudanças na potência do sinal em diferentes frequências, por exemplo, produzidas durante vários estágios do sono, como resultado de efeitos anestésicos e, algumas vezes, como resultado de traumas cerebrais. Além da análise do EEG para fins de diagnóstico, existem diversos estudos voltados para a utilização desse sinal para promover a comunicação entre homens e máquinas, promovendo a Interface Cérebro Máquina (ICM). A ICM permite a comunicação sem movimento, em que os usuários podem enviar mensagens ou comandos por meio de medidas diretas da atividade cerebral, de forma invasiva com o ECoG, ou não invasiva com o EEG.

O alvo desta técnica são as pessoas que possuem algum tipo de dificuldade ou deficiência motora, seja essa parcial, devido a amputações, ou total devido aos estágios mais avançados de doenças do neurônio motor [9], como por exemplo:

- Esclerose Lateral Primária (ELP): afeta os neurônios musculares superiores;
- Atrofia Muscular Progressiva (AMP): degeneração dos neurônios musculares inferiores;
- Esclerose Lateral Amiotrófica (ELA): lesões nos neurônios superiores e inferiores;
- Paralisia Bulbar Progressiva (PBP): acometimento predominante dos neurônios motores bulbares.

Ainda pode beneficiar indivíduos com problemas de condução nervosa, por exemplo, traumatismo raquimedular, lesão irreversível da medula espinhal [10]. No futuro, indivíduos com esse tipo de acometimento, em que a função dos músculos esteja

preservada, poderão mover membros pela contração de diferentes músculos por meio de eletroestimulação de acordo com a interpretação dos sinais cerebrais.

Utilizando recursos de interface cérebro máquina (ICM), parte específica da IHM que trata da análise de sinais provenientes do cérebro, indivíduos que possuem incapacidade motora poderão ter a oportunidade de mover e/ou controlar equipamentos com seus sinais cerebrais, imaginando algum tipo de movimento ou outra tarefa cognitiva.

Diversos estudos demonstram o benefício que indivíduos com deficiências motoras desfrutam por meio da mobilidade independente, por exemplo, com cadeiras motorizadas. A mobilidade independente reduz a necessidade de ajuda profissional e de familiares, trazendo como consequência um aumento da vontade e da autoestima [11]. Indivíduos acometidos por neuropatias motoras [9] não tem seus problemas de mobilidade atenuados com equipamentos que funcionam de forma manual, devido à incapacidade de realizar grandes movimentos. Na intenção de proporcionar uma melhor qualidade de vida a esses indivíduos, a aquisição e processamento de sinais bioelétricos podem ser utilizados para o controle de equipamentos.

Assim, a motivação desse trabalho parte da possibilidade de realizar acionamentos por meio de algoritmos de reconhecimento de padrões, por meio da análise de sinais bioelétricos, em especial EEG, com a finalidade de realizar algum tipo de evento mecânico de forma artificial que auxilie o indivíduo acometido de problemas locomotores.

1.1 Objetivos

Esse trabalho tem por objetivo principal desenvolver técnicas de processamento digital de sinais de EEG para detecção de padrões relacionados ao movimento e imaginação do movimento (IM) das mãos. Com a finalidade de desenvolver técnicas de ICM para acionamentos, que possam posteriormente auxiliar a mobilidade de pessoas

portadoras de deficiências motoras.

Os objetivos específicos desse trabalho são:

- Aquisição do sinal de EEG por meio do equipamento VERTEX SC823 da Meditron, em indivíduos saudáveis e destros;
- Desenvolver técnicas de processamento de registros de EEG para a atenuação das frequências indesejáveis e possíveis artefatos, evidenciando a região de interesse do sinal;
- Desenvolver técnicas de reconhecimento de padrões para identificar o movimento e IM das mãos.
- Realizar análise dos resultados obtidos dos algoritmos de reconhecimento por meio do cálculo da sensibilidade, especificidade e eficiência.

1.2 Estrutura da Tese

Este trabalho está organizado em 7 (sete) capítulos. Neste Capítulo 1, é feita uma introdução ao trabalho onde estão expostas suas motivações e seu objetivo.

No Capítulo 2 são apresentados conceitos de como se originam os biopotenciais e exemplos de três tipos de sinais bioelétricos com suas características. O Capítulo 3 versa sobre o sinal de eletroencefalografia com suas principais características e processo de aquisição. E são apresentados aspectos de ICM e seus principais tipos, destacando os avanços alcançados nas pesquisas desenvolvidas, realizando uma revisão bibliográfica das técnicas existentes.

O Capítulo 4 aborda as bases teóricas matemáticas das técnicas de processamento utilizadas no trabalho, como a Transformada Wavelet, Densidade Espectral de Potência e Redes Neurais Artificiais.

No Capítulo 5 é apresentada toda a metodologia deste trabalho, desde a aquisição

dos sinais, pré-processamento com eliminação de artefatos de movimento ocular, como a piscada palpebral, e movimento, “filtragem” para separação dos ritmos frequenciais de interesse, até o reconhecimento dos padrões de movimento e IM.

O Capítulo 6 apresenta os resultados referentes à aquisição e todos os passos das técnicas de processamento desenvolvidas. Neste capítulo também é realizada a análise dos resultados obtidos com os algoritmos de reconhecimento.

Por fim, o Capítulo 7 expõe as conclusões deste trabalho além de discutir propostas de trabalhos futuros a esta pesquisa.

CAPÍTULO 2

Biopotenciais e Sinais bioelétricos

Vários órgãos do corpo humano, tais como coração, cérebro, músculos e olhos, exercem suas funções por meio de geração de atividade elétrica nos mesmos. Neste capítulo serão descritos como são originados os biopotenciais e as principais características de cada sinal como: o Eletroencefalograma (EEG), atividade elétrica do cérebro; Eletromiograma (EMG), atividade elétrica relacionada à contração e relaxação dos músculos; e o Eletrooculograma (EOG), resposta ao movimento dos olhos.

2.1 Origem de Biopotenciais

A origem de biopotenciais pode ser considerada a partir da atividade elétrica a nível celular. O potencial elétrico através da membrana de uma célula é resultado de diferentes concentrações iônicas que existem no meio intra e extracelulares.

A estrutura da membrana que reveste cada célula do corpo humano consiste quase inteiramente de uma camada bilipídica, contendo também grande número de moléculas de proteínas, incrustadas nos lipídios, algumas delas atravessando toda espessura da membrana, como na Figura 2.1. Essa bicamada lipídica não se mistura com os líquidos intra e extracelular, constituindo uma barreira para o movimento de moléculas de água e substâncias hidrossolúveis. Contudo, algumas substâncias ditas lipossolúveis podem atravessar essa bicamada. As moléculas de proteínas nas membranas podem ser classificadas como proteínas transportadoras (sua maioria) ou proteínas canais, ambas são seletivas para o tipo de molécula ou íon que vai atravessar a membrana [12]. As

transportadoras se ligam as moléculas ou íons a serem transportados, ocorrem alterações estruturais na molécula da proteína, então a substância é movida pelos interstícios da proteína até o outro lado da membrana. As proteínas canais possuem espaços aquosos por toda extensão da molécula, permitindo o livre movimento de água, bem como de íons e moléculas selecionadas.

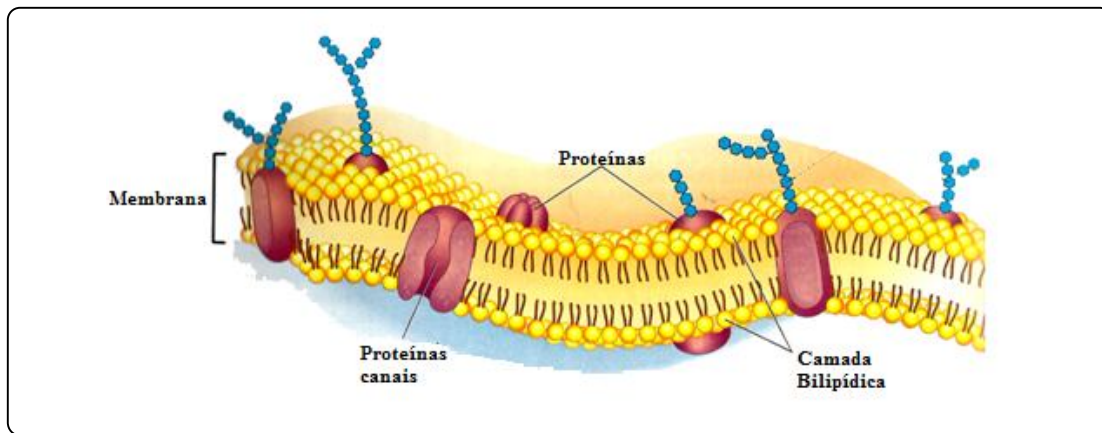


Figura 2.1 – Estrutura da membrana celular. Fonte: Modificada de: <http://mediateca.cl/500/imagenes%20biologia/celulas/membrana%20celular.htm>, visitado em 17/05/2014.

Existem dois tipos de transporte através da membrana celular, por meio de transporte passivo ou por transporte ativo. O transporte passivo é o movimento, a favor do gradiente (sem gasto de energia), de substâncias, molécula a molécula, através dos espaços intramoleculares da membrana ou em combinação com proteína transportadora. A energia causadora desse tipo de transporte é chamada de energia cinética normal da matéria. Esse transporte é dividido em: difusão simples, que é o movimento cinético molecular através da membrana sem a necessidade de se fixar a proteínas transportadoras; difusão facilitada é mediada por proteínas transportadoras; e osmose, que é o movimento devido à diferença de concentração. Já o transporte ativo é o movimento de íons ou de outras substâncias através da membrana em combinação com a proteína transportadora, que faz a substância se mover em direção oposta ao gradiente de energia, por exemplo, passando de um local de baixa concentração para um de alta concentração. Esse movimento além da energia cinética

requer uma fonte extra de energia, ATP (adenosina trifosfato).

As células em geral possuem íons dissolvidos em solução sendo então dotadas de cargas elétricas. Os principais grupos portadores de carga elétrica que aparecem no ambiente celular são os íons sódio (Na^+), potássio (K^+), cloro (Cl^-), e ânions orgânicos carregados (A^-), como proteínas e aminoácidos. A concentração desses íons é diferente em relação ao ambiente intracelular e o extracelular. Dessa forma, o interior da célula possui uma maior concentração de íons K^+ e A^- tornando a carga elétrica líquida resultante negativa. O exterior possui uma concentração maior de íons Na^+ e Cl^- com uma carga elétrica resultante positiva. Essa diferença de polaridade gera uma diferença de potencial elétrico através da membrana celular, chamado de potencial de membrana, sendo definido como a diferença de potencial entre o ambiente intracelular e o extracelular [12]. Para manter o equilíbrio da célula é necessária essa diferença de concentração, que é mantida pelo transporte ativo denominado bomba de sódio-potássio, que bombeia sódio para o meio extracelular e potássio para o interior da célula, vide Figura 2.2. Sendo assim a responsável por manter a diferença de concentração adequada dos íons sódio e potássio através da membrana.




Figura 2.2 – Concentração dos íons no meio intra e extracelular e os processos de difusão e bomba de Na^+ - K^+ . Fonte: autor.

Essa diferença de concentração de íons é necessária principalmente para as células musculares e nervosas. Essas células quando em repouso possuem eletronegatividade em seu interior e eletropositividade em seu exterior. O potencial de repouso das fibras nervosas, ou seja, quando não estão transmitindo impulsos nervosos, é de cerca de -75mV [12]. Os sinais nervosos são transmitidos por potenciais de ação, que são rápidas alterações do potencial de membrana que se propagam com grande velocidade por toda a membrana da fibra nervosa, até a sua extremidade final. A célula é dita polarizada quando ela se encontra no seu estado de repouso.

Com a excitação da célula nervosa, por estímulos que atinjam o limiar de excitabilidade da célula (-65mV), um potencial de ação é disparado dentro de um princípio denominado de “tudo ou nada”. O potencial de ação se caracteriza por três etapas distintas: despolarização, repolarização e hiperpolarização. O Potencial de Ação (PA) é a inversão súbita da polarização do meio intra e extracelular, que retorna a se polarizar rapidamente. Esse ciclo de despolarização e repolarização dura poucos milissegundos. Um PA é disparado quando uma despolarização inicial atinge o potencial limiar excitatório. Esse limiar varia, mas normalmente se encontra em torno de 15mV acima do potencial de repouso da membrana. Quando se atinge esse limiar a membrana fica mais permeável ao íon sódio, cuja entrada excede a saída de potássio, o que causa a despolarização da membrana (Figura 2.3) levando a abertura de mais canais de sódio. Após alguns décimos de milésimos de segundos após a despolarização os canais de sódio começam a se fechar e os canais de potássio se abrem mais que o normal. Assim, ocorre a rápida difusão dos íons potássio para o exterior da célula, ocorrendo uma hiperpolarização, com excesso de negatividade no interior celular o que impede a ocorrência de um novo potencial de ação, seguido do restabelecimento do potencial de repouso da membrana, esse processo chama-se repolarização [6].




Figura 2.3 – *Despolarização da membrana de uma célula nervosa (neurônio), mostrando a propagação do impulso nervoso e repolarização da membrana.* Fonte: Modificada de: <http://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso3.php>, visitado em 17/05/2014.

As células nervosas, denominadas neurônios, são formadas por dendritos (terminal de recepção do estímulo), corpo celular, axônio e terminal do axônio (terminal de transmissão). Parte do axônio pode ser mielinizada ou amielinizada, ou seja, se possui ou não bainha de mielina. Os trechos dos neurônios são ditos mielinizados quando um conjunto de células recobre o axônio, as células de *Schwann*, formando a bainha de mielina. Entre duas células de *Schwann* existe o nodo de *Ranvier*, que é uma área sem mielina. A estrutura do neurônio pode ser visualizada na Figura 2.4. Nesses neurônios mielinizados a condução do impulso nervoso é realizada de forma saltatória através dos nodos de *Ranvier*, obtendo alta velocidade de transmissão.




Figura 2.4 – Estrutura de um neurônio. Fonte: Modificado de: <http://www.infoescola.com/sistema-nervoso/neuronios/>, visitado em 17/05/2014.

O impulso nervoso é conduzido dos dendritos ao terminal do axônio ou telodendros, e é transmitido ao próximo neurônio por uma região denominada de sinapse [6]. Essa transmissão entre neurônios ocorre por meio de mediadores químicos, os neurotransmissores, que são secretados pela célula pré-sináptica na fenda sináptica e estimulam os receptores das células pós-sinápticas que ficam nos dendritos do próximo neurônio, vide Figura 2.5.




Figura 2.5 – Transmissão do impulso nervoso entre neurônios, fenda sináptica. Fonte: http://arquivos.unama.br/nead/graduacao/ccbs/fisioterapia/3semestre/fisiologia_exercicio/html/unidade3/unidade_3_page_3.html, visitado em 17/05/2014.

O mesmo ocorre em uma transmissão neuromuscular, em que o impulso nervoso é transmitido percorrendo o neurônio motor até as suas terminações nas fibras musculares, com o objetivo de efetuar uma contração muscular. Em cada terminação o neurônio motor secreta pequena quantidade de substância neurotransmissora, a acetilcolina. A acetilcolina é recebida por receptores no músculo e uma enzima (acetilcolinesterase) degrada o hormônio presente na fenda para que cesse a contração.

2.1.1 Tipos de Biopotenciais

Algumas das células do corpo humano são excitáveis e produzem um potencial de ação, que resulta em um fluxo de íons através da membrana da célula em resposta a um estímulo elétrico ou uma mudança transitória no gradiente elétrico da célula [13]. A seguir alguns exemplos de biopotenciais são citados.

Biopotencial relacionado ao sinal cardíaco: Os biopotenciais cardíacos são gerados no nodo sinoatrial localizado no átrio direito do coração. Esse nodo envia impulsos elétricos que percorrem as paredes dos átrios e estimula o nodo atrioventricular, responsável pelos impulsos que percorrem as paredes dos ventrículos. Essa excitação causa uma contração síncrona do músculo do coração. O sinal correspondente a esse biopotencial é representado pelo ECG [12].

Biopotencial relacionado à atividade cerebral: A excitação elétrica de um neurônio produz um potencial de ação que se desloca entre seus dendritos e axônio. No córtex (massa cinzenta) cerebral estão localizados os corpos dos neurônios e seus axônios na parte mais interna (massa branca) do cérebro. A atividade de um grande número de neurônios e suas interações com o córtex resulta no sinal de EEG [6].

Biopotencial relacionado à contração muscular: A excitação de neurônios, transmitida de um nervo a uma junção neuromuscular produz estímulos de fibras nervosas.

Elementos constitutivos de fibras musculares são as unidades motoras simples e sua atividade elétrica é chamada de potencial motor unitário [14]. A atividade elétrica de um grande número de unidades motoras simples manifesta-se na superfície do corpo como o sinal de EMG.

Biopotencial relacionado ao movimento ocular: Existe uma diferença de potencial entre a córnea e a retina que forma um dipolo elétrico entre esses dois extremos. O movimento do globo ocular relativo ao dipolo altera esse potencial elétrico. Colocando-se eletrodos na vizinhança dos olhos é possível medir o potencial associado com o movimento dos olhos, chamado de EOG.

2.1.2 Sinais Bioelétricos

A seguir são descritas algumas características dos sinais bioelétricos usados nesse trabalho. O sinal de EEG objeto principal de estudo desse trabalho é o que apresenta maior complexidade na sua aquisição possuindo artefatos biológicos em sua maioria relacionados à contração muscular e movimento dos olhos. Assim, com a finalidade de eliminar esses artefatos são estudados os sinais de EMG e EOG, em paralelo ao de EEG.

2.1.2.1 EEG

O sinal de EEG é referente à atividade elétrica do cérebro, capturado no escalpo. As atividades coletivas de neurônios corticais geram o sinal de EEG (Figura 2.6) que é caracterizado por sua baixa amplitude e alta complexidade de análise.




Figura 2.6 – Sinal de EEG capturado no canal C3 no momento do movimento da mão entre os instantes de tempo 2 e 5s. Fonte: autor.

Problemas na aquisição de sinais de EEG são ocasionados por fontes de artefatos fisiológicos, e não fisiológicos. Fontes fisiológicas de artefato podem ser originadas por movimento, contração muscular, movimento dos olhos e piscadas, e ainda sinais das batidas do coração. Os artefatos não fisiológicos são em sua maioria interferências elétricas originadas de fontes comuns como linhas de potência da rede elétrica, rádio frequência (RF) e interferências magneticamente induzidas. Aterramento adequado da rede elétrica e o uso de técnicas de medição adequadas podem atenuar os efeitos de tais fontes de ruídos e interferências [15].

2.1.2.2 EMG

Na eletromiografia de superfície o sinal de EMG é adquirido com o uso de eletrodos posicionados próximos ao grupo muscular de interesse. Por exemplo, um par de eletrodos dispostos no grupo flexor de punho e dedos do antebraço direito para captar sinais de EMG gerados devido ao movimento da mão, conforme Figura 2.7. No exemplo da Figura 2.7 utiliza-se a técnica bipolar (diferencial entre os dois eletrodos), onde são dispostos dois eletrodos sobre cada músculo, com uma distância entre eles de 3cm. Os eletrodos que devem ser usados para tais aplicações devem ser firmemente acoplados ao local do grupo muscular que se deseja realizar a aquisição livre de artefatos. Para isso,

normalmente, são utilizados eletrodos de superfície descartáveis, com baixa impedância, confeccionado em espuma de polietileno com adesivo medicinal hipoalergênico de alta adesividade, contato Ag/AgCl (Prata/Cloreto de Prata) com gel sólido aderente (Hydrogel). Esse eletrodo adesivo é fixado na pele (limpa com álcool a 70%) do voluntário.




Figura 2.7 – Aquisição de sinal de EMG, com os eletrodos posicionados no grupo flexor de punho e dedos do antebraço direito, pra detecção do movimento da mão. Fonte: autor.

O sinal de EMG (Figura 2.8) possui amplitude entre 1 e 10mV, e largura de faixa de 20Hz a 1kHz [15]. Em equipamentos comerciais de EMG, comumente são utilizados filtros para reduzir artefatos e interferências. Por exemplo, a utilização de um filtro passa alta com frequência de corte em 20Hz e filtro passa baixa com frequência de corte em 500Hz. Esse tipo de filtragem do sinal ainda contribui na eliminação de artefatos oriundos do movimento pele-eletrodo. Porém, muitas vezes necessita-se de outros filtros, em outras faixas de frequência, com a finalidade de eliminar artefatos.




Figura 2.8 – Sinal de EMG capturado com um equipamento de EEG, mostrando 6 momentos em que ocorreu contração muscular (regiões com maior amplitude). Fonte: autor.

2.1.2.3 EOG

O sinal de EOG (Figura 2.9) é composto por potenciais elétricos gerados em consequência do movimento do globo ocular, e possui amplitude entre 10 e 100 μ V, com frequência de 0 a 10Hz [15].




Figura 2.9 – Sinal de EOG capturado no eletrodo acima do olho esquerdo, durante o movimento de olhar para cima duas vezes. Sinal capturado com um equipamento de EEG. Fonte: autor.

A aquisição do sinal de EOG é realizada com a colocação de eletrodos de superfície descartáveis, similares aos utilizados na aquisição de sinais de EMG. Um eletrodo de

referência é fixado na testa do voluntário, dois eletrodos são postos em ambas as laterais de cada olho para medição de movimentos horizontais, e outros dois são fixados acima e abaixo de um dos olhos, ou de ambos, para medição de movimentos verticais, conforme Figura 2.10.



Figura 2.10 – *Posicionamento dos eletrodos para a aquisição do sinal de EOG. Fonte: autor.*

CAPÍTULO 3

Sinais Eletroencefalográficos e ICM

O primeiro registro da atividade cerebral em humanos foi realizado em 1924 por HANS BERGER [17]. Desde então grandes avanços vem sendo conquistados na área de mapeamento da atividade cerebral. Hoje a atividade cerebral pode ser mapeada utilizando diferentes formas, como as técnicas de imageamento, como a tomografia por emissão de pósitrons (PET) [18] e ressonância magnética funcional (fMRI) [18]. E, também, por técnicas de captura de biopotenciais elétricos, que pode ser realizada de forma invasiva, o eletrocorticograma (ECoG) [19], ou não invasiva, o eletroencefalograma (EEG) [6]. Dentre essas técnicas, a eletroencefalografia é a mais utilizada na implementação de uma Interface Cérebro Máquina (ICM) por ser um método não invasivo e de fácil registro, e por utilizar um equipamento de pequeno porte e de baixo custo.

3.1 Sinal de Eletroencefalografia

O sinal de EEG de um ser humano normal possui amplitude entre 20 e 100 μ V, com frequência de 0,5 a 30Hz [6]. Na aquisição de EEG são utilizados eletrodos reutilizáveis, geralmente de placa de ouro ou Ag/AgCl que devem ser seguramente fixados no escalpo de modo a se obter uma baixa impedância de contato. O formato do eletrodo permite a colocação de gel eletrolítico ou pasta condutora, com a finalidade de melhorar a interface pele eletrodo. O posicionamento dos eletrodos é padronizado, o Sistema Internacional 10-20 [16] de posicionamento de eletrodos de EEG [16], como mostrado na Figura 3.1, é um

dos sistemas mais utilizados em registros clínicos. Esse sistema utiliza distâncias relativas de 10 ou 20%, em relação ao Nasion, Inion e Vertex.




Figura 3.1 – Sistema Internacional 10-20 de posicionamento de eletrodos de EEG. Fonte: Modificado de: http://www.neurosoft.com.br/_suporte.php?p=100, acessado em: 04/06/2014

Neste sistema, os números pares estão relacionados com o lado direito da cabeça e os ímpares com o esquerdo. As letras F (frontal), C (central), P (parietal), T (temporal) e O (occipital) são utilizadas para identificar as diferentes regiões do córtex, como apresentadas na Figura 3.2. Usualmente se utilizam 24 eletrodos, em que 21 são colocados no escalpo (Fp1, Fpz, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, Oz, e O2), 2 são auriculares (A1 e A2) e 1 de aterramento que pode ser posto no lugar de Fpz.

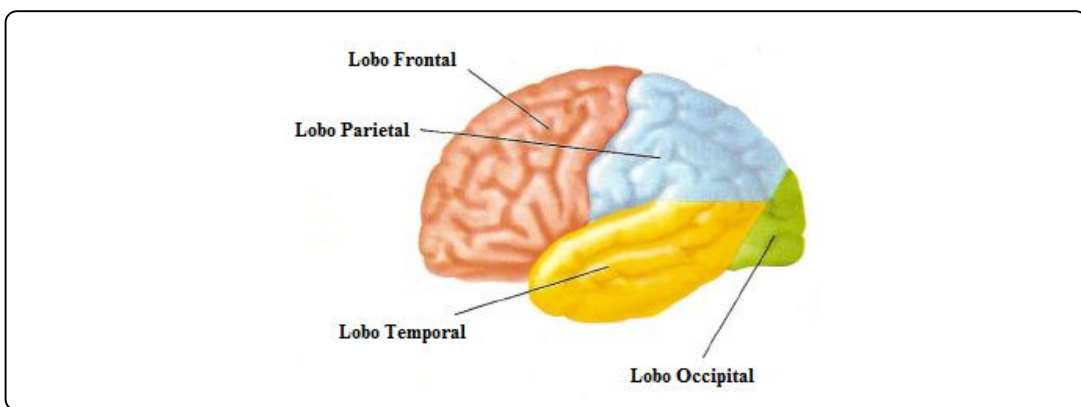


Figura 3.2 – Visão anatômica do cérebro identificando os lobos: frontal, parietal, temporal e occipital. Fonte: Modificado do Atlas de Fisiologia Humana de Netter, capítulo 2 de Neurofisiologia.

A atividade elétrica medida no escalpo, sinal de EEG, é uma medida atenuada do fluxo de corrente extracelular do somatório de atividades de diversos neurônios. No entanto, nem todas as células nervosas contribuem igualmente. O EEG reflete predominantemente a atividade dos neurônios corticais próximos ao eletrodo fixado. Devido ao fato da atividade elétrica se originar em neurônios no tecido subjacente do cérebro, a forma de onda detectada pelo eletrodo de superfície depende da orientação e da distância da fonte elétrica em relação ao eletrodo [6]. O sinal de EEG é atenuado pela filtragem produzida pela intervenção das camadas de tecido e osso, que atuam como resistores e capacitores em um circuito elétrico. Assim, a amplitude do potencial de EEG (microvolts) é o resultado do somatório de tensão de um agrupamento de neurônios, que é menor do que as variações de tensão em um único neurônio (milivolts) quando medido diretamente no córtex.

A amplitude e a frequência do EEG variam de acordo com a atividade cerebral. Um exemplo está relacionado ao sinal adquirido na região occipital com os olhos fechados e abertos. Quando os olhos estão abertos observa-se uma amplitude menor e frequência maior. Quando os olhos estão fechados a amplitude aumenta e a frequência diminui, conforme Figura 3.3.




Figura 3.3 – Sinal de EEG capturado na região occipital mostrando a diferença de amplitude e frequência com olho aberto e olho fechado (circulado em vermelho). Fonte: autor.

Os ritmos dos sinais eletroencefalográficos (Figura 3.4) são classificados de acordo com as várias frequências observadas nesses sinais [6]:

- *Delta* (δ) - O ritmo δ compreende a banda de 0,5 a 4 Hz, com amplitude variável, inferior a $100\mu\text{V}$. Este ritmo normalmente está relacionado com o estado de sono profundo, sendo mais predominante na região frontal. Por causa de sua magnitude variável, às vezes é confundido com um artefato ou mesmo alguma anomalia associada ao cérebro.
- *Teta* (θ) - O ritmo θ é limitado pela banda de 4 a 8 Hz, com amplitude que pode alcançar $100\mu\text{V}$. Este ritmo está relacionado com o estresse emocional, mais especificamente com a frustração e desapontamento, podendo ser observado nas regiões parietal e temporal. Pode-se observá-lo também, durante momentos de inspiração criativa e profunda meditação.
- *Alfa* (α) - O ritmo α se refere a banda de 8 a 13 Hz, com amplitude entre 30 e $50\mu\text{V}$. É mais predominante sobre as regiões occipital e parietal do cérebro. Este ritmo está, normalmente, associado ao estado de vigília relaxado e os olhos fechados momento que atinge sua amplitude máxima.
- *Mi* (μ) - O ritmo μ se origina no córtex motor, englobando as áreas motoras primária, suplementar e parietal. Suas características são semelhantes às do ritmo α , com amplitude inferior a $50\mu\text{V}$ e frequência entre 8 e 13 Hz. Sua amplitude diminui com o movimento ou intenção de movimento.
- *Beta* (β) - O ritmo β compreende a banda de frequência entre 13 e 30 Hz, podendo ser detectado sobre a região parietal e frontal com uma amplitude entre 5 e $30\mu\text{V}$. Este ritmo está, normalmente, associado a intensa atividade mental, pensamento e atenção. E pode distribuir-se de forma assimétrica entre os hemisférios.




Figura 3.4 – Ritmos separados de EEG espontâneo capturado na região occipital: (a) delta, (b) teta, (c) alfa e (d) beta. Fonte: autor.

3.1.1 Controle cortical sobre a função motora

A maioria dos movimentos voluntários iniciados no córtex cerebral passa pelos centros inferiores (medula, tronco cerebral, núcleos da base e cerebelo) antes do sinal chegar aos músculos. Contudo, para alguns movimentos o córtex tem quase uma via direta dirigida para os neurônios motores anteriores da medula, sobrepondo-se a alguns centros no percurso. Isso ocorre no controle de movimentos finos e com a destreza das mãos e dos dedos [12].

Na Figura 5.2(a) observam-se algumas áreas funcionais do córtex cerebral. O córtex motor está localizado anteriormente ao sulco cortical central. Posteriormente ao sulco central tem-se a área somatosensorial, que envia ao córtex motor muitos dos sinais que iniciam as atividades motoras. O córtex motor é dividido em três subáreas: o córtex motor primário, a área pré-motora e a área motora suplementar. A Figura 5.2(b) mostra a área 4 (córtex motor primário), a área 6 (córtex pré-motor e motor suplementar) e áreas 1, 2, 3, 5 e 7 (córtex sensorial) correspondentes ao mapa citoarquitetônico de BRODMANN [6].

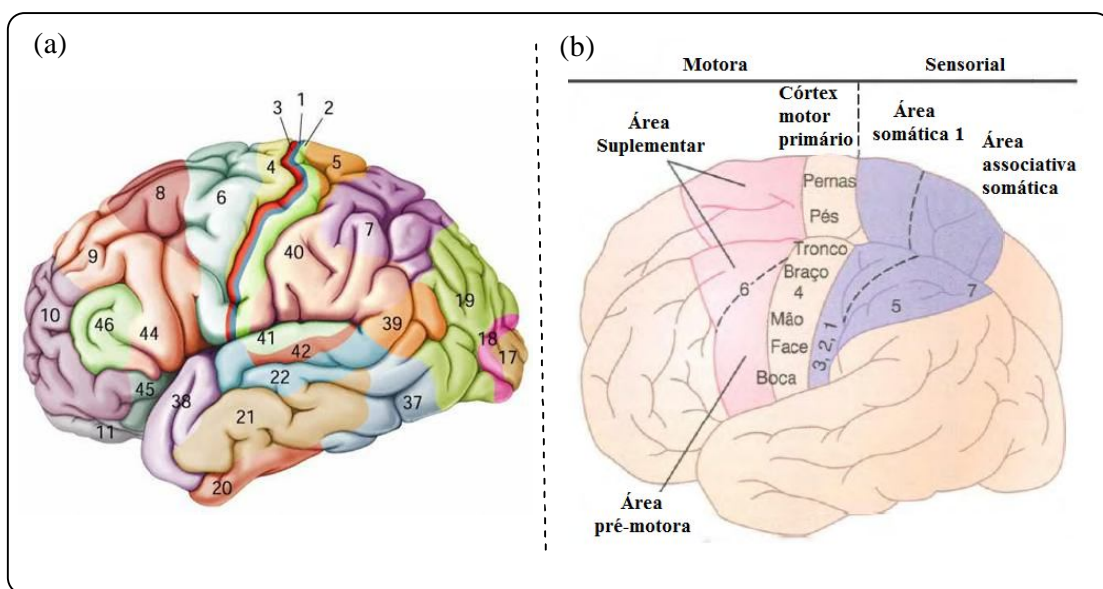


Figura 3.5 – É apresentado em (a) o mapa arquiteônico de Brodmann e em (b) a representação do córtex motor. Fonte: Modificado de GUYTON [12].

O planejamento motor tem início na área pré-motora que está relacionada com o controle motor dos músculos, por meio da informação recebida do córtex parietal posterior (áreas 5 e 7) que definem os grupos musculares e músculos específicos que devem ser ativados para a realização da tarefa. A área motora suplementar comanda o início do movimento dos músculos. O movimento ocorre com a transmissão da informação das áreas pré-motoras e suplementares que são enviadas para as áreas do córtex motor primário, conforme Figura 3.6.

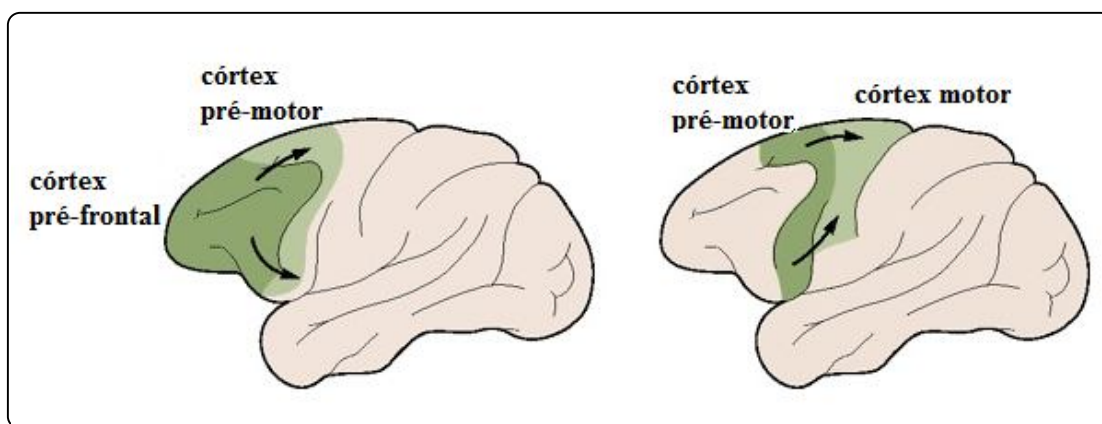


Figura 3.6 – Planejamento do movimento. Fonte: Modificado de KANDEL et al. [6].

Cada parte do corpo é representada no córtex em proporção com seu grau de inervação. Assim, a área do córtex dedicada aos dedos é maior do que para os braços. Do mesmo modo, a representação dos lábios e da língua ocupa uma região maior da superfície cortical do que a do restante da face [6]. A Figura 3.7a representa o homúnculo sensorial.

A estimulação elétrica em regiões específicas do córtex motor primário gera um mapeamento das áreas musculares sobre uma determinada seção do cérebro. Quanto mais complexo for o movimento maior é a área da superfície do córtex que o representa. A Figura 3.7b mostra o homúnculo motor, percebe-se a grande área cerebral que representa a mão, comparado com o resto dos membros do corpo. Por esse motivo, vários estudos justificam o uso da mão na imaginação do movimento.

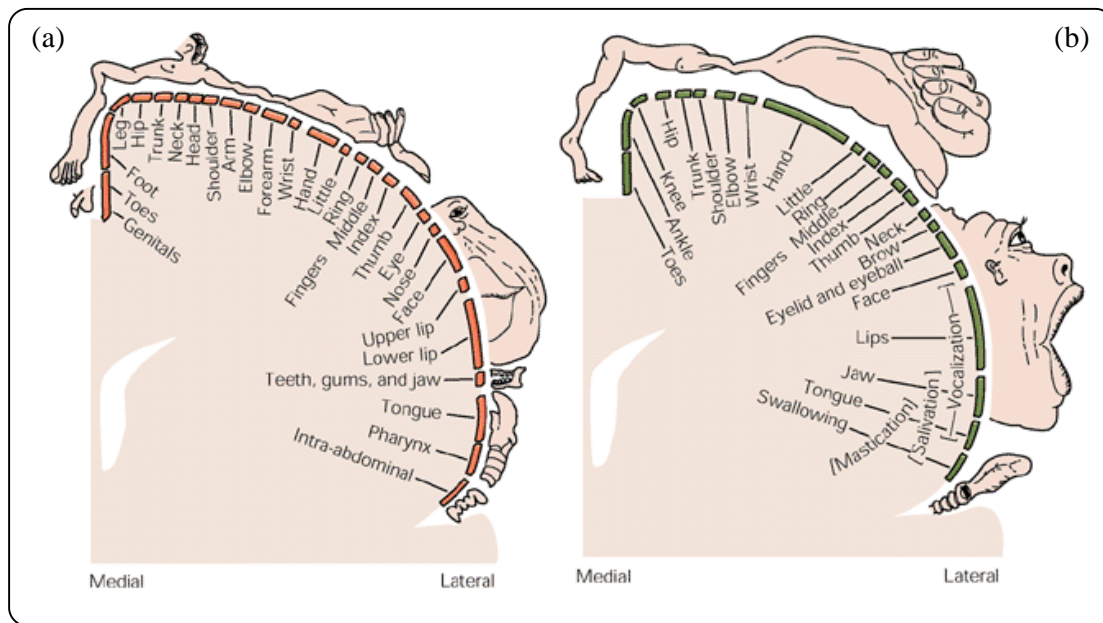


Figura 3.7 – Em (a) homúnculo sensorial e em (b) homúnculo motor. Fonte: KANDEL [6].

Alterações no fluxo sanguíneo cerebral em indivíduos, com maior concentração em determinadas áreas do córtex, podem identificar diferentes tipos de atividade, por exemplo, movimento ou imaginação do movimento (IM), e identificar o membro que realizou tal movimento ou a intenção de movê-lo. Essa identificação se deve a contralateralidade presente entre corpo e cérebro, por exemplo, ao se mover a mão direita o hemisfério que concentra maior fluxo sanguíneo é o contralateral, ou seja, o esquerdo, o mesmo ocorre ao mover a mão esquerda, o hemisfério direito possui maior ativação. Segundo LOTZE *et al.* (1999) [20], que realizou o estudo em imagens de ressonância magnética funcional (fMRI), durante o movimento da mão direita ocorre uma forte ativação contralateral do córtex motor primário e do córtex somatosensorial e menor ativação da área motora suplementar de ambos os hemisférios, com uma forte ativação no lobo cerebelar anterior ipsilateral (do mesmo lado). Comparando com o movimento, a ativação durante a IM é mais forte na área motora suplementar, menor na área motora primária, e particularmente baixa no córtex somatosensorial e lobo cerebelar anterior.

NEUPER e PFURTSCHELLER (1999) [21] registraram uma redução da energia (dessincronização) do ritmo μ , na região contralateral durante a IM. Segundo os autores, nenhuma alteração significativa foi registrada nas regiões medial e ipsilateral.

3.1.2 Atividades evocadas e induzidas

O registro de EEG sem a existência de estímulo é denominado como atividade espontânea ou basal. Quando o registro é realizado fazendo uso de algum tipo de estímulo podem ocorrer dois tipos de alterações na atividade elétrica gerada no córtex: uma sincronizada em fase e no tempo com o evento, denominada de potencial evocado (PE) ou potencial relacionado a evento (PRE), e outra denominada atividade induzida, que não está sincronizada em fase, mas pode estar sincronizada ou não no tempo. A atividade induzida sincronizada no tempo é conhecida por sincronização relacionada ao evento (ERS), enquanto que a atividade não sincronizada no tempo denomina-se dessincronização relacionada ao evento (ERD) [23].

NEUPER e PFURTSCHELLER (1999) [23] mostraram que a aplicação da ERD/ERS nas bandas de frequência dos ritmos μ e/ou β , durante o movimento (mãos, dedos, pés) indicou que a ERD está relacionada com a preparação e execução do movimento e a ERS com o término do movimento. Enquanto que a ERS representa um aumento de potência, a ERD representa uma diminuição [24]. Esta quantificação é obtida com o cálculo da razão da potência ou da variância de trechos dos sinais, filtrados nas bandas específicas, obtidos durante a atividade espontânea (referência) e o movimento [24]. O movimento de membros resulta em uma dessincronização na banda alta de μ (10-12 Hz) e na banda baixa de beta (16-20 Hz). Esta dessincronização se inicia cerca de 2s antes de efetuar um movimento sobre a região contralateral e se torna imediatamente simétrica bilateralmente antes da execução do movimento [24].

O cérebro possui plasticidade funcional [25], ele se adapta a mudanças repetitivas externas. Na área médio central do córtex surgem oscilações beta induzidas durante a IM, quando indivíduos são expostos a um grande número de treinamentos. O desenvolvimento destas oscilações, com amplitudes de alguns microvolts, indica que muitos neurônios exibem cooperação ou comportamento sincronizado. Conhecendo esta habilidade do cérebro, alguns pesquisadores mostram que o padrão de sinal a ser detectado pode ser melhorado por meio de sessões de treinamento por parte do usuário [26].

3.2 Interface Cérebro Máquina (ICM)

Interface cérebro máquina (ICM) é um sistema de comunicação em que mensagens ou comandos são enviados do cérebro de um indivíduo ao meio externo sem passar através do caminho normal da informação, que se inicia no cérebro, indo até nervos periféricos ou músculos. Uma ICM provê um método alternativo de interação com o meio, tendo como objetivo principal auxiliar pessoas que possuem dificuldade na motricidade, lesão nervosa, que não possuam atividade muscular decorrente de doença no neurônio motor, ou ainda danos na medula espinhal.

A ICM pode se dividir em duas classes: dependentes e independentes [31]. Uma ICM dependente não utiliza os caminhos normais (nervos periféricos e músculos) de saída do cérebro, mas a atividade nestes caminhos é necessária para gerar atividade cerebral que leve a isto. Ou seja, um indivíduo com alguma lesão nesses caminhos fica impossibilitado de utilizá-la. Um exemplo desse tipo de ICM utiliza os PEs, como por exemplo, o potencial evocado visual ou auditivo.

Uma ICM independente não utiliza os caminhos normais de saída do cérebro e não necessita que haja atividade nesses caminhos. Este tipo tem sido mais pesquisado do que o dependente, pois oferece uma ICM a pacientes com doenças degenerativas que possuem

parcial ou total paralisia dos músculos. Algumas ICMs independentes utilizam como padrão, o PRE P300 que é uma forma de onda positiva que surge no EEG cerca de 300ms após a ocorrência de um estímulo raro e relevante [28]. Outras ICMs utilizam a densidade espectral de potência (PSD) [22], ou ainda o ERD/ERS [21] e do potencial cortical lento (PCL) [30].

Ainda uma ICM pode ser classificada em relação ao tipo de registro utilizado, se invasivo (ICM direta) ou não invasivo (ICM indireta). Os sistemas não invasivos têm a grande vantagem de não expor o paciente aos riscos inerentes a uma cirurgia do cérebro. Entretanto, os sinais obtidos por estes sistemas possuem qualidade inferior, em relação aos invasivos, o que dificulta a sua utilização para o controle de uma prótese com um maior número de graus de liberdade de movimento (tipos de movimentos independentes), segundo LEBEDEV e NICOLELIS, 2006 [31].

As técnicas invasivas de ICM começaram a ser estudadas em macacos durante as décadas de 60 e 70 [32], e continuam até os dias atuais. A partir da década de 90, com o avanço das técnicas de registro [33] e das condições de implante dos eletrodos, as experiências evoluíram para utilização em humanos. Para a obtenção de resultados efetivos com uma ICM, seja esta invasiva ou não invasiva, é necessário um treinamento por parte do usuário. Este treinamento irá possibilitar ao usuário desenvolver a habilidade de controlar as atividades elétricas do cérebro, produzindo com maior eficiência os padrões desejados para a interação cérebro máquina. Essa habilidade se torna mais eficiente, por exemplo, com a utilização de um *feedback* visual [31]. Assim, a ICM identificará o padrão desejado de forma mais rápida e precisa, o que é extremamente importante, por exemplo, para o controle de uma prótese que utiliza a IM [26].

Uma terceira classificação está relacionada ao controle temporal durante a aquisição que pode ser realizada de forma síncrona ou assíncrona. Na síncrona o indivíduo

recebe um estímulo externo, geralmente visual ou auditivo, que indica o momento em que deve gerar o padrão cerebral que será analisado. Quando o indivíduo envia comandos cerebrais sem que haja algum estímulo, a aquisição é dita como assíncrona. Ainda em relação ao momento de execução do algoritmo de processamento e reconhecimento em uma ICM, ela pode ser classificada como *online* ou *off-line*. Uma ICM é dita *online* quando o processo de aquisição dos dados, o pré-processamento do sinal, a extração de características e a classificação são realizados durante o tempo em que o indivíduo está utilizando a ICM [34]. Se a aquisição dos dados é feita para análise posterior e os sinais capturados não são utilizados para gerar ações imediatas, a ICM é dita *off-line* [35].

3.2.1 Partes de uma ICM

Como qualquer comunicação ou sistema de controle, uma ICM possui entrada (EEG), saída, e componentes que traduzem a entrada na saída. Assim sua implementação deve possuir 3 módulos básicos, que podem ser visualizados na Figura 3.8, e são descritos a seguir:

- Aquisição dos sinais: esse módulo tem por função captar o sinal da atividade elétrica cerebral com uma relação sinal-ruído satisfatória para o processamento. Esse módulo é composto por eletrodos, e condicionamento do sinal (amplificador de biopotenciais, filtros, conversor analógico/digital, armazenamento e sistema de transmissão).
- Processamento: primeiramente é realizado um pré-processamento com filtragens e extração de características, com o objetivo de atenuar os artefatos, e evidenciar os padrões desejados. Em seguida é realizado um processamento para o reconhecimento dos padrões referentes a cada evento em questão.
- Saída: este módulo recebe o sinal processado e torna-os capazes de

acionar dispositivos eletrônicos, como o cursor do mouse em um computador, cadeira de rodas, próteses, entre outros.

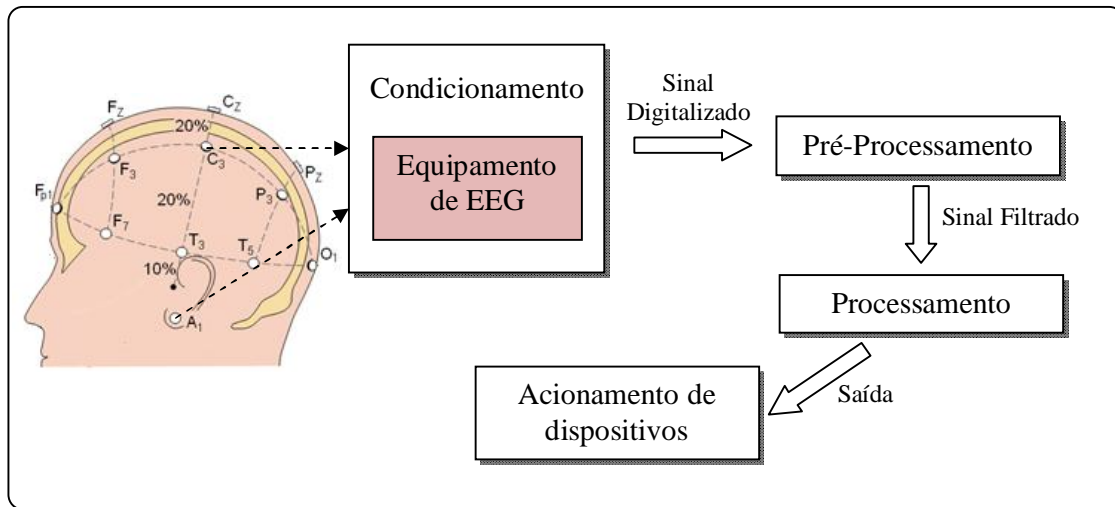


Figura 3.8 – Diagrama básico de uma ICM. Fonte: autor, e parte Modificado de: http://www.neurosoft.com.br/_suporte.php?p=100, acessado em: 04/06/2014.

3.2.2 Técnicas existentes

Nas últimas décadas, o número de grupos de pesquisa e de trabalhos envolvendo as ICMs tem aumentado significativamente, principalmente devido ao avanço tecnológico dos computadores, à maior integração interdisciplinar dos campos de pesquisa envolvidos e ao avanço na área de neurociência.

Diversos trabalhos relacionados ao reconhecimento do movimento e IM realizam a aquisição dos sinais no escalpo posicionando os eletrodos na região central C3 e C4, do sistema 10-20. Após a aquisição é realizado um pré-processamento do sinal para atenuação de artefatos, no intuito de aumentar a relação sinal ruído. A remoção desses artefatos pode ser realizada, por exemplo, por meio de técnicas de filtragem ou análise de componentes independentes – ICA [36], [37], ou técnicas de remoção automática de artefatos como em TIERRA-CRIOLLO (2001) [38]. Em seguida é realizada a extração de características desses sinais. Para esse tipo de extração várias propostas têm sido desenvolvidas para ICMs [39] e [40]. Dentre essas podem ser citadas a promediação de trechos dos sinais

(*grand average*) de EEG sincronizados com o evento [35] e [38], análise por componentes independentes [41], [42], análise de densidade espectral de potência (PSD) [22], transformada wavelet [43] e modelos autoregressivos [44].

Na etapa de classificação de padrões comumente são utilizadas em ICMs redes neurais artificiais [45], *neurofuzzy* [46], classificadores *bayesianos* [47], máquina de suporte vetorial [48], modelos lineares e não lineares [49], componentes principais [50], dentre outros.

Por exemplo, em PFURTSCHELLER *et al.* (1996) [23] é realizada a classificação com o uso de RNA. Neste averiguaram a correlação entre o movimento de membros e o comportamento de algumas componentes do sinal de EEG (ritmos mi e beta). Realizaram a aquisição dos sinais com os eletrodos posicionados em C3 e C4, com referência em Fz, do sistema 10-20. O sinal foi filtrado entre 0,5 Hz e 30 Hz e amostrado a uma taxa de 64 Hz. Na classificação dos sinais utilizaram uma rede neural DSLVQ (*Distinction Sensitive Learning Vector Quantization* – Quantização de Vetores por Aprendizagem Sensível a Distinção). Como entrada da rede, utilizaram frequências contidas entre 7 Hz e 24 Hz calculadas através da Transformada de Fourier. As redes neurais foram inicializadas com o algoritmo de agrupamento c-means. Após o treinamento, detectaram qual o lado do movimento da mão.

Em AHMADI e ERFANIAN (2009) [51] foi realizado um estudo com dois indivíduos, em que a aquisição foi realizada nos canais F3, F4, C3 e C4. O indivíduo foi instruído a se imaginar pegando um copo com a mão direita e depois fechar após ser preenchido por um líquido (primeiro classificador). Se o sistema perceber um erro o indivíduo deve corrigir imaginando a mão esquerda fazendo o mesmo movimento da direita (segundo classificador). O sinal foi filtrado por um filtro passa baixa com frequência de corte em 45Hz. Para a classificação foi utilizada uma rede recorrente

probabilística.

Em OZMEN e GUMUSEL (2013) [52] comparam 3 métodos de classificação. Foram realizados testes com 2 voluntários, que efetuaram movimento e IM da mão direita e esquerda, realizando desenhos de círculos continuamente. Na aquisição utilizaram o método bipolar em que CZ é utilizado como eletrodo de referência para C3 e C4. Foram selecionados os trechos a serem processados, eliminando os trechos com artefatos. Foi realizado o cálculo da PSD e os trechos relacionados às bandas alfa e beta foram separados. Em seguida foram calculados os máximos para essas bandas. Para a classificação utilizaram: Análise de discriminante linear, *support vector machine* e RNA. A RNA utilizada foi uma *multilayer feedforward* com o algoritmo *backpropagation* para o erro, possuindo 20 neurônios na camada escondida, e como função de ativação a função sigmoideal com range entre 0 e 1.

Em SOUZA *et al.* utilizaram a MSC [35] para extrair as características de 3 eventos: EEG espontâneo, movimento e IM. Essa extração foi realizada nas bandas delta, alfa e beta. Utilizaram duas formas de classificar, uma com Modelo escondido de Markov e MLP *perceptron multilayer*. Foram realizados testes em 3 indivíduos. A rede MLP utiliza como função de ativação a logsigmoide. Utiliza 6 padrões de entrada, e tem como *targets* 0, 0,5 e 1, respectivamente para espontâneo, movimento e IM. Estes entre outros trabalhos que utilizam algum tipo de RNA para a classificação dos eventos.

Este trabalho segue a mesma linha de atuação dos trabalhos mencionados, utilizando no reconhecimento RNAs supervisionadas, porém com uma nova abordagem, em que utiliza uma RNA com dinâmica de entrada, e ainda que se adapta a novos indivíduos e a cada vez que o sistema é reconectado.

CAPÍTULO 4

Fundamentação Teórica

Neste capítulo serão abordados alguns conceitos básicos de ferramentas de processamento de sinais e matemáticas utilizadas, para o melhor entendimento da metodologia utilizada neste trabalho.

4.1 Transformada Wavelet (TW)

Investigações utilizando a Transformada Wavelet (TW) com aplicações em ciências e nas engenharias começaram apenas no início dos anos 90. Desde então a transformada wavelet tem sido utilizada como uma ferramenta aplicada na investigação de diversos fenômenos físicos, que vão desde a análise de dados climáticos, índices financeiros, biopotenciais, sinais sísmicos até a filtragem e compressão de imagens e sinais [53].

Na análise feita pela TW são utilizadas pequenas funções ondulatórias conhecidas como wavelet principal ou wavelet mãe. Alguns exemplos de wavelet mãe podem ser visualizados na Figura 4.1.




Figura 4.1 – Exemplos de wavelet mãe: Haar, Daubechies, Symlet, Coiflet e DMeyer, respectivamente. Adquirido na Wavelet Toolbox do MATLAB®.

Um grande atrativo da TW é a possibilidade de se analisar sinais e imagens no domínio tempo-frequência, podendo-se detectar, por exemplo, as frequências que são mais

evidentes em um sinal com o passar do tempo, facilitando a identificação de determinados eventos que possuam como característica a variação na frequência. As wavelets são funções matemáticas que separam dados em suas diferentes componentes frequenciais e extraem cada componente com uma resolução adequada a sua escala. Assim a wavelet trata de forma mais apropriada sinais que contêm descontinuidades e variações bruscas, como é o caso do EMG e do EEG.

A transformada wavelet pode ser manipulada de duas maneiras diferentes: por meio do deslocamento no tempo, abrangendo diferentes locais do sinal e pela dilatação e compressão de suas escalas. O cálculo da transformada pode ser realizado em diferentes locais do sinal e em diferentes escalas da wavelet, o que gera um plano com as correlações entre a wavelet e o sinal original [53]. Se houver correlação entre a wavelet utilizada e o sinal analisado, em um local específico e em uma escala específica, o sinal transformado apresentará valores com amplitudes elevadas, do contrário, apresentará amplitudes reduzidas.

Esse plano de correlações pode ser gerado de uma forma suave e contínua através da transformada wavelet contínua (CWT) ou em passos discretos através da transformada wavelet discreta (DWT).

4.1.1 Transformada Wavelet Contínua (CWT)

A CWT foi desenvolvida como uma alternativa a Transformada de Fourier de Tempo Curto (STFT), em meados da década de 80. Apesar de possuírem certa semelhança, a CWT não usa a multiplicação do sinal por uma janela como a STFT, e sim por uma função wavelet. Devido a essa característica, de não fixar uma janela, esta resolve o problema da resolução no plano tempo-frequência, pois com o uso de wavelet pode-se realizar uma Análise Multiresolucional (AMR), ou seja, analisar as diferentes frequências

do sinal com diferentes resoluções [54]. Tem-se uma alta resolução no domínio do tempo e baixa no domínio da frequência para frequências mais altas do sinal. E uma resolução frequencial alta e temporal baixa para frequências mais baixas do sinal. A CWT é definida pela Equação (4-1), [54]:

$$CWT(a,b) := \int_{-\infty}^{+\infty} f(t)\psi_{a,b}^*(t)dt, \quad (4-1)$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}}\psi\left(\frac{t-b}{a}\right), \quad (4-2)$$

onde CWT são os coeficientes da wavelet determinados por um produto interno [55] entre uma função $f(t)$ e uma wavelet principal, denominada wavelet-mãe Ψ conjugada (Ψ^*). Observando a Equação (4-2), essa wavelet básica $\Psi_{a,b}$, denominada wavelet-filha, depende de dois parâmetros, o a que está relacionado às escalas, mas que pode exprimir numa análise espectral uma frequência relativa [55], e o b é referente à translação (deslocamento), dando informação de tempo no domínio da transformada [55]. Se $a < 1$ tem-se uma versão comprimida da wavelet-mãe e se $a > 1$ tem-se uma versão dilatada da wavelet-mãe.

Para a análise das frequências predominantes no sinal, com o passar do tempo, utiliza-se a CWT transformando as escalas em pseudofrequências. Neste trabalho foram realizadas análises com a CWT para fins de teste. Obtiveram-se os coeficientes da wavelet, utilizando como wavelet-mãe a *Daubechies 4* [56]. Existe um grande número de funções que podem ser escolhidas como wavelet-mãe (Figura 4.1), porém a Wavelet de Daubechies (dbN) foi utilizada neste trabalho devido a sua regularidade, por se tratar de uma “família” de wavelets ortogonais de suporte compacto e por apresentar boa correlação com os potenciais de EEG [57]. Essa wavelet foi desenvolvida por Ingrid Daubechies no início dos anos 80 e é baseada em filtros ortogonais cujo número de coeficientes é determinado pela

ordem da wavelet (N), ou seja, de acordo com a ordem N da wavelet, são produzidos $2N$ coeficientes dos filtros. Sendo que essa wavelet se torna mais regular com o aumento linear de N . Porém através de diversos experimentos com sinais de EEG escolheu-se N igual a 4, $db4$, como melhor resultado.

O gráfico de uma CWT traz a informação de a e b , mas ainda torna-se necessária a informação de frequência. Para a obtenção das pseudofrequências (F_a) é realizada uma transformação do eixo a , vide Equação (4-3), [58]:

$$F_a = \frac{F_C}{a\Delta}, \quad \text{com} \quad \Delta = \frac{1}{250}, \quad (4-3)$$

onde F_C é a frequência central da wavelet principal e Δ o período de amostragem do sinal (250Hz foi a taxa de amostragem utilizada nesse trabalho). Essa transformação utiliza o cálculo da F_C considerando uma aproximação da função wavelet mãe por sua oscilação máxima (Figura 4.2), que é normalizada pela escala a multiplicada pelo período de amostragem do sinal (Δ).

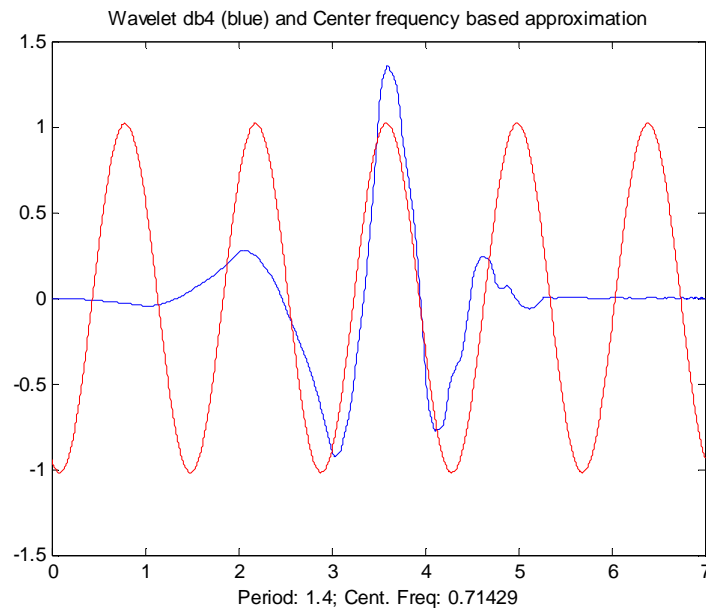


Figura 4.2 – Gráfico da wavelet $db4$ e uma senóide, mostrando a aproximação por sua oscilação máxima. Adquirido na Wavelet Toolbox do MATLAB®.

Após a obtenção dos coeficientes da wavelet (*CWT*) a densidade espectral de energia (*S*) é calculada por meio da Equação (4-4), trazendo informação das frequências mais evidentes ao longo do tempo por meio de um gráfico em três dimensões.

$$S = CWT^2 \quad (4-4)$$

Como exemplo foi utilizado um registro de EEG, Figura 4.3, adquirido na região occipital, canal O1 segundo o sistema 10-20, em que o voluntário estava inicialmente com os olhos abertos e realizou uma sequência de fechar e abrir os olhos por três vezes. Nesse gráfico podem-se identificar facilmente os dois eventos, devido à diferença de amplitude e frequência, com os olhos fechados (circulado em vermelho) tem-se o aumento da amplitude e diminuição da frequência (ondas alfa), e com os olhos abertos menor amplitude e maior frequência (ondas beta).




Figura 4.3 – Sinal de EEG adquirido em O1, onde podem ser observadas três regiões de maior amplitude referentes ao evento olhos fechados, circulado em vermelho, e quatro de menor amplitude referente a olhos abertos. Fonte: autor.

Antes de utilizar a *CWT*, foi realizada a separação dos ritmos do sinal, por exemplo, por meio de um filtro do tipo Resposta ao Impulso Finita (*FIR*) passa-faixa digital [59], de acordo com a faixa de frequência de cada banda de EEG. As filtragens

foram implementadas no domínio do tempo por meio da convolução do sinal com os respectivos filtros de cada banda. Na Figura 4.4 podem ser observados os ritmos separados desse mesmo sinal, verificando a maior contribuição, para esses eventos, dos ritmos alfa e beta, com maior ênfase para o alfa na situação em que o indivíduo está com os olhos fechados, e na banda beta quando o indivíduo está com os olhos abertos.

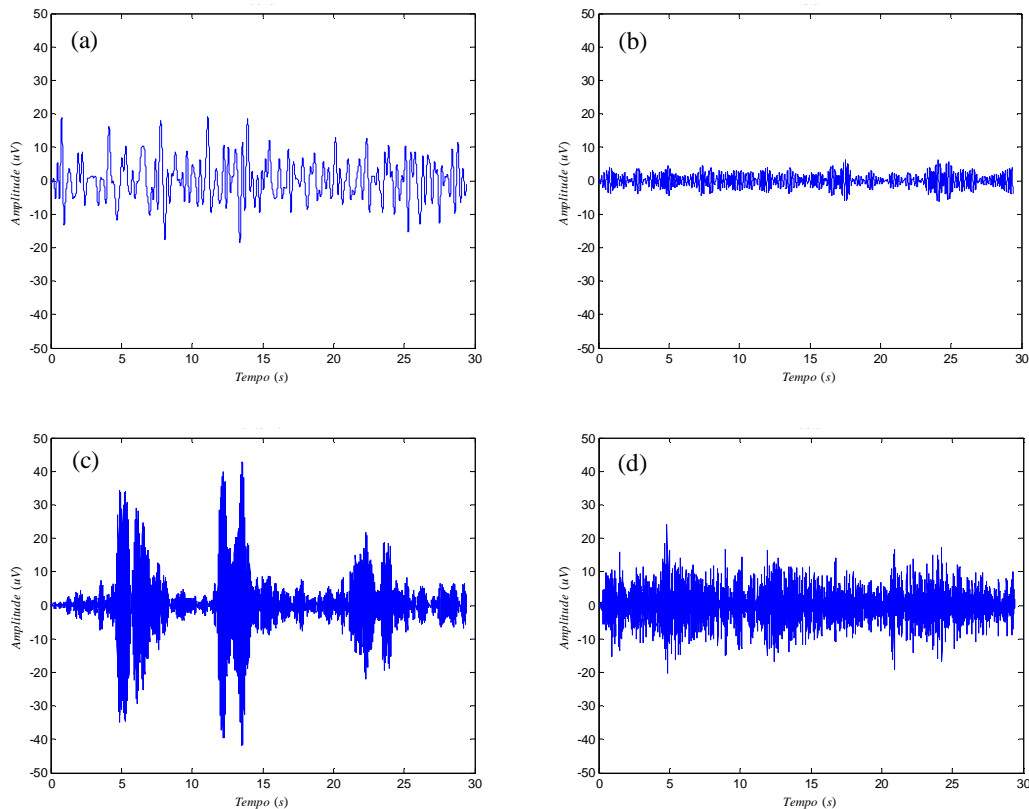


Figura 4.4 – Faixas de frequência do sinal de EEG capturado na região occipital, (a) delta, (b) teta, (c) alfa e (d) beta. Fonte: autor.

Após a separação das bandas do sinal de EEG original, foram gerados gráficos de densidade espectral de energia, baseados nos coeficientes da wavelet adquiridos pela CWT. O eixo correspondente a escala a foi transformado em pseudofrequências e o eixo correspondente a translação b é referente ao tempo de duração do sinal. Foram gerados gráficos em três dimensões (3D), com o terceiro eixo referente à densidade espectral de energia. Assim, a CWT transmite a informação de frequências mais evidentes com o passar

do tempo. Os gráficos das CWTs das bandas que indicam melhor a diferença entre os eventos do sinal referente ao canal O1 podem ser observados na Figura 4.5.

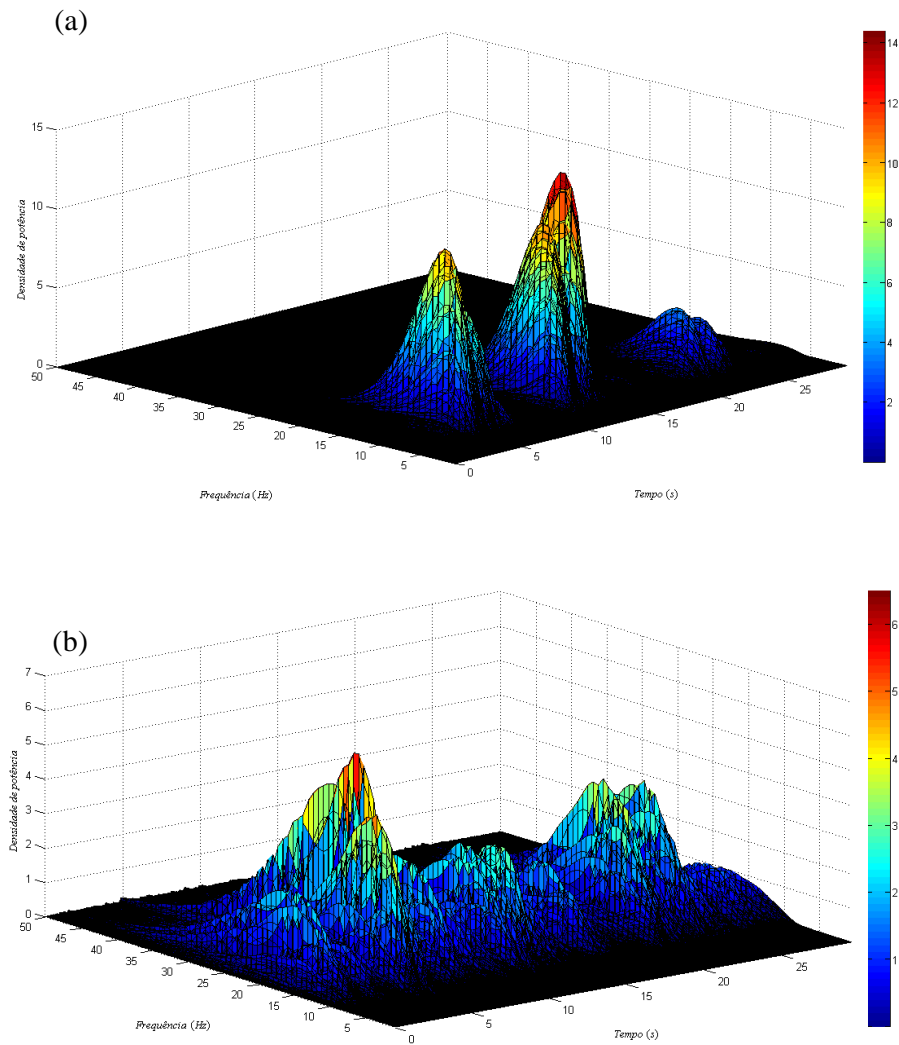


Figura 4.5 – CWT das bandas (a) alfa e (b) beta, do EEG capturado no canal O1. Fonte: autor.

Observam-se, nesses gráficos, as frequências mais evidentes com o passar do tempo, nesse caso confirmando a hipótese do aparecimento do ritmo alfa ao fechar os olhos. Outra forma de representar a análise do sinal através da CWT, é através do escalograma, na Figura 4.6 pode-se observar o mesmo sinal da banda alfa com 32 escalas.




Figura 4.6 – Escalograma da banda alfa. Fonte: autor.

Na prática a CWT não é muito utilizada devido a quantidade de translações e escalonamentos que são necessários realizar, demandando muito tempo e recursos computacionais, e ainda gerando muita redundância [53].

4.1.2 Transformada Wavelet Discreta (DWT)

No intuito de proporcionar uma descrição mais eficiente que a CWT, foi introduzida a Transformada Wavelet Discreta (DWT) [53]. A DWT não é transladada e escalonada continuamente como a CWT, mas sim em intervalos discretos, em que ocorre apenas a discretização no domínio dos parâmetros (variáveis de escala e translação). Essa discretização pode ser realizado com uma pequena modificação na definição matemática da wavelet contínua, conforme a Equação (4-5) [53]:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{|a_0^m|}} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right), \quad (4-5)$$

onde m e n são inteiros, $a_0 > 1$ é um parâmetro de dilatação fixo, b_0 é o fator de translação fixo. Na maior parte das aplicações para a DWT emprega-se a sequência diádica (que segue o critério de admissibilidade) [53], ou seja, $a_0 = 2$ para que se tenha uma amostragem da frequência dita como diádica, e $b_0 = 1$ para que a amostragem temporal também seja

diádica. Assim as escalas variam em potência de 2, caracterizando assim a AMR.

Na análise multirresolução wavelet os sinais discretos são decompostos utilizando bancos de filtros tipo FIR, conforme a Figura 4.7. Este é o princípio utilizado para o cálculo da DWT e é conhecido como um tipo de codificação de sub-banda. O modo utilizado na análise de wavelets discretas consiste em projetar filtros passa-alta (HPF) e passa-baixa (LPF), de modo que particione o espectro ao meio. Os componentes resultantes da filtragem passa-alta, contém as altas frequências, que traz informações de detalhes. Os componentes resultantes do filtro LPF fornecem apenas uma versão global dessas frequências, denominados aproximações. Então, esse trecho do espectro passa por outro par de filtros LPF e HPF. Da mesma forma, o filtro HPF fornecerá detalhes e o LPF a aproximação. E a aproximação passará novamente por um par de filtros até que se considere satisfatório o número de bandas criadas [55].

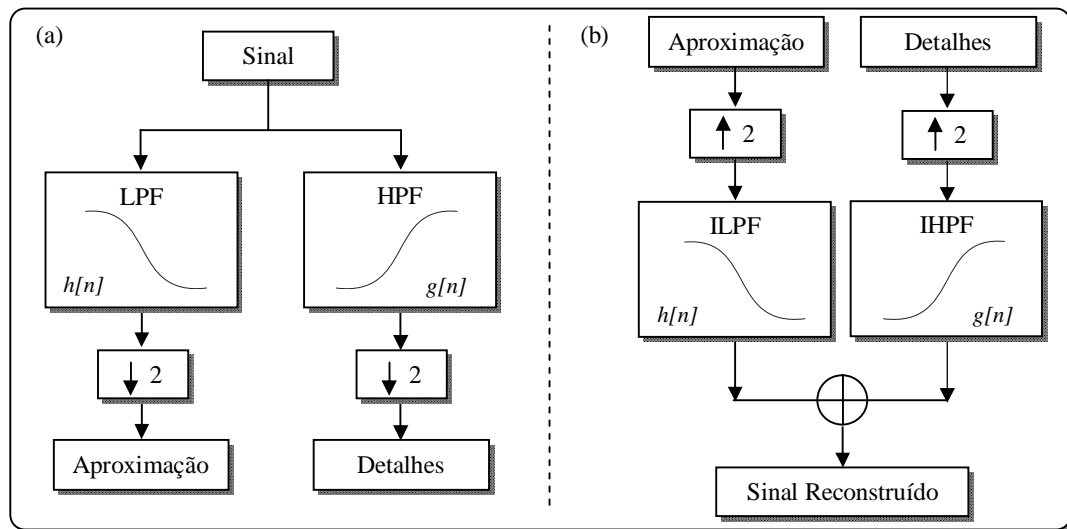


Figura 4.7 – (a) Processo de decomposição do sinal e (b) processo de reconstrução. Fonte: autor.

Na Figura 4.8 pode-se observar a decomposição de um sinal $x[n]$ em suas n -resoluções por um conjunto de filtros, $h[n]$ que extraem as características médias do sinal (Aproximações), sendo somados a um conjunto de filtros $g[n]$ que extraem as

características de alta frequência (Detalhes).

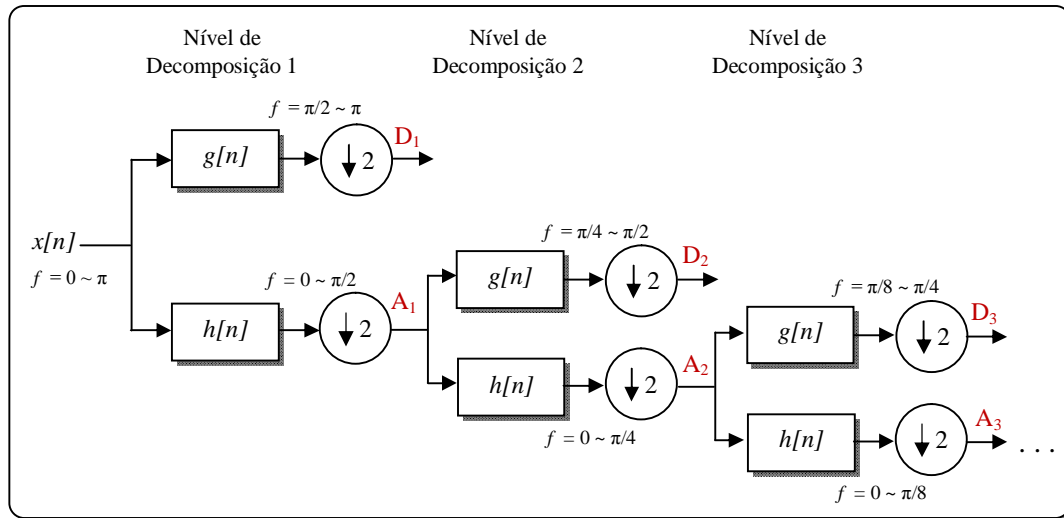


Figura 4.8 – Decomposição do sinal $x[n]$, passando pelos filtros $g[n]$ e $h[n]$ e em seguida sendo subamostrado de 2, gerando os detalhes ($D_1, D_2, D_3, \dots, D_n$) e as aproximações ($A_1, A_2, A_3, \dots, A_n$). Fonte: Modificada de OLIVEIRA [53].

Neste trabalho a CWT foi utilizada para fins de teste. A adotada neste trabalho foi a análise multiresolucional (AMR) pela decomposição com a DWT.

4.2 Densidade Espectral de Potência

O objetivo da estimação espectral é descrever a distribuição, em frequência, da potência contida em um sinal, com base em um conjunto finito de dados. A estimativa dos espectros de potência é útil para uma variedade de aplicações, incluindo a detecção de sinais imersos em uma grande quantidade de ruído.

A densidade espectral de potência (PSD) de um processo aleatório estacionário $x[n]$ é dada pela Transformada de Fourier de Tempo Discreto (DFT) [59] de sua sequência de autocorrelação. Em termos de frequência normalizada, isto é dado pela Equação (4-6) [58]:

$$P_{xx}(\omega) = \frac{1}{2\pi} \sum_{m=-\infty}^{\infty} R_{xx}(m) e^{-jom}, \quad (4-6)$$

onde P_{xx} é a PSD e R_{xx} é a sequência de autocorrelação de $x[n]$. A PSD pode ser descrita em função da frequência f em hertz usando a relação $\omega = 2\pi f/fs$, onde fs é a frequência de amostragem, vide Equação (4-7) [58].

$$P_{xx}(f) = \frac{1}{fs} \sum_{m=-\infty}^{\infty} R_{xx}(m) e^{-j2\pi f m / fs}. \quad (4-7)$$

E a função de autocorrelação de $x[n]$ é dada pela Equação (4-8):

$$R_{xx}(l) = \sum_{n=-\infty}^{\infty} x(n)x(n-l), \quad l = \pm 1, \pm 2, \dots \quad (4-8)$$

As unidades da PSD são de potência por unidade de frequência, no caso de $P_{xx}(f)$ as unidades são watts/ hertz.

Um estimador da PSD é proposto por WELCH [60]. O método consiste em dividir os dados de série temporal em segmentos (possivelmente sobrepostos), computar o periodograma modificado de cada segmento, e em seguida realizar a média das estimativas da PSD. O resultado é a estimativa da PSD de WELCH [58].

4.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são sistemas que funcionam de forma paralela, compostos por unidades de processamento simples, denominadas neurônios artificiais. Essas unidades são inspiradas nos neurônios biológicos que executam procedimentos geralmente não lineares, e propagam o sinal para os próximos neurônios. Essas unidades são dispostas em camadas que são interligadas por um grande número de conexões, que estão associadas aos pesos sinápticos, os quais armazenam o conhecimento adquirido pelo modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

As redes neurais se dividem, quanto ao aprendizado, em dois grandes grupos, as redes não supervisionadas e as redes supervisionadas. As RNAs supervisionadas, além do conjunto de treinamento, necessitam de um “supervisor” para verificar a efetividade da rede para esse conjunto. O “supervisor” identifica o erro para cada padrão e através de algoritmos de treinamento procura minimizá-lo, por meio da mudança de pesos sinápticos da rede. Neste trabalho foram utilizadas apenas as RNAs do tipo supervisionadas, devido a necessidade de treinar as redes de acordo com padrões previamente definidos, que representam alguma informação útil no processo de classificação do EEG.

Quando se utiliza RNAs do tipo supervisionada, o procedimento usual na solução de problemas passa inicialmente por um processo de aprendizagem, em que um conjunto de exemplos é apresentado para a rede, a qual extrai as características necessárias para representar a informação fornecida. Elas possuem a habilidade de “aprender” e generalizar, produzindo saídas adequadas para entradas não presentes na etapa do treinamento, o que possibilita a resolução de problemas de ordem complexa. Entretanto, é importante compreender que atualmente as RNAs estão muito distantes das redes neurais naturais, devido ao alto grau de paralelismo existente na estrutura cerebral humana.

Nos itens a seguir serão descritos os principais elementos que compõem a estrutura de uma RNA supervisionada, entre elas o neurônio artificial, funções de ativação e o tipo de algoritmo utilizado para o treinamento.

4.3.1 Neurônios Artificiais

O modelo do neurônio artificial proposto por McCulloch e Pitts é uma simplificação do neurônio biológico. Sua descrição matemática resultou em um modelo com n terminais de entrada (dendritos) que recebem os valores x_1, x_2, \dots, x_n (que

representam as ativações dos neurônios anteriores) e apenas um terminal de saída representando o axônio [61]. Na Figura 4.9 pode ser observado o modelo do neurônio artificial.

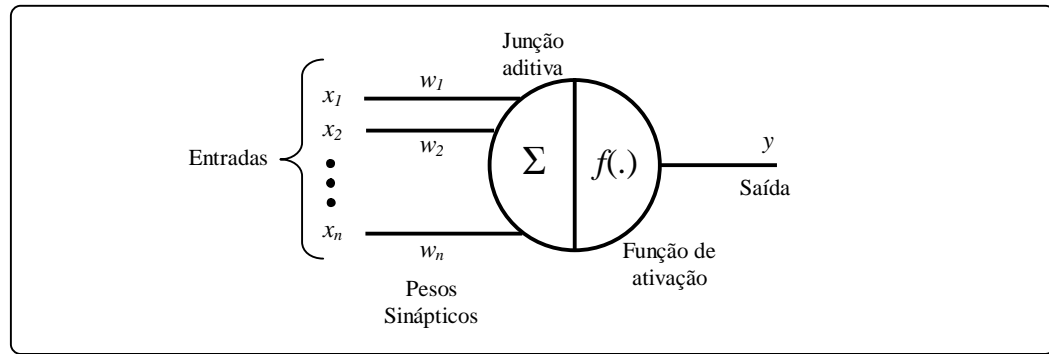


Figura 4.9 – Modelo de neurônio artificial. Fonte: modificada de BRAGA [61].

Para representar o comportamento das sinapses (ponto de contato entre a terminação axônica de um neurônio com os dendritos de outro neurônio) os terminais de entrada do neurônio possuem pesos associados (w_1, w_2, \dots, w_n), cujos valores podem ser positivos ou negativos, dependendo das sinapses serem excitatórias ou inibitórias. O efeito de uma determinada sinapse i para cada neurônio pós-sináptico é dado por $x_i w_i$, representando a entrada para a função de ativação do neurônio. Os pesos determinam o grau em que o neurônio deve disparar, isto é, o valor de entrada é utilizado no processo de ativação.

Um neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação. Esse comportamento é representado no neurônio artificial por um mecanismo que realiza a soma dos n valores $x_i w_i$ recebidos em cada entrada do neurônio (soma ponderada) e comparando a soma obtida com o limiar de ativação deste neurônio. Esse cálculo é chamado de *net* do neurônio e pode ser representado pela Equação (4-9). A função de ativação é a responsável pela determinação do tipo de limiar utilizado.

$$net = \sum_{i=0}^n x_i w_i. \quad (4-9)$$

4.3.2 Função de Ativação

A função de ativação é responsável por gerar a saída y do neurônio a partir de valores dos vetores de peso e de entradas. Os três tipos básicos de função de ativação mais utilizadas são [63]:

- A função linear descrita como na Equação (4-10):

$$y(x) = ax + b, \quad (4-10)$$

onde a e b são valores escalares.

- A função logística possui gráfico em formato de S. É um exemplo de função sigmóide e é definida pela Equação (4-11):

$$y(x) = \frac{1}{1 + e^{-ax}}, \quad (4-11)$$

onde a é o parâmetro da inclinação da função sigmóide. Essa função pode assumir valores entre 0 e 1.

- A função tangente hiperbólica é descrita como na Equação (4-12):

$$y(x) = \frac{e^{ax} - e^{-ax}}{e^{ax} + e^{-ax}}, \quad (4-12)$$

onde a é um escalar positivo. Essa função possui gráfico em formato de S e assume valores entre -1 e 1.

O valor S de saída do neurônio, levando em consideração as entradas, pesos e função y de ativação é calculado conforme a Equação (4-13):

$$S = y(net). \quad (4-13)$$

4.3.3 Número de Camadas de uma RNA

Um modelo de RNA simples utiliza apenas uma única camada de neurônios. Neste caso têm-se apenas as entradas que se conectam com os neurônios da camada de saída. A grande limitação desta classe de rede é a impossibilidade de se resolver problemas classificados como linearmente não separáveis [64].

Um segundo tipo de RNAs são as redes que utilizam mais de uma camada. Essas redes se caracterizam pela presença de uma ou mais camadas intermediárias de neurônios. A função dos neurônios das camadas intermediárias, é extrair informações dos neurônios da camada de entrada, processar a informação e fornecê-las como entrada para os neurônios da camada de saída. Esse tipo de rede está apta a resolver problemas de ordem mais complexa, isto é, problemas não separáveis linearmente [61].

4.3.4 RNA Feedforward e Algoritmo Backpropagation

Em uma rede *feedforward* (propagação para frente), cada camada se conecta à próxima camada, não existindo realimentações entre as entradas e saídas das camadas. Todas as conexões portanto, tem a mesma direção, partindo da camada de entrada rumo a camada de saída. Um exemplo da estrutura de uma rede com duas camadas de neurônios pode ser visualizado na Figura 4.10. Esta rede apresenta dois padrões de entrada, três neurônios na camada intermediária ou escondida, e um neurônio na camada de saída.




Figura 4.10 – Estrutura simples de uma rede feedforward. Fonte: autor.

Uma rede *feedforward* ou *perceptron* multi-camadas, como também é conhecida, pode utilizar o algoritmo de treinamento supervisionado *backpropagation* [61]. O treinamento supervisionado é realizado por retropropagação do erro, que consiste na apresentação de um padrão de treinamento para a rede e o seu respectivo valor de saída, que é comparado com um valor desejado de saída. É então calculado o erro ε por meio da Equação (4-14).

$$\varepsilon(n) = \frac{1}{2N} \sum_{n=1}^N (pD(n) - y(n))^2, \quad (4-14)$$

onde $pD(n)$ são os valores de saída desejados para cada padrão de entrada, $y(n)$ é o valor da de saída da rede e N o total de padrões apresentados à rede.

No treinamento da RNA, após o cálculo do erro, o algoritmo atualiza os pesos em todas as camadas, partindo da saída até a entrada e é realizado o cálculo dos erros. No treinamento essa atualização é realizada época a época. Todos os padrões de treinamento são apresentados à rede e os seus respectivos erros são acumulados e o erro médio quadrático da época é então avaliado. O erro médio de cada época é retropropagado pela rede, e os pesos das conexões sinápticas são atualizados uma única vez por época. O algoritmo de treinamento tem como base o gradiente descendente, fazendo com que o erro diminua, o que indica a convergência do treinamento da rede [63].

Na fase do aprendizado é utilizado um coeficiente denominado Coeficiente de Aprendizagem (η). Quanto menor é o η , menores são as variações de pesos e mais suave é a trajetória da variação dos pesos da RNA, no entanto, a aprendizagem é lenta. Quanto maior é o η , mais rápida é a aprendizagem, porém as variações dos pesos são grandes, podendo inferir em erro na identificação do padrão.

Para se alcançar um modelo com baixo erro de reconhecimento dos padrões deve-se

evitar que a RNA ultrapasse o momento ideal de parada do seu respectivo treinamento e acabe perdendo o poder de generalização [62]. O poder de generalização está relacionado a rede também reconhecer padrões próximos aos treinados, quando ocorre a perda da generalização a rede passa a reconhecer apenas padrões iguais ao aprendido.

4.3.5 RNA Dinâmica

Redes Neurais Dinâmicas são capazes de modelar sistemas dinâmicos. A dinâmica de uma rede pode ser obtida utilizando-se neurônios dinâmicos ou por meio de uma dinâmica externa, como um retardo na entrada ou uma realimentação [65].

Neste trabalho são utilizadas as redes com retardo na entrada. As características dinâmicas deste tipo de rede estão nos elementos de entrada da RNA. Por exemplo, uma malha de atraso na entrada faz com que todos os pontos do registro passem por cada um dos neurônios de entrada da rede, sendo que, o primeiro ponto é eliminado após ser computado o seu valor por todas as entradas da RNA. Este procedimento se repete até o final do registro ou do padrão a ser analisado. A principal característica desta RNA é a de verificar a maneira como os pontos variam no decorrer do tempo e não a disposição dos pontos no plano, como é o caso da Rede Neural Artificial Estática (RNAE), possibilitando desta forma a identificação das variações dos sinais no tempo, como é o caso dos sinais bioelétricos [66].

CAPÍTULO 5

Reconhecimento do Movimento e IM

Neste capítulo são apresentadas as técnicas utilizadas neste trabalho desde a aquisição dos sinais de EEG, pré-processamento e processamento utilizando RNAs para o reconhecimento de movimento e IM das mãos pela flexão do punho. Um esquema geral de toda metodologia pode ser visualizado na Figura 5.1, e será detalhada no decorrer deste capítulo.

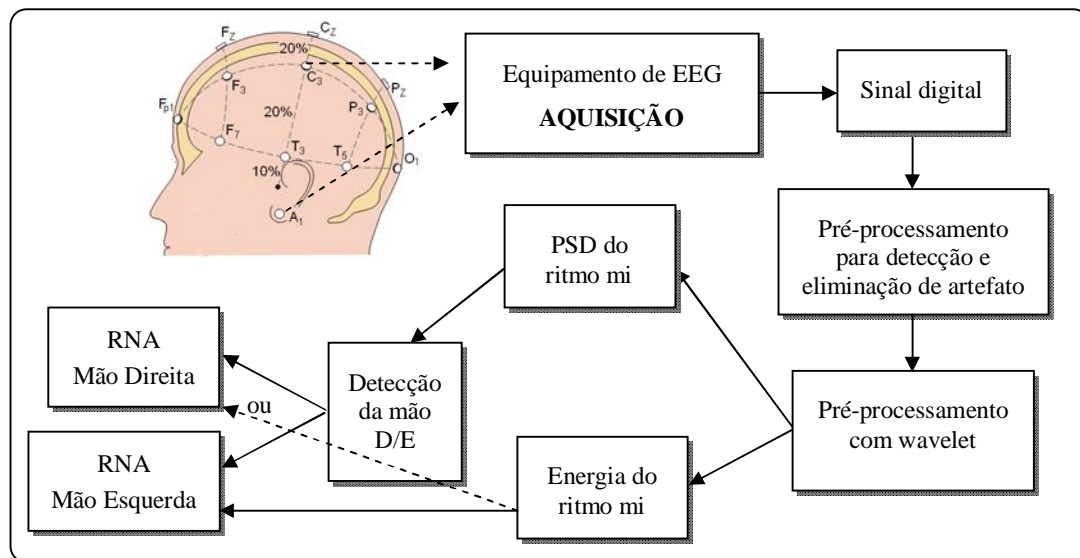


Figura 5.1 – Esquema geral da metodologia utilizada. Fonte: autor e parte Modificado de: http://www.neurosoft.com.br/_suporte.php?p=100, acessado em: 04/06/2014

5.1 Aquisição do Sinal de EEG

A aquisição do sinal de EEG foi realizada por meio do equipamento VERTEX SC823 da Meditron, composto pelo *hardware* EEG COMPACT 723 e *software* SOMNIUM. O *hardware* é composto de 23 canais, sendo 2 de referência, possui amplificadores de instrumentação, filtro passa-altas analógico de 1ª ordem com frequência de corte em 0,1Hz e filtro passa-baixas de 2ª ordem com frequência de corte em 100Hz. A digitalização dos sinais é realizada com uma taxa de amostragem de 250Hz, por canal. O sinal digitalizado é enviado para o computador pela porta USB e é visualizado no software SOMNIUM, que exporta o arquivo com os sinais dos respectivos canais em extensão *edf*. Em seguida esse arquivo é convertido em arquivo texto pelo *software* EDFbrowser® [67], para que possa ser analisado e processado.

A captura dos sinais foi realizada em 10 indivíduos saudáveis do sexo masculino e destros, na faixa etária de 18 a 40 anos, que não possuíam qualquer problema neurológico aparente e que não faziam uso de medicação que pudesse provocar alterações no sinal de EEG. Os registros foram efetuados no Laboratório de Pesquisa de Engenharia Biomédica da Universidade Federal de Pernambuco. A pesquisa obteve aprovação pelo Comitê de Ética e Pesquisa em Seres Humanos conforme a resolução Nº 466/12 do Conselho Nacional de Saúde (CAAE - 01971812.1.0000.5208). Os voluntários foram informados da natureza da proposta do estudo, bem como, leram e assinaram o termo de consentimento livre e esclarecido, que pode ser visualizado no Apêndice1.

Inicialmente os voluntários foram submetidos a uma anamnese onde foi realizado um questionamento sobre suas condições clínicas, e histórico familiar, relacionados a problemas ou desconfortos mentais, por meio dos quais foi possível a verificação dos critérios de exclusão previstos no trabalho, vide Apêndice2. Em seguida o voluntário foi preparado para a aquisição do sinal, em uma cadeira fixa, de braço e confortável, onde foi

realizada a colocação dos eletrodos (prata banhado a ouro) na região de interesse.

O voluntário foi preparado conforme a Figura 5.2, com a colocação de 10 eletrodos (C3, CZ, C4, F3, F4, P3, P4, O1, OZ, O2) instalados no couro cabeludo de acordo com o Sistema Internacional 10-20 [16] (Figura 5.3), com mais dois eletrodos de referência, auriculares, e um eletrodo de terra, na região peri-clavicular direita (para diminuir ruído de movimento ocular, como piscadas por exemplo). Os eletrodos C3, CZ, C4, F3 e F4 foram utilizados para a detecção do movimento e imaginação do movimento (IM). Os eletrodos O1, OZ, O2, P3 e P4 são utilizados no momento da aquisição para verificar a existência de possíveis potenciais evocados visuais, que pode ser propagado da região occipital para a região de interesse.




Figura 5.2 – *Voluntário preparado para aquisição de EEG* Fonte: autor.

Antes da colocação dos eletrodos foram realizadas as medidas das dimensões da cabeça do indivíduo e seguindo o Sistema Internacional 10-20 os pontos referentes aos eletrodos foram marcados com lápis dermográfico. Para melhorar a condutividade, para detecção da atividade cerebral desejada no estudo, foi utilizada pasta condutora Carbofix, misturada com água, e gaze, para a fixação dos eletrodos. Os eletrodos foram fixados de

forma a se obter uma impedância menor que $5k\Omega$. Esta preparação ocorreu em uma sala climatizada e de baixa iluminação, que tem por finalidade minimizar os ruídos externos no processo de aquisição, como por exemplo, os artefatos de sudorese, comumente encontrados neste registro. O protocolo desse registro de EEG obedece rigorosamente aos critérios de segurança nacionais e internacionais [68].




Figura 5.3 – *Posicionamento dos eletrodos de EEG. Fonte: autor.*

Com o objetivo de auxiliar o processo de aquisição, principalmente devido à complexidade na identificação dos eventos em um sinal de EEG, foi desenvolvida uma interface para controle e marcação, desenvolvida em ambiente Borland Delphi® [70]. Essa interface além de realizar estímulos visuais interage com um equipamento de *hardware* marcador (Figura 5.4), também desenvolvido neste trabalho, que por sua vez é ligado a dois canais (modo bipolar) do equipamento de aquisição com a finalidade de indicar a posição onde ocorrem os eventos no registro. Este equipamento é composto por uma placa de controle, com o microcontrolador pic16f877a, e um divisor de tensão para diminuição da amplitude do sinal de saída do pic, para a ordem de μV (micro volts). A marcação originada na interface é enviada ao marcador, via cabo conversor USB/Serial, que gera pulsos que são enviados ao equipamento de EEG.




Figura 5.4 – Equipamento marcador desenvolvido (a esquerda) interligado ao equipamento de EEG (a direita). Fonte: autor.

Um exemplo de marcação pode ser observado na Figura 5.5, onde se tem um sinal de EEG adquirido na região pré-motora, canal F3, e um sinal proveniente do marcador indicando o momento que iniciou e finalizou a realização do movimento da mão direita.




Figura 5.5 – (a) Sinal gerado pelo marcador com região circulada em vermelho referente ao movimento, e (b) sinal de EEG capturado no ponto F3 durante um movimento. Fonte: autor.

A interface indica quando o indivíduo deve efetuar um movimento ou imaginar o movimento, tornando a aquisição sincronizada. Essa indicação é feita por meio de telas projetadas: todas as projeções são realizadas em uma tela branca, inicialmente é projetada uma cruz no meio da tela, que permanece assim por 10s (EEG espontâneo ou basal); em

seguida aparece a letra M durante 1s, que ao desaparecer indica que o movimento deve ser efetuado, em uma janela temporal de até 3s; na sequência é apresentada novamente a primeira tela que permanece por 10s (EEG espontâneo ou basal); em seguida aparece a letra I durante 1s que ao desaparecer indica que a IM deve ser efetuada, em uma janela temporal de até 3s, retornando para o início do ciclo. Esse procedimento é repetido totalizando 10 movimentos e 10 imaginações do movimento. Sempre que ocorre uma mudança de tela a interface envia um pulso ao equipamento marcador, que entrega um trem de pulso ao equipamento de EEG. Esse procedimento do protocolo, bem como as telas projetadas pode ser visualizado na Figura 5.6.

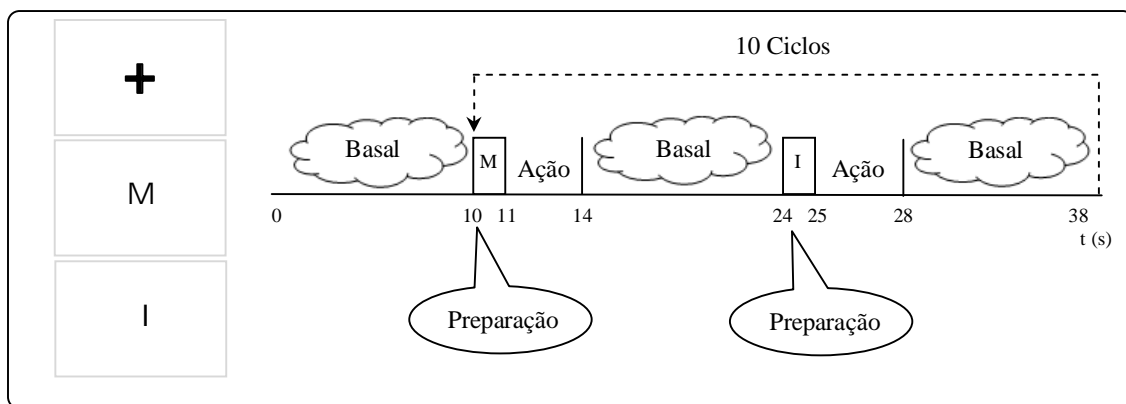


Figura 5.6 – A esquerda observa-se as telas geradas para a sincronização com os eventos. E a direita o procedimento do protocolo de aquisição de cada sessão. Fonte: autor.

O EEG foi registrado em dois dias para cada voluntário. Cada sessão foi realizada com o protocolo, conforme Figura 5.6, e possui duração total de 4,83min. Em cada dia foram realizadas duas sessões com a mão direita e duas com a esquerda.

Para o procedimento o voluntário foi instruído a deixar a mão relaxada com a palma para cima nos instantes relacionados ao EEG espontâneo. No instante do movimento efetuar apenas um movimento da mão por meio da flexão do punho, como se segurasse um objeto e trouxesse para si, e retornar a posição inicial, conforme Figura 5.7.




Figura 5.7 – Protocolo do movimento efetuado por cada voluntário. Fonte: modificada de: http://cinesiologiaemfisioerapia.blogspot.com.br/2011_08_01_archive.html, acessado em 15/06/2014.

Durante a IM o voluntário deve realizar a imaginação do mesmo movimento efetuado. Para a IM o voluntário foi instruído quanto à forma de realizar a imaginação: em primeira pessoa, utilizando a memória visual e/ou cinestésica (sentir o movimento) [68]. Um treinamento antes de iniciar a sessão é realizado para o voluntário se tornar apto a realizar a IM e seguir corretamente o protocolo. No treinamento da IM foi pedido que o indivíduo observasse o movimento que estava realizando, quantas vezes ele julgasse necessário para formar uma imagem o mais nítida possível. Em seguida foi solicitado que o voluntário fechasse os olhos e se concentrasse no movimento, sentindo cada passo, para que pudesse em seguida imaginar o que sentiu realizando o movimento sem de fato efetuá-lo. Por último os voluntários tentaram imaginar o movimento utilizando as duas ou a melhor forma que conseguisse realizar a IM. Todos os voluntários mencionaram conseguir realizar melhor a IM fazendo uso da memória visual.

5.2 Pré-Processamento dos sinais

Após a aquisição dos sinais, é realizado o processamento dos sinais de forma *off-line*, porém todo algoritmo foi implementado de forma a permitir uma posterior implementação de uma ICM em tempo real.

Várias técnicas de processamento de sinais têm sido propostas para detectar a

dessincronização, ERD, que ocorre na banda mi ao se realizar um movimento ou IM [23]. Entretanto, para que estas técnicas possam apresentar maior qualidade dos resultados faz-se necessária a utilização de técnicas de pré-processamento para melhorar a relação sinal/ruído (RSR).

Neste trabalho a Transformada Wavelet (TW) foi utilizada para separar os detalhes do sinal de EEG relacionados às suas faixas de frequência. A primeira etapa de pré-processamento realizada nos sinais de EEG adquiridos neste trabalho é determinada pela extração de características utilizando a Transformada Wavelet Discreta (DWT), decompondo o sinal em suas aproximações e detalhes, e eliminando as componentes indesejadas.

Os sinais foram adquiridos a uma taxa de amostragem de 250Hz. A partir dessa taxa, com o objetivo de se obter as frequências relacionadas aos ritmos de EEG, utiliza-se a Análise Multiresolucional (AMR) realizando a decomposição em 8 níveis, conforme Tabela 5.1. Para essa decomposição foi adotada como wavelet-mãe a Daubechies *db4*, muito utilizada na literatura [71], [72] e [73]. Na Tabela 5.1 podem ser observadas as frequências referentes às aproximações e detalhes relacionados a cada nível de decomposição. Essa decomposição foi realizada conforme a Figura 4.8.

Tabela 5.1– *Lista de frequências relacionadas a cada nível de decomposição para um sinal de 250 Hz de frequência de amostragem.*

Nível de decomposição	Aproximações A em Hz	Detalhes D em Hz
1	0 – 63	63 – 125
2	0 – 31	31 – 63
3	0 – 16	16 – 31
4	0 – 8	8 – 16
5	0 – 4	4 – 8
6	0 – 2	2 – 4
7	0 – 1	1 – 2
8	0 – 0,5	0,5 – 1

Após a decomposição é realizada a reconstrução utilizando apenas os detalhes e/ou aproximações desejadas, com o objetivo de analisar apenas a faixa de frequência importante.

5.2.1 Eliminação de Artefatos

Em um sinal de EEG é comum encontrar artefatos biológico originados por biopotenciais musculares, movimento do voluntário ou movimento dos olhos. A identificação e eliminação dos padrões dos sinais de EOG e EMG no sinal de EEG é uma forma de minimizar esses tipos de artefatos, que possuem maior amplitude que o sinal em estudo.

Primeiramente, é realizada a verificação da existência de artefatos com alta amplitude no registro de EEG, caso existam é realizada a identificação e eliminação desses artefatos. Para essa verificação utiliza-se o sinal capturado no canal frontal F3 (podendo ser o canal F4), canal mais susceptível a esses tipos de artefatos, principalmente o relacionado ao movimento ocular, como a piscada palpebral. Quando detectado artefato nesse canal a eliminação do ruído é realizada em todos os canais utilizados. A detecção é realizada através da análise do valor absoluto do sinal em F3, onde é calculado o seu valor máximo, sua média e desvio padrão, para todos os sinais capturados. Com esses valores calculados, verifica-se o percentual médio da distância que a média mais o desvio padrão está do valor máximo de F3. Esse percentual médio calculado foi de 31%, para garantir uma boa classificação foi tomado um limiar T de 40% do máximo, com o objetivo de verificar o número de picos acima desse valor. Se o sinal tiver um número muito elevado de picos, a probabilidade desses picos de não ser artefato relacionado à EOG e EMG é elevada. Levando isso em consideração, o número de picos é comparado com um valor de 2,5% do tamanho do sinal. Se o número de picos for superior a esse valor, o sinal não será

processado pelos algoritmos de remoção desses artefatos, para que seja evitada a sua detecção de forma equivocada. Se o número de picos for menor que os 2,5% do tamanho do sinal, o mesmo passará pela detecção e remoção desses artefatos. Esse valor de 2,5% foi determinado verificando o percentual referente à distância entre o número de picos acima do limiar T , e o número de pontos do sinal. Com o objetivo de determinar esse valor percentual, foi realizada uma inspeção visual de cada registro, que foram classificados em sinal com ou sem artefato. Os sinais sem artefatos, fisiológicos de alta amplitude, obtiveram como percentual mínimo 2,5% do tamanho do sinal, sendo assim esse valor adotado. Na Figura 5.8 pode ser observado o valor absoluto de dois registros de EEG capturados no canal F3, para dois voluntários diferentes, que exemplifica um sinal com artefato de grande amplitude, Figura 5.8a, e um sinal sem artefato evidente Figura 5.8b. Nesse gráfico pode ser visualizada uma reta em vermelho referente ao limiar T calculado.




Figura 5.8 – Exemplos do valor absoluto de sinais de EEG capturados em F3, em indivíduos diferentes, em (a) com artefato de grande amplitude e em (b) sem artefatos evidentes. Fonte: autor.

Assim, o primeiro objetivo do algoritmo de pré-processamento é a eliminação dos artefatos biológicos de maior amplitude, quando esses existirem. Para essa eliminação é necessária a detecção dos padrões dos artefatos relacionados à EOG e EMG.

5.2.1.1 Eliminação de padrões com características de EOG

O sinal de EOG pode ser utilizado em uma IHM para acionamentos de dispositivos de *hardware* [4], por meio do reconhecimento dos trechos do sinal que foram realizados movimentos oculares. Porém, em um sinal de EEG o movimento ocular, bem como a piscada palpebral, pode interferir no sinal, e sua detecção pode ser realizada da mesma forma que em um sinal de EOG.

Inicialmente o sinal de EEG foi decomposto em seus ritmos pela DWT conforme, mostrado anteriormente, na Tabela 5.1, com o objetivo de selecionar o melhor detalhe ou aproximação que represente de forma mais adequada o evento a ser detectado. Na análise de sinal de EOG tem-se interesse em sua envoltória, com a finalidade de detectar os picos positivos e negativos do sinal. Para essa detecção é suficiente uma faixa de frequência baixa, até 4Hz. Então, observando a Tabela 5.1 verifica-se as possíveis faixas de frequência a serem utilizadas para uma boa detecção desses picos, entre 0 e 4Hz. Após a decomposição o sinal é reconstruído por meio da DWT inversa. Conforme a Tabela 5.2, essa reconstrução pode ser realizada utilizando apenas a aproximação 5 (A5), ou utilizando os detalhes de nível 6,7 e 8 (D6+D7+D8), ou ainda por uma junção da aproximação 5 com a soma dos detalhes citados. Como as três formas se mostraram equivalentes, a de menor custo computacional foi adotada, ou seja, A5. Na Figura 5.9a pode ser observado um trecho de sinal de EEG que possui artefato de piscada e o sinal reconstruído apenas com a A5 (Figura 5.9b).

Tabela 5.2– Formas de reconstruir o sinal de EEG evidenciando os artefatos de EOG e EMG a partir das aproximações e/ou detalhes.

Artefatos	Faixa de frequência de interesse	Reconstrução por aproximação	Reconstrução por detalhes	Reconstrução por aproximação e detalhes
EMG	31 – 63Hz	A1-A2	D2	A1-A2+D2
EOG	0 – 4Hz	A5	D6+D7+D8	A5+D6+D7+D8




Figura 5.9 – Trecho de sinal de EEG que possui artefato de piscada: (a) sinal original, e (b) aproximação A5 por decomposição wavelet. Fonte: autor.

Após a reconstrução do sinal de EEG pela aproximação A5, a qual evidencia as características do artefato de movimento ocular, foi realizado o cálculo da envoltória.

O cálculo da envoltória em sinais de EOG pode ser realizado no domínio do tempo utilizando um filtro de média móvel (MM) para eliminar o ruído, porém após utilização desse filtro ocorre um aumento no tempo de acomodação do sinal, que é reduzido retirando a tendência do sinal, como desenvolvido por SANTOS FILHO *et al.* [4], porém aumenta o nível de ruído, como pode ser visualizado na Figura 5.10c.




Figura 5.10 – (a) EOG original, (b) filtrado com MM e (c) depois de retirada a tendência do sinal. Fonte: Imagem retirada de SANTOS et al. [4].

Neste trabalho foi desenvolvida uma nova abordagem de detecção de envoltória para sinais de EOG baseada na expansão do sinal por meio da utilização de uma função exponencial. Da mesma forma pode ser utilizada em um sinal de EEG, contaminado por artefatos de EOG, para detecção de envoltória após a obtenção da aproximação A5 pela decomposição wavelet. Como pode ser visualizado na Figura 5.11 os valores de baixa amplitude são mapeados para valores ainda menores (compressão), e valores de maior amplitude são mapeados para valores ainda maiores (expansão), evidenciando os picos mais altos do sinal. Devido às características do sinal foi utilizada uma exponencial do tipo $(e^x - 1)$ para a parte positiva, e $(-e^x + 1)$ para a parte negativa do sinal (Equação (5-1)), evidenciando os trechos com picos, tanto positivos quanto negativos e diminuindo a contribuição dos outros trechos.

$$Envoltória = (e^{\frac{4mx}{\max(x)}} - 1) + (-e^{\frac{4\bar{m}x}{\min(x)}} + 1), \quad (5-1)$$

onde x é o sinal de EEG com artefato de EOG evidenciado, m é uma máscara formada de valores igual a 0 e 1, em que m é 1 quando $x > 0$ e 0 caso contrário, e \bar{m} é o barrado de m . Assim a primeira parte da Equação (5-1) atua apenas nos trechos positivos e a segunda parte nos trechos negativos.

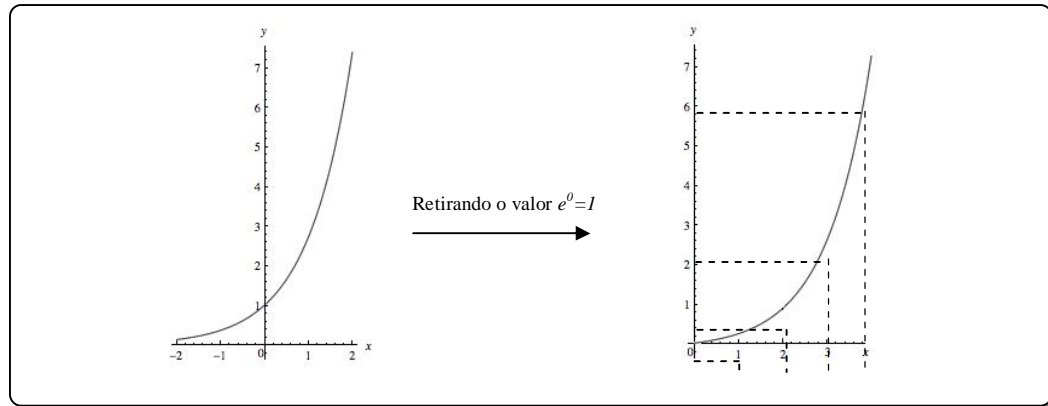


Figura 5.11 – Função exponencial utilizada como expansora dos trechos com maior valor, e compressora para os trechos com menor valor, conforme tracejado. Fonte: autor.

Na Figura 5.12a pode ser observado a aproximação A5 do sinal de EEG. Na Figura 5.12b a envoltória do sinal resultante da “filtragem” wavelet, calculado com a função exponencial.




Figura 5.12 – Sinal de EEG: (a) A5 e (b) envoltória do sinal (a). Fonte: autor.

Por último é realizada a detecção dos padrões relacionados ao movimento ocular. O sinal é percorrido ponto a ponto, e o ponto que atingir um limiar maior que três desvios padrões (3σ) para a parte positiva do sinal, e menor que -3σ para a parte negativa do sinal, é classificado como pertencente ao movimento ocular. Na Figura 5.13 pode ser observado um exemplo do reconhecimento de padrão para o método de processamento desenvolvido neste trabalho.




Figura 5.13 – Reconhecimento de padrão de EOG em um sinal de EEG. Fonte: autor

Assim, com a detecção dos pontos referentes a esse tipo de artefato presente no sinal de EEG, sua eliminação pode ser realizada de duas formas: a primeira é eliminar todos os trechos de interesse que contenham os artefatos de EOG; e a segunda forma, que foi a adotada neste trabalho, para que não houvesse muitas perdas de trechos, os pontos detectados como artefato foram eliminados do sinal original, sendo substituídos pelo valor do ponto anterior ao artefato, vide Figura 5.14.




Figura 5.14 – Eliminação de artefato de EOG em um sinal de EEG: (a) sinal original com artefato (picos com maior amplitude), (b) sinal após eliminação do artefato, (c) trecho ampliado de (a) mostrando um padrão de artefato de EOG, e em (d) trecho (c) após eliminação de artefato. Fonte: autor.

Durante a aquisição dos sinais de EEG, em diversos voluntários, foi detectada uma quantidade substancial de artefatos de EOG. Como o sistema para o reconhecimento do movimento e IM deve ser robusto, isto é, resistente a falhas, foi necessária a eliminação desse tipo de artefato.

5.2.1.2 Eliminação de padrões com características de EMG

O sinal de EMG pode ser utilizado em uma IHM para realizar acionamentos de dispositivos [2] por indivíduos que possuam alguma atividade muscular. Nessa interface devem-se reconhecer os trechos do sinal que ocorreram uma contração muscular, ou seja, trecho que possui maior amplitude. Em um sinal de EEG a ativação da musculatura da cabeça e/ou pescoço pode interferir no sinal, e sua detecção pode ser realizada da mesma forma que em um sinal de EMG. Devido a grande variação de amplitude que ocorre durante a ativação muscular ou movimento do indivíduo, por exemplo, em uma deglutição, é suficiente para interferir no sinal de EEG.

Inicialmente o sinal de EEG é decomposto em seus ritmos pela DWT conforme Tabela 5.1, com o objetivo de selecionar o melhor detalhe ou aproximação que represente de forma mais adequada o evento a ser detectado. Na aquisição do sinal de EEG devido às características dos filtros do equipamento, a maior parte das frequências relacionadas ao EMG já é eliminada na aquisição. Observando a Tabela 5.1 verificam-se as possíveis faixas de frequências a ser analisadas no sinal de EEG. Experimentalmente uma faixa de frequência que se obteve uma boa detecção da ativação muscular se encontra entre 31 e 63Hz, devido as características de alta frequência do EMG. A faixa de frequências situadas entre 63 e 125Hz não foram consideradas por possuírem um maior nível de ruído relacionado a rede elétrica. Assim, após a decomposição é realizada a reconstrução do sinal utilizando a DWT inversa. Conforme a Tabela 5.2 essa reconstrução pode ser realizada

utilizando a subtração entre as aproximações 1 e 2 (A1-A2), ou utilizando apenas detalhe de nível 2 (D2), ou ainda por uma junção da subtração entre as aproximações 1 e 2 somado com o detalhe 2. Como as três formas se mostraram equivalentes, a de menor custo computacional foi adotada, ou seja, D2. Na Figura 5.15a pode ser observado um trecho de sinal de EEG que possui artefato muscular e o sinal reconstruído apenas com o detalhe D2, Figura 5.15b.




Figura 5.15 – Sinal de EEG com artefato muscular: (a) sinal original, e (b) detalhe D2.
Fonte: autor.

Após a extração das características do EEG relacionadas à ativação muscular pelo detalhe D2, é realizada a detecção da envoltória do sinal. O cálculo da envoltória em sinais de EMG é abordado na literatura tanto no domínio do tempo [74] quanto no domínio da frequência [75]. Neste trabalho foi realizada uma abordagem no domínio do tempo baseada na detecção de envoltória muito utilizada na área de telecomunicações, por exemplo, em um receptor de rádio AM, ou seja, a demodulação [76]. Demodulação é o ato de recuperar a onda modulante do sinal original da onda modulada que chega a um receptor. Analogamente, para o sinal de EMG, a onda modulante traz informação suficiente para a detecção do momento que ocorre a ativação muscular. Para essa demodulação existem vários dispositivos, porém neste trabalho foi adotado o modelo de um simples detector de envoltória constituído de um diodo e um filtro resistor-capacitor (RC), vide Figura 5.16.




Figura 5.16 – Circuito detector de envoltória com analogia para o EMG. Fonte: autor.

O princípio de operação desse detector de envoltória é dado da seguinte forma: no semiciclo positivo do sinal de entrada, o diodo é diretamente polarizado e o capacitor C carrega rapidamente até o valor do pico do sinal de entrada. Quando o sinal cai abaixo desse valor, o diodo fica reversamente polarizado e o capacitor descarrega-se lentamente através do resistor de carga R , esse processo de descarga continua até o próximo semiciclo positivo, e o processo se repete [77]. Logo, o cálculo da envoltória é baseado na carga e descarga do capacitor, em que o sinal resultante coletado no resistor segue a equação de descarga do capacitor segundo a Equação (5-2) [78].

$$V(t) = V_0 e^{-\frac{t}{\tau}}, \quad (5-2)$$

onde V é o sinal de saída, t é o tempo, V_0 é a tensão do capacitor carregado e τ é a constante de tempo determinada por RC . A escolha da constante de tempo RC é realizada de forma que o capacitor descarregue lentamente entre os picos positivos, ou seja, $RC \gg 1/\omega_c$, onde ω_c é a frequência gerada pela oscilação (*ripple*) devido à descarga do capacitor entre os picos positivos. Experimentalmente um bom valor escolhido para RC foi $1000/\omega_c$.

O sinal é percorrido ponto a ponto, e é realizada uma comparação do ponto atual da entrada com o ponto anterior, se o ponto atual for maior ou igual ao anterior, a saída será igual ao ponto atual, similarmente quando o diodo está polarizado diretamente e está ocorrendo a carga do capacitor, quando o ponto atual é menor que o anterior significa que o capacitor atingiu sua carga máxima e o diodo fica polarizado inversamente. Logo, na

saída tem-se a equação de descarga do capacitor. Na Figura 5.17 pode-se observar o envelope do sinal de EEG referente ao artefato de EMG.




Figura 5.17 – Envelope do sinal de EEG com artefato de EMG, calculado com o método baseado em um circuito demodulador. Fonte: autor.

Após o cálculo da envoltória é realizada a classificação para detecção da ativação muscular. O traçado da envoltória é percorrido ponto a ponto, e o ponto que atingir um limiar maior que três desvios padrões (3σ) é classificado como pertencente ao evento contração muscular, que corrobora com o encontrado na literatura [2]. Em que σ é o desvio padrão calculado considerando todo o sinal. Alguns pontos durante a contração podem ser classificados de forma equivocada, logo para tornar a classificação mais uniforme é realizada a aplicação de um filtro de mediana móvel, numa janela de 150 pontos. Na Figura 5.18 pode ser observado um exemplo do reconhecimento do padrão.




Figura 5.18 – Reconhecimento de padrão para o sinal de EEG com artefato de EMG: (a) classificação utilizando o limiar de 3σ , e (b) após filtro da mediana. Fonte: autor.

Da mesma forma que o artefato de EOG, apenas os pontos detectados como artefato relacionado a EMG foram eliminados do sinal original, sendo substituídos pelo valor do ponto anterior ao artefato, vide Figura 5.19.




Figura 5.19 – *Eliminação de artefato de EMG em um sinal de EEG: (a) trecho de um sinal original com artefato, (b) sinal após eliminação do artefato. Fonte: autor.*

5.2.2 Separação dos Ritmos do EEG com Wavelet

Após a verificação da existência de artefatos e eliminação de cada um dos tipos mencionados, o sinal de EEG é separado em seus ritmos de frequência utilizando o mesmo método mencionado, pela AMR efetuada pela DWT.

O método mais utilizado para separação dos ritmos do EEG é por filtragem com a utilização de filtro do tipo FIR passa-faixas, contudo, a amplitude do sinal de EEG é muito baixa, com muitos artefatos, por exemplo, ruído referente à rede elétrica, que ainda fica evidente após a filtragem. O uso da wavelet mostrou-se mais eficaz na separação em bandas do sinal, isso pode ser verificado visualizando a Figura 5.20a que apresenta o espectrograma da banda alfa extraída utilizando uma filtragem com filtro FIR de ordem 512, e na Figura 5.20b o espectrograma da mesma banda extraída pela decomposição do sinal pela wavelet.

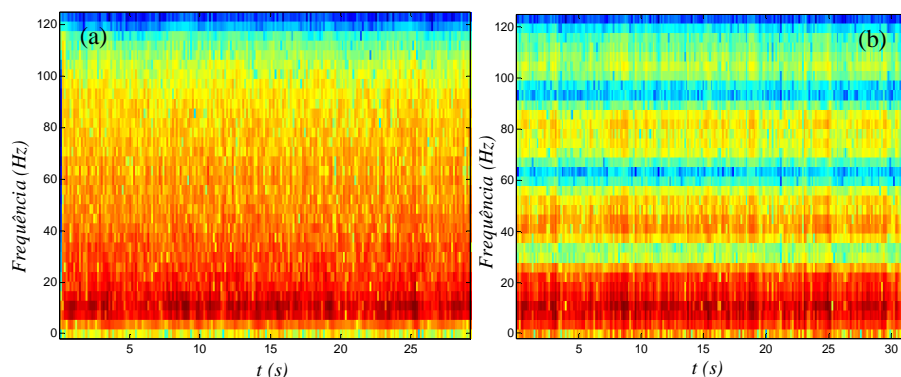


Figura 5.20 – Espectrograma da banda alfa extraída por filtragem (a) no tempo com filtro passa-faixa do tipo FIR, e (b) decomposição com wavelet, AMR. Fonte: autor.

Na separação dos ritmos de EEG por meio da reconstrução do sinal utilizando a DWT inversa é necessário observar a Tabela 5.1 e determinar que detalhes e/ou aproximação é referente a cada faixa de frequência. Pode ser visualizado na Tabela 5.3 as faixas de frequências dos ritmos de EEG associadas aos detalhes da wavelet. Alguns dos detalhes possuem uma banda maior que a banda do EEG, por exemplo, D4 possui frequências entre 8 e 16Hz, e a banda alfa entre 8 e 13Hz, no entanto a banda alfa está contida na faixa de D4, que irá representar alfa, bem como, ocorre com a banda beta e gama. O detalhe D4 além de englobar a faixa de frequência do ritmo alfa ou mi também possui parte de beta1 [80]. Para este trabalho o D4 possui a faixa de frequência necessária para a análise de ERD e ERS do movimento e IM, devido à variação que ocorre nessa faixa de frequência ao se efetuar esses eventos. Assim o detalhe D4 será tomado como ritmo alfa ou mi.

Tabela 5.3– Separação dos ritmos do EEG, a partir da reconstrução utilizando detalhes.

Ritmos de EEG	Frequências das bandas	Reconstrução por detalhes	Detalhes D em Hz
Delta	0,5 – 4Hz	D6+D7+D8	0,5 – 4Hz
Teta	4 – 8Hz	D5	4 – 8Hz
Alfa ou Mi	8 – 13Hz	D4	8 – 16Hz
Beta	13 – 30Hz	D3	16 – 31Hz
Gama	30 – 40Hz	D2	31 – 63Hz

Na Figura 5.21 pode ser observado um sinal de EEG original, capturado na região occipital no canal O1, e seus ritmos separados por decomposição wavelet.

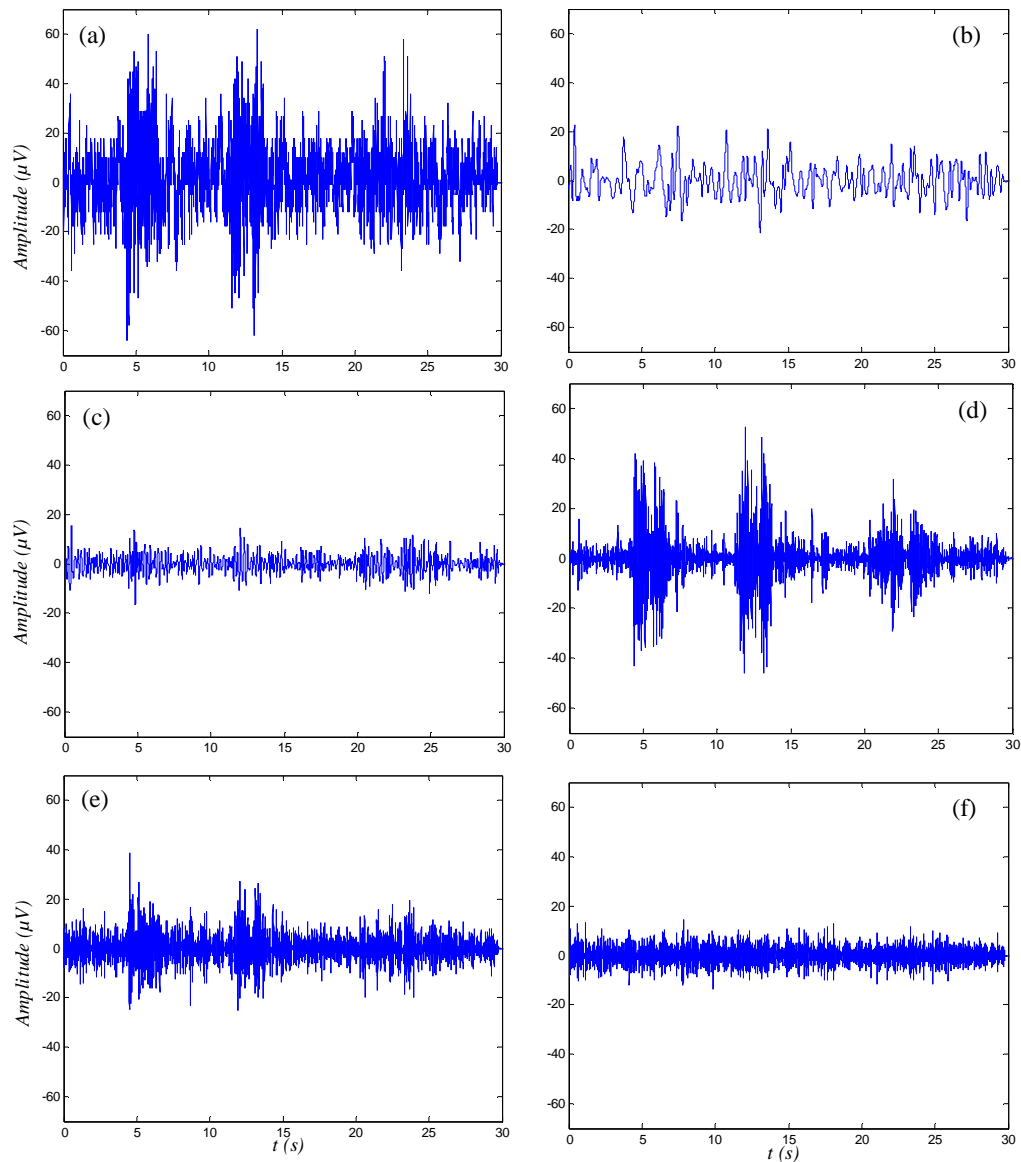


Figura 5.21 – Sinal de EEG (a) original, e ritmos (b) delta, (c) teta, (d) alfa, (e) beta e (f) gama, por meio de decomposição wavelet. Fonte: autor.

Um exemplo do ritmo mi, por D4, em um instante de movimento (entre 3,2 e 6,4s) pode ser visualizada na Figura 5.22, referente a um sinal de EEG capturado no eletrodo C3 durante o movimento da mão direita.




Figura 5.22 – Sinal de EEG (a) original e (b) apenas a banda mi separada por decomposição wavelet, detalhe D4. Fonte: autor.

Após essa “filtragem” cada sinal de cada voluntário é separado em trechos referentes a três tipos de atividades: EEG espontâneo ou basal, movimento e IM. Cada trecho contém 7s, conforme Figura 5.23, englobando os 3s do movimento ou IM com mais 2s antes e depois. Na maioria dos registros, em cada sessão foram extraídos 10 trechos de cada atividade. Totalizando aproximadamente 80 trechos de movimento e 80 de IM para cada indivíduo.




Figura 5.23 – Ritmo mi do EEG capturado em C3: (a) espontâneo, (b) movimento e (c) IM. Fonte: autor.

5.2.3 Energia do Sinal

Após a obtenção do ritmo mi foi realizado o cálculo da sua energia no decorrer do tempo dentro de uma janela de tamanho, determinado experimentalmente, de 100 pontos. A janela percorre o sinal ponto a ponto realizando o cálculo da energia segundo a Equação(5-3) [59].

$$E = \sum_{n=i}^{n=i+99} |x(n)|^2 \quad (5-3)$$

Com o cálculo da energia na banda mi é possível visualizar quando ocorre ERD no início do movimento ou IM e ERS ao final desses eventos. Na Figura 5.24a pode ser observado o ritmo mi do sinal de EEG capturado no canal C3 em atividade espontânea, e na Figura 5.24b o gráfico de sua energia calculada. Na Figura 5.25a e Figura 5.25c o ritmo mi durante o movimento e IM, respectivamente. E na Figura 5.25b e Figura 5.25d suas respectivas energias, com o instante do movimento e IM circulos em vermelho.




Figura 5.24 – EEG espontâneo capturado em C3: (a) ritmo mi e (b) sua energia. Fonte: autor.




Figura 5.25 – EEG capturado em C3: (a) ritmo mi durante o movimento, (b) energia de (a), (c) ritmo mi durante IM, e (d) energia de (c). Fonte: autor.

Além do cálculo da energia é retirado seu valor médio e em seguida é normalizado por seu desvio padrão, deixando-o com menor amplitude e com valores positivos e negativos, vide Figura 5.26. Esse cálculo indica o número de desvios padrões que um

determinado valor está distante da média. O sinal resultante de todo o pré-processamento posteriormente é percorrido pelo algoritmo de reconhecimento de padrões que determina o instante em que ocorreu o movimento ou IM. Ainda é realizada a média de 10 trechos desse sinal resultante de um voluntário para o treinamento desse algoritmo.




Figura 5.26 – (a) Energia calculada em C3 e (b) sinal resultante do pré-processamento.
Fonte: autor.

5.2.4 Densidade Espectral de Potência do EEG

Realizando o processamento sobre o sinal, após a separação do ritmo alfa ou mi, pela wavelet foi realizado o cálculo da densidade espectral de potência (PSD, do inglês *Power Spectrum Density*) [77] utilizando o método de WELCH [60] aplicada nos canais C3 e C4. A PSD é calculada nos trechos de 7s, em um processamento *online* é realizado o cálculo a cada janela de 1750 pontos, considerando a taxa de amostragem aqui utilizada, 250amostras/s. Essa informação da PSD dos dois canais serve de entrada em um sistema simbólico (SS). Esse SS é baseado em regras e identifica na PSD o valor da potência em

12Hz para cada canal e indica se o movimento ou IM foi realizado pela mão direita ou esquerda, de acordo com a menor potência. Essa distinção da mão, ao efetuar o movimento, pode ser constatada visualizando a Figura 5.27. A Figura 5.27a é referente ao movimento da mão direita, logo o hemisfério contralateral, canal C3, sofre uma dessincronização maior, ocorrendo uma diminuição da potência da banda mi maior que em C4. E a Figura 5.27b é referente ao movimento da mão esquerda, ocorrendo o inverso, porém com uma diferença menor entre as potências em C3 e C4, comportamento comum em destros [22].

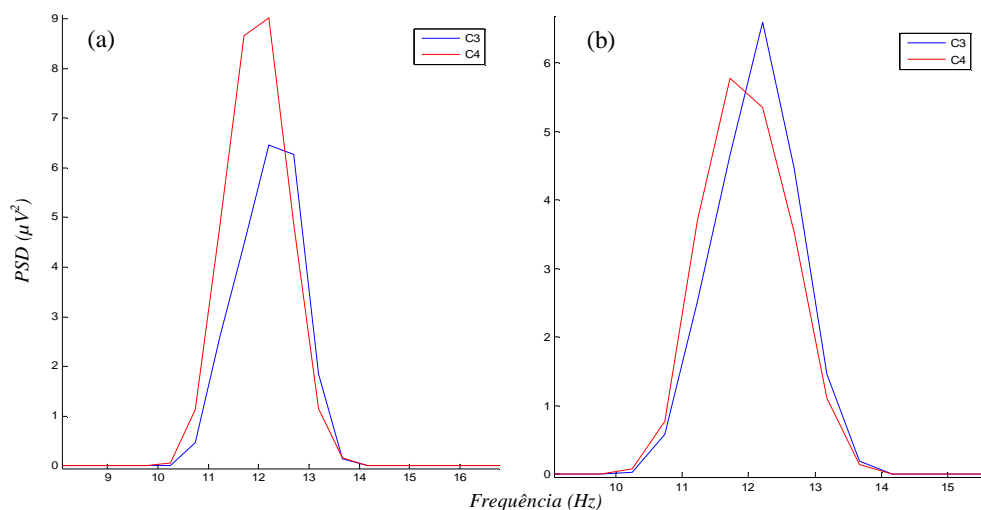


Figura 5.27 – PSD calculada para os canais C3(azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.

Utilizando o PSD pode-se detectar se ocorreu movimento/IM ou se o indivíduo estava em estado basal. Essa diferença entre a PSD do EEG espontâneo e quando ocorre movimento ou imaginação do movimento pode ser visualizado na Figura 5.28, corroborando com os resultados de STECKLOW [82]. Na Figura 5.28a para o sinal capturado em C3, observa-se a maior potência para o sinal espontâneo e menor quando ocorre o movimento da mão direita, demonstrando a dessincronização que ocorre com o movimento. Na Figura 5.28b para o sinal capturado em C4, observa-se da mesma forma a maior potência do sinal espontâneo, e ainda percebe-se a maior potência detectada em C4

comparado com C3, quando ocorre o movimento, o que enfatiza que o movimento ocorreu na mão direita.

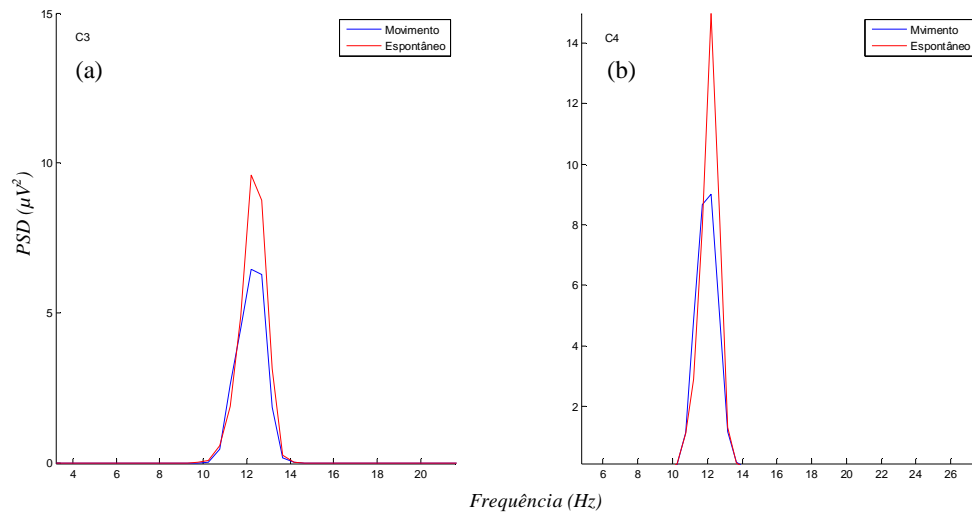


Figura 5.28 – PSD calculada para o movimento (azul) e EEG espontâneo (vermelho): (a) capturado em C3 e (b) capturado em C4. Fonte: autor.

Porém para verificar a existência do movimento ou IM de forma mais eficiente e elaborada foi utilizado outro algoritmo de processamento e reconhecimento, utilizando o cálculo da PSD apenas como entrada no SS que identifica se o movimento ou IM ocorreu na mão direita ou esquerda, com o objetivo de acionar uma das RNAs. As RNAs foram desenvolvidas, uma com padrões de entrada referente à mão direita e outra com padrões referentes à mão esquerda, logo o SS acionará a RNA respectiva.

5.3 RNAs para o Processamento do EEG

Métodos matemáticos e estatísticos podem ser aplicados para o reconhecimento de padrões, porém o especialista humano ainda é conhecido como a melhor opção para a classificação de padrões. Por meio da inspeção visual de um especialista nos registros de EEG, apesar de não ser uma tarefa fácil e possuir um percentual de erro agregado, ele é capaz de classificar e identificar com muita eficiência padrões característicos no EEG, por

exemplo, padrões epileptiformes [81], e padrões que caracterizam as fases do sono [66].

Padrões relacionados ao movimento e IM em um sinal de EEG também podem ser identificados por um especialista, entretanto, dificilmente apenas realizando uma inspeção no sinal original como os citados, por possuírem uma maior complexidade exigem uma análise estatística e matemática mais apurada. Na análise do EEG, por exemplo, para a identificação da IM, segundo STECKLOW [82], pode ser observada a variação dos picos de potência do ritmo μ , que diminui quando é realizado o movimento ou IM. Uma segunda abordagem desenvolvida por *SANTOS FILHO* [35] consegue detectar a IM utilizando a análise no ritmo delta, de 0,3 a 1Hz, utilizando a Magnitude Quadrática da Coerência (MSC).

Neste trabalho foram desenvolvidas três RNAs, uma RNA estática e duas RNAs dinâmicas, para o auxílio na identificação do movimento e IM por meio da análise do registro de EEG. As três utilizam o algoritmo de treinamento supervisionado *Backpropagation*. Para a entrada das três RNAs efetuou-se uma subamostragem de 20 pontos no sinal de energia para diminuir o número de pontos do padrão de entrada da rede, diminuindo o custo computacional. Todas as RNAs desenvolvidas foram testadas individualmente, para que se pudesse definir a mais adequada para o reconhecimento do padrão do movimento e da IM. O padrão de movimento e IM são os mesmos diferindo apenas do EEG espontâneo.

5.3.1 RNA Estática (RNAE)

Neste trabalho foram utilizados os canais C3 e C4 na detecção do movimento e da IM. Uma RNA foi treinada com padrões capturados em C3 quando o indivíduo efetuou movimento e IM com a mão direita, e da mesma forma outra rede foi treinada com os

padrões capturados em C4 quando ocorre o movimento ou IM da mão esquerda. No processo de reconhecimento o sistema simbólico SS fornece a informação de qual hemisfério se originou a atividade, e é realizada automaticamente a escolha da rede a ser utilizada.

A primeira rede desenvolvida foi uma rede neural estática (RNAE), e para seu treinamento foram utilizados cinco padrões de entrada, 2 padrões para a identificação de movimento ou IM, e três referentes a EEG espontâneo. Os padrões foram escolhidos entre os mais característicos para que a rede pudesse identificá-los e ainda utilizar seu poder de generalização para auxiliar na identificação de padrões semelhantes aos treinados, aumentando a qualidade da detecção do ERD. Os sinais foram subamostrados de 20 pontos, ficando com uma taxa de amostragem de 12,5Hz, com o objetivo de diminuir o número de pontos do padrão de entrada da rede, diminuindo o custo computacional, sem comprometer a integridade do sinal, Figura 5.29.




Figura 5.29 – Energia do sinal capturado em C3, em (a) original e em (b) subamostrado de vinte pontos. Fonte: autor.

A topologia da RNAE é composta de 30 neurônios na camada de entrada, referentes à C3 para a RNAE da mão direita e C4 para a RNAE da mão esquerda. Essa RNAE possui duas camadas intermediárias, a primeira com 20 e a segunda com 10 neurônios, totalmente interconectados e 1 neurônio na camada de saída. A escolha de 30 neurônios na camada de

entrada deve-se ao número de pontos do padrão desejado. A Figura 5.30 apresenta a estrutura das camadas e disposição dos neurônios da RNAE.

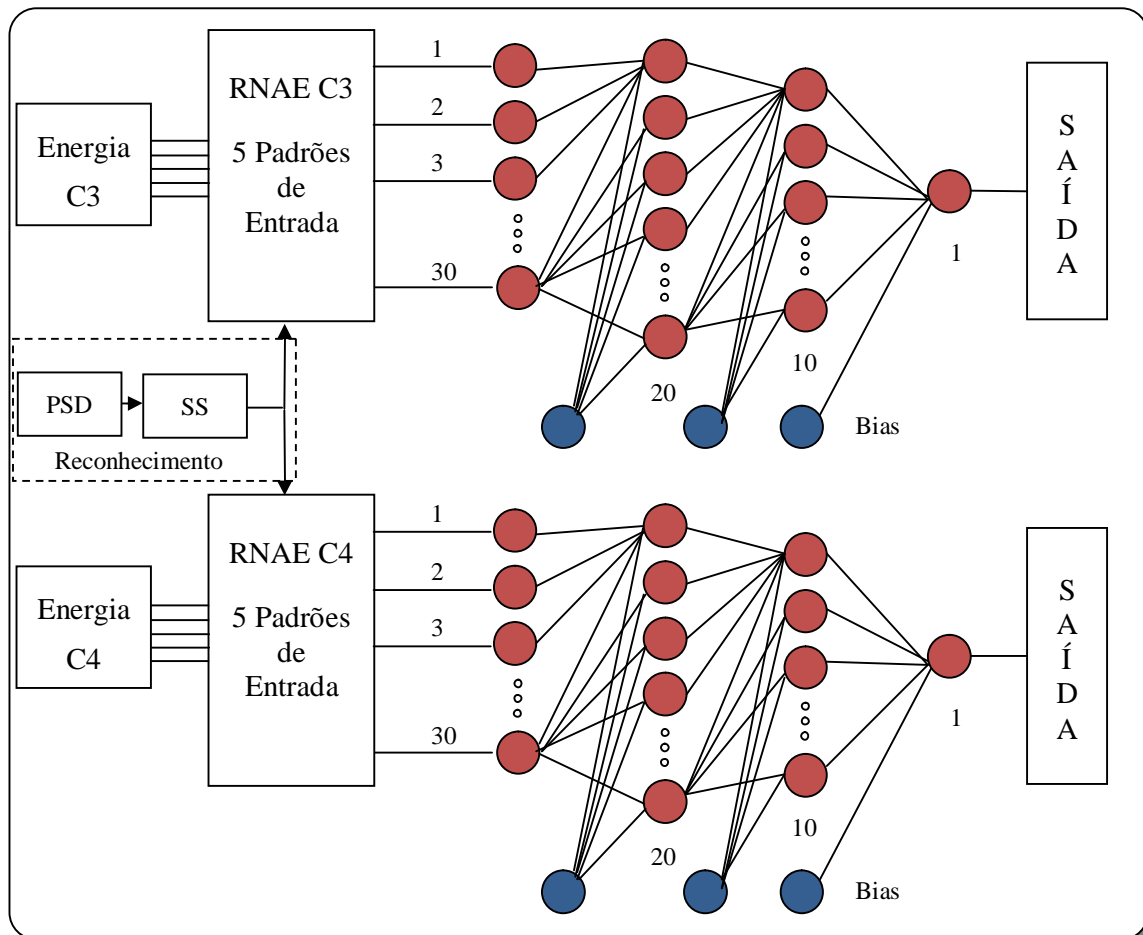


Figura 5.30 – Estrutura da RNAE desenvolvida. Fonte: autor.

Os padrões utilizados para o treinamento correspondem às entradas da RNAE, isto é, cada ponto de trechos do sinal resultante do pré-processamento corresponde à entrada de um neurônio na RNAE. O padrão alvo para saída da RNAE é 0,9 para movimento ou IM e 0 para EEG espontâneo, conforme Tabela 5.4. Foram utilizados 5 padrões de treinamento, em que 2 deles são referentes ao padrão de movimento e IM.

Tabela 5.4– Padrões de entrada e saída para o treinamento da RNAE.

Padrões de entrada	Saída desejada
EEG basal	0
Movimento ou IM	0,9

A Figura 5.31 apresenta cinco padrões de treinamento da RNAE referentes ao canal C3. Os padrões em (a) e (c) são referentes à diminuição da energia que ocorre no ritmo mi devido ao movimento ou IM, mostrando a dessincronização e ressincronização; e os padrões em (b), (d) e (e) são referentes à EEG basal (espontâneo). Antes de entrar na rede esses padrões são normalizados pelo valor máximo entre os máximos de cada padrão, ficando com valores no máximo até 1, porém mantendo a diferença de amplitude natural entre eles.




Figura 5.31 – Padrões de treinamento para a RNAE: (a) movimento ou IM, (b) EEG basal (variação isolada), (c) movimento, (d) EEG basal e (e) EEG basal. Fonte: autor.

O treinamento da RNAE é realizado por meio da apresentação de um padrão na entrada da rede e outro padrão respectivo é gerado na saída da rede. Após, realizar a primeira época do treinamento para todos os padrões de entrada, verifica-se o critério de

parada, se este não for satisfeito repete-se o treinamento com todos os padrões novamente. O critério de parada para o treinamento da RNAE é o somatório do erro médio quadrático total (SEQT) [83], quando o SEQT for menor ou igual a 0,001, ou até atingir 10000 ciclos de treinamento, o treinamento é interrompido, pois se considera que a rede “aprendeu” com esses elementos de entrada.

A taxa de aprendizado foi mantida constante (taxa de aprendizado = 0,2) para todos os tipos de RNA apresentadas neste trabalho, com a finalidade de facilitar a comparação dos resultados entre os diversos tipos de redes.

5.3.2 RNA Dinâmica 1 (RNAD1)

A segunda RNA desenvolvida possui características dinâmicas e tem como padrão de entrada o sinal resultante da fase de pré-processamento, referente à C3 ou C4. O padrão de treinamento é composto pela média de 10 trechos de dois voluntários em uma sessão. Os registros que geram os padrões de entrada possuem 7s, contendo partes de EEG espontâneo e parte com uma manobra de movimento. O SS atua no reconhecimento escolhendo a rede a ser utilizada, da mesma forma que na RNAE.

A RNAD1 possui como entrada uma camada constituída de 40 neurônios. A entrada de cada neurônio é interligada a uma malha de atraso. A RNAD1 possui duas camadas intermediárias, a primeira com 20 neurônios totalmente interconectados com a camada de entrada, e a segunda com 10 neurônios totalmente interconectados com o único neurônio de saída. A Figura 5.32 apresenta a estrutura das camadas e disposição dos neurônios da RNAD1.




Figura 5.32 – Estrutura da rede RNADI. Fonte: autor.

Os padrões de entrada da rede, juntamente com o padrão desejado, podem ser visualizados na Figura 5.33. Esses padrões são referentes à média de 10 trechos, no padrão da Figura 5.33a ocorre movimento e na Figura 5.33b EEG basal, do sinal capturado em C3 após todo pré-processamento, normalizado por seu valor máximo e subamostrado de 20 pontos da mesma forma que na RNAE.




Figura 5.33 – Em azul o sinal de entrada da RNAD1 e em vermelho o padrão desejado, marcando o espaço temporal que ocorreu o movimento. Fonte: autor.

A malha de atraso na entrada da RNAD1 faz todos os pontos do registro de EEG percorrerem cada um dos 40 neurônios de entrada da rede, sendo que, o primeiro ponto, é eliminado após o seu valor ser computado por todas as entradas da RNA. Este procedimento se repete até o final do registro a ser analisado. O treinamento da rede é realizado, ponto a ponto, isto é, para cada ponto que entra na malha de atraso é realizado um treinamento pela rede. No início, entram 40 pontos e em seguida a entrada vai se deslocando e atualizando um ponto de cada vez na malha de atraso. A principal característica desta RNA é a de verificar a maneira com que os pontos variam no decorrer do tempo e não a disposição física dos pontos no plano, como é o caso da RNAE, possibilitando desta forma a identificação de sinais variantes no tempo.

A RNAD1 utiliza como padrões de treinamento um conjunto de padrões (vetores) de entrada e saída conforme descrito na Tabela 5.5. A saída desejada para o padrão de entrada treinado é mostrada em vermelho na Figura 5.33. A rede foi treinada com valores

de 0 e 0,9, não foram utilizados -1 e 1 por serem os valores limites dos neurônios da rede, devido a função de ativação utilizada (tangente hiperbólica), fato esse que aumentaria o tempo de treinamento [66].

Tabela 5.5– Padrões de entrada e saída para o treinamento da RNAD1.

Padrões de entrada	Saída desejada da RNAD1
EEG basal	0
Movimento ou IM	0,9

A RNAD1 foi treinada com a finalidade de encontrar movimento e IM na extensão do registro de EEG, utilizando um padrão de entrada capturado em um canal posto no córtex motor (C3 ou C4). Assim, para o neurônio de saída, quando o movimento ou IM é encontrado o resultado do neurônio é em torno de 0,9, quando o padrão não é encontrado o resultado é aproximadamente 0.

O treinamento da RNAD1 foi realizado, mantendo o mesmo coeficiente de aprendizagem da RNAE, igual a 0,2. Após, realizar a primeira época do treinamento para todos os padrões de entrada, verifica-se o critério de parada, se este não for satisfeito repete-se o treinamento com todos os padrões novamente. O critério de parada para o treinamento da RNAD1 é o somatório do SEQT, quando o SEQT for menor ou igual a 0,001, ou até atingir 10000 ciclos de treinamento, o treinamento é interrompido, pois se considera que a rede “aprendeu” com esses elementos de entrada.

5.3.1 RNA Dinâmica Auto Adaptativa Supervisionada (RNAD2)

A terceira RNA desenvolvida também possui características dinâmicas e tem como padrão de entrada o sinal resultante da fase de pré-processamento, referente à C3 ou C4. Um dos padrões de entrada é referente à média de 10 trechos de um voluntário em uma sessão. O registro que gera os padrões de entrada possui 7s, contendo partes de EEG espontâneo e parte com uma manobra de movimento. O SS atua no reconhecimento escolhendo a rede a ser utilizada, da mesma forma que nas outras RNAs.

A RNAD2 foi desenvolvida com o objetivo de se obter uma rede mais robusta que seja capaz de “carregar” a informação de um treinamento inicial, composto por padrões médios selecionados de cinco indivíduos diferentes e tenha a possibilidade de se auto adaptar para reconhecer os sinais de outros indivíduos, ou ainda dos mesmos indivíduos em instantes diferentes. Ocorrem mudanças em um indivíduo a cada dia, bem como as condições de aquisição do sinal, necessitando assim de uma adaptação da rede. Essa rede possibilita a implementação de uma ICM inteligente, em que o indivíduo entra no sistema com sua identificação, se for um novo usuário o sistema é retreinado absorvendo um novo padrão. Se for um usuário veterano o sistema realiza apenas uma calibração para o indivíduo a cada vez que o sistema for reconectado.

A RND2 possui uma unidade de treinamento que possui as características básicas similares a RNAD1, possuindo como entrada uma camada constituída de 40 neurônios. A entrada de cada neurônio é interligada a uma malha de atraso. A RNAD2 possui duas camadas intermediárias, a primeira com 20 neurônios totalmente interconectados com a camada de entrada, e a segunda com 10 neurônios totalmente interconectados com o único neurônio de saída. A Figura 5.34 apresenta a estrutura das camadas e disposição dos neurônios da unidade de treinamento dinâmico da RNAD2. Essa unidade é controlada por

uma unidade de controle do treinamento adaptativo.

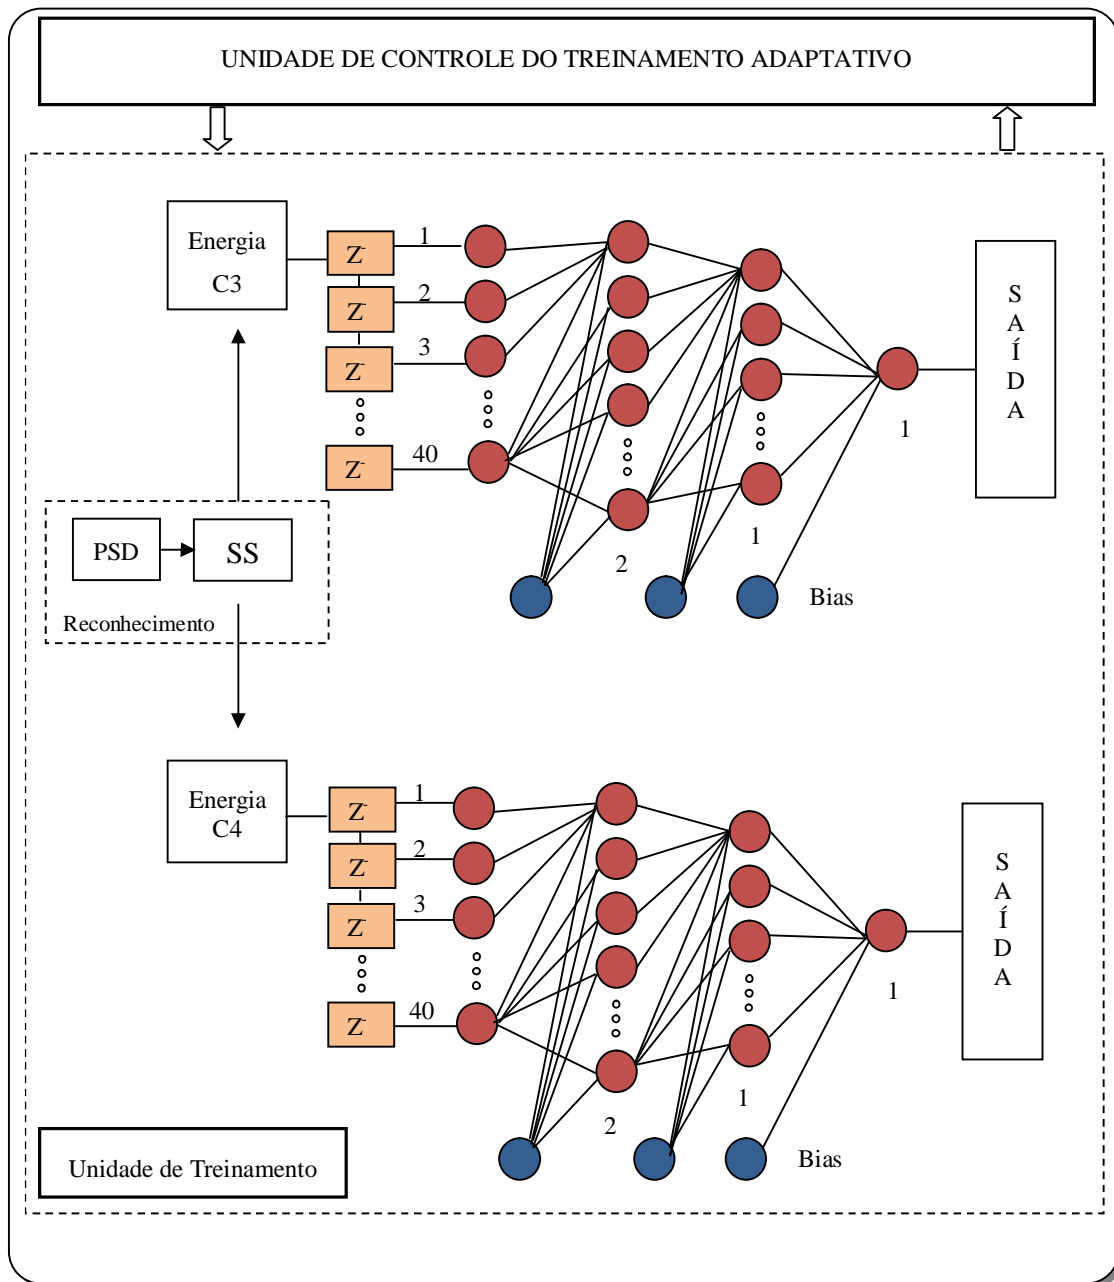


Figura 5.34 – Estrutura da RNAD2, mostrando a unidade de treinamento e a unidade de controle do treinamento adaptativo. Fonte: autor.

A RND2 é formada por uma unidade de controle de treinamento adaptativo, que é capaz de retreinar e adaptar a rede, e as unidades, de treinamento dinâmico, associadas. Essa unidade de controle possui uma unidade de treinamento principal, que possui a

mesma estrutura da unidade de treinamento. Essa unidade principal é utilizada em todas as situações posteriores de treinamento adaptativo, funcionando como memória do sistema. Essa memória está relacionada ao aprendizado com cinco conjuntos de padrões de entrada referentes a cinco indivíduos, selecionados de forma a representar diferentes padrões que podem ser encontrados no decorrer do registro, aumentando a qualidade da rede. Os cinco padrões de entrada da unidade principal da rede, juntamente com o padrão desejado, podem ser visualizados na Figura 5.35. Cada padrão de entrada é referente à média de 10 trechos, nos quais ocorre manobra de movimento, do sinal capturado em C3 após todo pré-processamento e subamostrado de 20 pontos, da mesma forma que nas outras RNAs. A normalização das entradas é realizada calculando-se o valor máximo entre os máximos de cada padrão de entrada, mantendo a diferença original de amplitude entre eles. Esse valor máximo utilizado na normalização é “carregado” também na memória do sistema, sendo levado em consideração nos posteriores treinamentos adaptativos.




Figura 5.35 – Em azul o sinal de entrada da RNAD2 e em vermelho o padrão desejado.
Fonte: autor.

A malha de atraso da entrada da RNAD2 faz com que todos os pontos do registro de EEG percorram cada um dos 40 neurônios de entrada da rede, sendo que, o primeiro ponto, é eliminado após o seu valor ser computado por todas as entradas da RNAD2. Este

procedimento se repete até o final do registro a ser analisado. O treinamento da rede é realizado, ponto a ponto, isto é, para cada ponto que entra na malha de atraso é realizado um treinamento pela rede. No início, entram 40 pontos e em seguida a entrada vai se deslocando e atualizando um ponto de cada vez na malha de atraso, da mesma forma que a RNAD1.

A RNAD2 utiliza como padrões de treinamento um conjunto de padrões (vetores) de entrada e saída conforme descrito na Tabela 5.6. A saída desejada para o padrão de entrada treinado é mostrada em vermelho na Figura 5.35. A rede foi treinada com valores para os padrões desejados de 0 e 0,9, não foram utilizados -1 e 1 da mesma forma que a RNAD1.

Tabela 5.6– *Padrões de entrada e saída para o treinamento da RNAD2.*

Padrões de entrada	Saída desejada da RNAD2
EEG basal	0
Movimento ou IM	0,9

As unidades da RNAD2 foram treinadas com a finalidade de encontrar movimento e IM na extensão do registro de EEG, utilizando padrões de entrada capturados em um canal posto no córtex motor (C3 ou C4). Assim, para o neurônio de saída, quando o movimento ou IM é encontrado o resultado do neurônio é em torno de 0,9, quando o padrão não é encontrado o resultado é aproximadamente 0.

O treinamento da RNAD2 foi realizado de forma similar a RNAD1, mantendo o mesmo coeficiente de aprendizagem de 0,2. Após, realizar a primeira época do treinamento para todos os padrões de entrada, verifica-se o critério de parada, se este não for satisfeito repete-se o treinamento com todos os padrões novamente. O critério de parada para o treinamento da RNAD2 é o somatório do SEQT, quando o SEQT for menor ou igual a

0,001, ou até atingir 10000 ciclos de treinamento, o treinamento é interrompido, pois se considera que a rede “aprendeu” com esses elementos de entrada, da mesma forma que as outras RNAs.

Toda estrutura da rede e processo de treinamento são os mesmo para a unidade principal e para a unidade de treinamento da RNAD adaptativa desenvolvida (RND2), diferindo apenas no número de padrões de entrada. Após o treinamento da unidade principal a rede pode ser utilizada por qualquer usuário que ela irá realizar um processo de retreinamento e adaptar-se, tornando-se apta a reconhecer os padrões de um novo usuário. Um fluxo geral do funcionamento da unidade de controle adaptativo da RNAD2 pode ser visualizado na Figura 5.36.

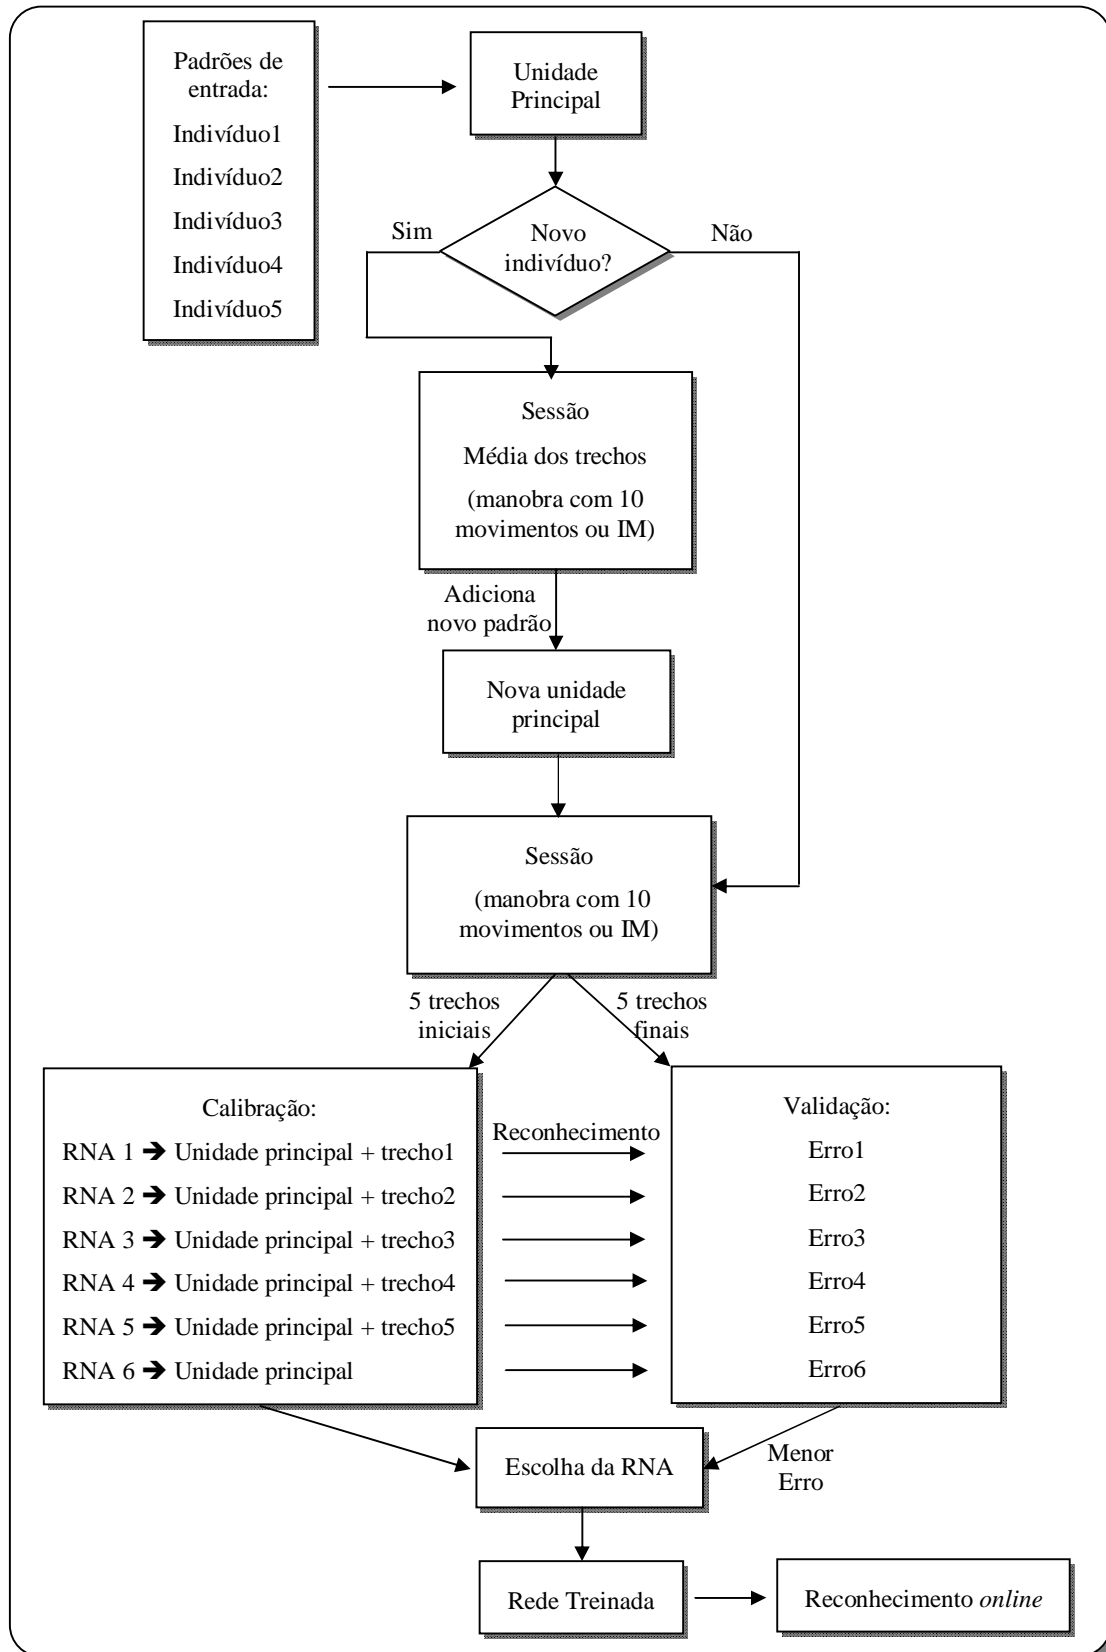


Figura 5.36 – Diagrama do funcionamento da unidade de controle adaptativo. Fonte: autor.

Neste trabalho os sinais de 10 voluntários foram coletados com sessões realizadas em dois dias. Para o treinamento da unidade principal foram utilizados os sinais da sessão 1 do primeiro dia de teste de 5 desses voluntários, o que permite validar o sistema com relação a testes efetuados em um indivíduo que teve seu sinal como padrão de entrada da unidade principal e por voluntários novos.

Se for um novo voluntário, ou seja, diferente do grupo que participou do treinamento da unidade principal, a média dos 10 trechos onde ocorreu o movimento de sua primeira sessão é acrescentada como padrão de entrada e a rede é retreinada. Essa passa a ser a unidade principal especificamente desse indivíduo.

A calibração e validação da nova rede são realizadas com o registro da segunda sessão, onde metade do número de trechos é adicionada, separadamente, a unidade principal que ganha mais um padrão de entrada para ser retreinada. Por exemplo, em um registro com 10 trechos, são geradas 5 redes diferentes, uma para cada trecho, e mais a rede composta apenas pelas entradas da unidade principal.

As 6 redes treinadas, no processo de calibração, são validadas com os trechos da segunda metade do registro da segunda sessão. É realizado o reconhecimento nos trechos por cada uma das redes e é calculado o erro para cada uma. Esse erro é calculado pela diferença entre a saída da rede e o padrão desejado gerado pelo marcador que sincroniza o evento. Os erros calculados de cada trecho são somados, e a rede que obteve menor erro é adotada para a utilização no reconhecimento dos padrões em todos os registros daquele indivíduo enquanto a aquisição possuir as mesmas características. Então, sempre que o sistema for desconectado do indivíduo e reconectado, a rede é recalibrada, se adaptando as novas condições de aquisição e do indivíduo. No caso de indivíduos que já utilizaram o sistema ocorre apenas o processo de calibração e validação, vide Figura 5.36.

CAPÍTULO 6

Resultados

Neste capítulo são apresentados os resultados obtidos com os diversos experimentos realizados. São apresentados os resultados alcançados desde a aquisição até o reconhecimento de padrões com os três tipos de redes desenvolvidas.

6.1 Aquisição e Banco de Dados

A aquisição dos sinais de EEG foi realizada conforme descrito na sessão 1 do Capítulo 5. Foram realizadas aquisições com 11 voluntários, porém o registro de um deles foi descartado, sendo 10 utilizados para análise. O registro de um dos voluntários foi descartado devido ao nível de ansiedade que o mesmo se encontrava durante a aquisição, produzindo um número de piscadas palpebrais intensas e muito frequentes, além da alta probabilidade de não ter atingido os objetivos do protocolo. Todos os registros foram efetuados no Laboratório de Engenharia Biomédica da UFPE. A maioria dos voluntários são estudantes de Pós-Graduação em Engenharia Elétrica (PPGEE) da mesma instituição e possuem em torno de 30 anos de idade.

No processo de preparação do indivíduo para a aquisição do EEG, levando em consideração a montagem dos eletrodos, instrução sobre as manobras, treinamento e o registro dos sinais seguindo o protocolo, foi necessário um tempo médio de uma hora e meia, para cada voluntário. Foram realizadas duas aquisições por dia, um voluntário por

turno. A aquisição foi realizada em dois dias para cada voluntário, na maioria, com um espaçamento de uma semana entre as aquisições. Assim, obteve-se um total de 80 registros, somando 38,64min para cada voluntário, um total de aproximadamente 6,44 horas.

Os registros foram realizados de forma sincronizada com uma projeção em uma tela. Inicialmente foram realizados testes com uma variação de cor de preto para branco para a indicação de início e fim do evento, porém foi verificada a presença de potencial evocado contaminando o registro, conforme marcado em vermelho na Figura 6.1b.




Figura 6.1 – Em (a) sinal marcador que indica o instante de tempo que se deve iniciar e finalizar o evento, e (b) sinal de EEG capturado em F3 durante o movimento, com partes circuladas em vermelho, possivelmente relacionadas a PE visual. Fonte: autor.

Assim, a maneira de sincronizar a projeção com o evento foi modificada. A tela projetada se mantém sempre branca com uma cruz no meio para evitar que o voluntário desvie o olhar, e no momento que deve ser efetuada a manobra aparece uma letra que indica movimento (M) ou IM (I), após essa indicação visual o voluntário realiza a atividade.

Um banco de dados foi gerado com todos os sinais adquiridos e os mesmos modificados em cada passo de pré-processamento e processamento. Cada registro foi dividido em trechos, referentes a movimento, IM e EEG espontâneo. Todos esses trechos

foram armazenados, facilitando a sua visualização e análise. O banco de dados possui todos os registros e trechos, filtrados, detalhes adquiridos com decomposição wavelet relacionados ao ritmo alfa ou mi e delta, PSD, energia e energia média e os resultados do reconhecimento pelos três tipos de RNAs. Todos esses arquivos foram gerados para os canais F3, F4, C3, C4, P3 e P4, totalizando um banco de dados de mais de 170.000 arquivos, um exemplo pode ser visualizado na Figura 6.2.




Figura 6.2 – Em (a) sinal com marcador de movimento. Registro de EEG nos canais (b) F3, (c) F4, (d) C3, (e) C4, (f) P3 e (g) P4. Fonte: autor.

No banco de dados além dos sinais dos voluntários, foram armazenados os registros originados no marcador para auxiliar a análise do registro, pois indica quando uma manobra se inicia e finaliza, tanto de movimento quanto de IM. Um espaço de tempo de 3s foi determinado para a realização da manobra, aparecendo a indicação de preparação para o tipo de manobra 1s antes. Durante a aquisição foi observado que muitos voluntários iniciaram a manobra nesse 1s de preparação, e findavam a manobra antes do término dos 3s reservado para a mesma. Outros voluntários iniciavam de forma tardia e finalizavam após o espaço de tempo determinado. O que torna difícil a criação de um padrão “ouro”

para a comparação em um sistema de reconhecimento. Dessa forma a análise foi realizada particionando os trechos de forma a obter 2s antes e depois de cada manobra, gerando para os voluntários que conseguiram completar as sessões, 160 trechos de movimento e IM, e 160 de espontâneo. Se todos os voluntários tivessem completado todas as sessões seria um total de 3200 trechos para análise, mas alguns voluntários, devido a erro próximo ao final da aquisição não chegaram a finalizar a sessão. Assim contabilizou-se um total de 3056 trechos, que foram analisados nesse trabalho.

6.1 Resultados das Etapas de Pré-processamento

No diagrama da Figura 6.3 pode ser observada a sequência do algoritmo de pré-processamento desenvolvido.

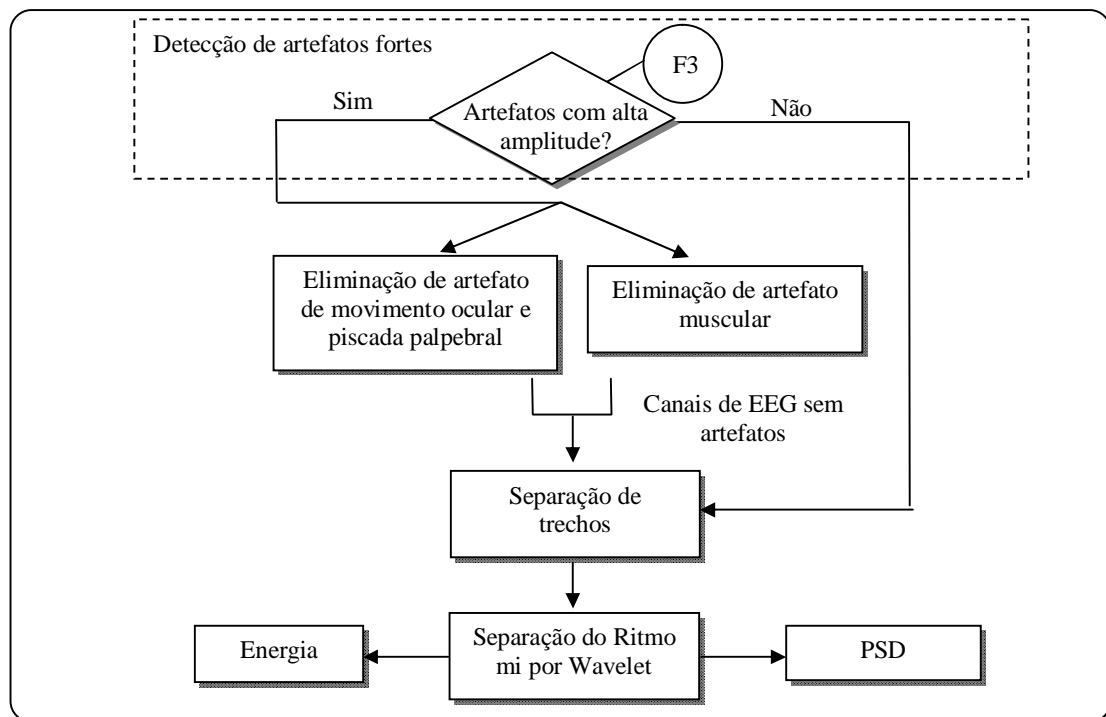


Figura 6.3 – Esquema geral do algoritmo de pré-processamento. Fonte: autor.

A detecção e eliminação dos artefatos foram realizadas de forma automática, prevendo-se, no futuro, um processamento *online*. Os artefatos provenientes de movimento ocular ou piscada palpebral foram eliminados seguindo a sequência mostrada no esquema da Figura 6.4. O sinal resultante da classificação indica que trechos com artefatos são eliminados de todos os canais utilizados.

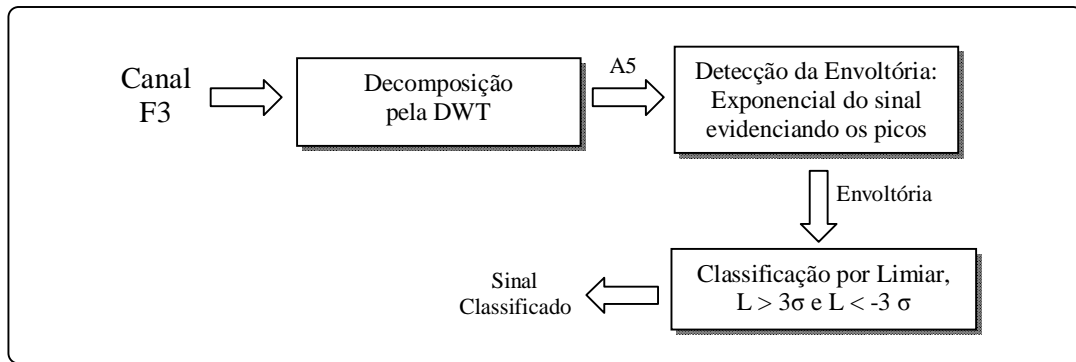


Figura 6.4 – Diagrama geral do algoritmo de eliminação de artefato de EOG. Fonte: autor.

Na Figura 6.5 pode-se observar um sinal adquirido no canal F3 de um voluntário que realizou 6 piscadas palpebrais mais intensas e foram totalmente eliminadas.




Figura 6.5 – Eliminação de artefato de EOG em um sinal de EEG: (a) sinal original com artefato e (b) sinal após eliminação do artefato. Fonte: autor.

Os artefatos de origem muscular foram eliminados seguindo os passos da sequência mostrada na Figura 6.6. O sinal resultante da classificação indica os trechos com esse tipo de artefato, que são eliminados de todos os canais utilizados.

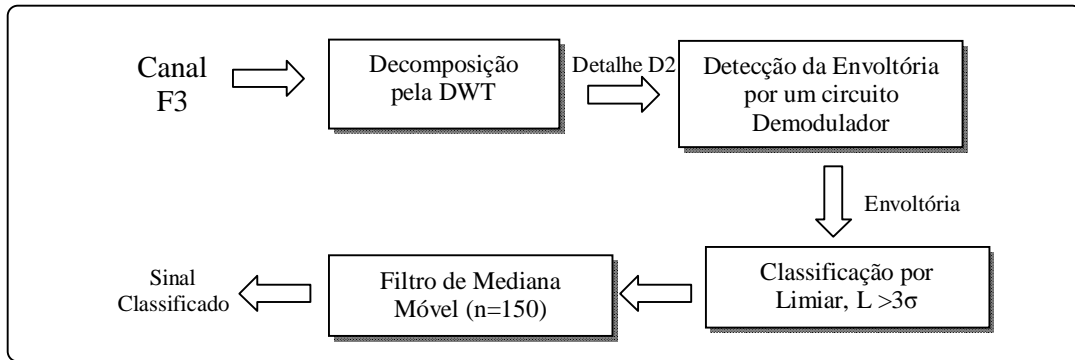


Figura 6.6 – Diagrama geral do algoritmo de eliminação de artefato de EMG. Fonte: autor.

Esse tipo de artefato aparece geralmente quando o indivíduo deglute saliva, ou realiza movimento com a cabeça ou pescoço. Um sinal com muito artefato muscular pode ser visualizado na Figura 6.7, bem como após sua eliminação. Durante a aquisição do sinal do voluntário que gerou a Figura 6.7, foi verificado que esse voluntário ao efetuar o movimento da mão realizava força excessiva, o que leva a contrair também, sem que o mesmo perceba, a musculatura da face, o que possivelmente gerou o artefato.




Figura 6.7 – Eliminação de artefato de EMG em um sinal de EEG: (a) sinal original com artefato, e (b) sinal após eliminação do artefato. Fonte: autor.

Após a eliminação dos dois tipos de artefatos nos canais de EEG originais, os sinais foram separados em trechos de 7s, correspondentes a EEG espontâneo, trecho com manobra de movimento ou de IM. Em seguida por meio de decomposição wavelet foram

extraídas as características relacionadas ao ritmo mi do EEG. Neste trabalho o método para a detecção do movimento e IM utiliza os padrões relacionados à dessincronização relacionada ao evento (ERD) que ocorre no ritmo mi quando um indivíduo se prepara para realizar esses eventos. Uma forma de visualizar a variação que ocorre no ritmo mi no decorrer do tempo é por meio do cálculo da energia, que neste trabalho foi calculada em uma janela de tamanho igual a 100 pontos percorrendo o sinal ponto a ponto. Observando a energia dos sinais adquiridos, detectou-se que nem sempre os voluntários conseguem produzir o padrão de dessincronização desejado durante a manobra de IM. Uma maneira de melhorar a produção do padrão desejado, para ser utilizado em uma ICM, é o uso de *feedback* durante a aquisição, para que o voluntário possa aprender a lidar com suas atividades cerebrais, de forma a serem reconhecidos pelos algoritmos. Na Figura 6.8 pode ser visualizada a variação de energia do ritmo mi capturado no canal C3, em um momento que o padrão de ERD foi gerado (a) e outro que não foi gerado (b).




Figura 6.8 – Energia do ritmo mi do canal C3 durante IM: (a) sinal que gerou padrão de ERD, e (b) não foi gerado. Fonte: autor.

Além da energia foi calculada a PSD do ritmo mi para a detecção da mão que realizou o movimento. Como os voluntários selecionados para este trabalho são destros é esperado grande lateralização da ERD do ritmo mi no período anterior ao movimento e IM da mão direita quando comparada com o da mão esquerda. Ou seja, existe uma diferença maior na potência do ritmo mi no hemisfério contralateral quando o indivíduo realiza uma manobra com seu membro dominante, conforme Figura 6.9. Já com canhotos, segundo PILLA JÚNIOR (1999) [84], é encontrada uma preponderância contralateral para atividade realizada com ambos os lados. Após as aquisições, a maioria dos voluntários comentou a maior facilidade em efetuar as manobras com a mão direita, com exceção de dois que disseram ter a mesma facilidade com ambas. Analisando a PSD de um desses dois voluntários observou-se que o comportamento, segundo PILLA JÚNIOR (1999) [84], era similar a de um canhoto, vide Figura 6.10. Esse voluntário foi contatado e o mesmo verificou com os familiares a possibilidade de ser canhoto. Duas informações fornecidas pelo voluntário levaram a crer na possibilidade dele ser canhoto e ter adquirido habilidades com as duas mãos: quando criança, ele foi instruído pela família a utilizar a mão direita; e o pai é canhoto.




Figura 6.9 – Voluntário destro. PSD calculada para os canais C3(azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.




Figura 6.10 – Possivelmente voluntário canhoto. PSD calculada para os canais C3(azul) e C4 (vermelho): (a) movimento da mão direita e (b) movimento da mão esquerda. Fonte: autor.

Neste trabalho as PSDs calculadas são interpretadas pelo SS, mesmo para o indivíduo possivelmente canhoto, o sistema funciona da mesma forma, obtendo acerto sempre que o indivíduo consegue produzir padrões de ERD. Foi calculado o percentual de acerto do SS para a mão direita durante o movimento e a IM, e da mesma forma para a mão esquerda, conforme Tabela 6.1.

Tabela 6.1– Resultado (percentual de acerto) da interpretação da mão de origem do movimento e da IM pelo sistema simbólico SS.

Mão de Origem	Movimento	Imaginação do Movimento
Mão Direita	59%	66%
Mão Esquerda	72%	74%

Os resultados da Tabela 6.1 demonstram que nem sempre ocorre a maior diminuição da potência, durante o movimento e IM, no hemisfério contralateral do cérebro. E apesar dos voluntários serem destros, ou seja, o lado dominante ser o direito, eles conseguiram produzir com maior frequência o padrão desejado, para uma análise da PSD, com a mão esquerda. Ainda, o SS possui maior percentual de acerto para a imaginação do

movimento da mão esquerda. Esses resultados demonstram que possivelmente a produção do padrão desejado, diminuição da potência do ritmo μ , está, também, relacionada ao nível de concentração que o indivíduo emprega ao efetuar uma atividade. Devido aos indivíduos serem destros, eles possuem uma maior facilidade em movimentar e imaginar o movimento da mão direita, tornando muitas vezes o movimento meio automático. Movimentar e principalmente imaginar o movimento da mão esquerda requer uma maior concentração. Uma melhor classificação pelo SS pode ser obtida com a utilização de um *feedback* para que o indivíduo aprenda a produzir os padrões desejados de PSD.

6.2 Resultados do Reconhecimento do Movimento e IM pelas RNAs desenvolvidas

Neste trabalho, o reconhecimento dos padrões de movimento e IM foram realizados com o auxílio de Redes Neurais Artificiais. Três tipos de RNAs foram desenvolvidas, uma estática e duas dinâmicas. Primeiramente foi projetada a rede estática, isto é, identificação da forma do padrão no plano. Nessa identificação, quando o processo é realizado *online*, a RNAE não é a mais adequada, pois a rede procura identificar uma imagem idêntica (ou semelhante) a treinada, o que não ocorre em vários registros.

Assim, passou-se a projetar um tipo de rede que não dependesse diretamente do padrão treinado, mas sim da dinâmica de variação desse padrão no tempo. Pois o padrão pode estar deslocado no tempo e mesmo assim, a rede possui a capacidade de identificar esse padrão como verdadeiro. As redes com dinâmica de entrada, conforme o trabalho de RODRIGUES (2002) [66], são mais adequadas a essa necessidade.

A primeira rede neural dinâmica (RNAD1) desenvolvida apresentou bons resultados na identificação de padrões variantes no tempo. Contudo, a rede foi treinada

com um número determinado de entradas referentes a dois voluntários, existindo a necessidade de adicionar novos padrões alvo e novos padrões de entrada para o reconhecimento de padrões de um novo indivíduo.

Com a finalidade de adequar os novos padrões de voluntários diferentes, foi projetada uma rede neural dinâmica (RNAD2) capaz de se auto retrainar com novos padrões, com a finalidade de se “adaptar” ao novo indivíduo, por meio de um novo treinamento, onde é considerado o treinamento anterior da rede e também os novos padrões para cada indivíduo.

A avaliação do desempenho de cada uma das redes é uma etapa importante no processamento dos sinais de EEG. O desempenho pode ser avaliado por meio da habilidade do algoritmo de discriminar entre dois grupos, por exemplo, movimento ou IM e repouso (EEG espontâneo ou basal). Esse comparativo é realizado tomando como base um “padrão ouro”, que indica onde ocorreu o evento. Geralmente esse “padrão ouro” é gerado por um especialista, porém quando esse especialista é humano sempre existirá um erro agregado [66]. Neste trabalho o sinal foi dividido em três tipos de trecho baseando-se no padrão ouro gerado pelo equipamento marcador, desenvolvido neste trabalho, que indica em que instante o evento deverá iniciar e finalizar. Levando em consideração que a ERD pode ocorrer até 2s antes e também existe o tempo entre o indivíduo perceber o estímulo visual e efetuar o evento, ou mesmo que o indivíduo efetue o evento no momento da preparação do evento. Assim, os trechos foram separados contabilizando 7s de duração, como já mencionado. Para teste das RNAs foram utilizados esses trechos referentes a movimento, IM e basal.

Neste trabalho os índices de desempenho utilizados para a análise dos resultados obtidos pelas RNAs, foram a sensibilidade, a especificidade e a eficiência.

Estes índices são calculados por meio dos dados relacionados aos sujeitos em estudo e os resultados dos testes realizados, representados pelos indicadores verdadeiro-positivos (VP), verdadeiro-negativos (VN), falso-positivos (FP) e falso-negativos (FN).

Sensibilidade: A sensibilidade é a capacidade de identificar positivos (padrões relacionados ao movimento ou a IM) entre os padrões verdadeiramente existentes. Ela é calculada segundo a Equação (6-1).

$$Sensibilidade(\%) = \frac{VP}{VP + FN} \times 100\%, \quad (6-1)$$

onde *VP* é a indicação da existência de um padrão de movimento ou IM quando este realmente existe. *FN* é a indicação da inexistência do movimento ou da IM quando estes existem.

Especificidade: A especificidade é a capacidade de identificar negativos (quando não existe movimento ou IM) entre os padrões verdadeiramente negativos ou inexistentes. Ela é calculada segundo a Equação (6-2):

$$Especificidade(\%) = \frac{VN}{VN + FP} \times 100\%, \quad (6-2)$$

onde *VN* é a indicação da existência de um padrão que não é movimento ou IM, ou seja, basal, quando este realmente existe. *FP* é a indicação da existência do movimento ou da IM quando estes não existem.

Eficiência: A eficiência indica a probabilidade de uma medida estar correta. É a concordância global dos resultados verdadeiros positivos e negativos quando ocorre movimento ou IM e quando não ocorre. O índice de eficiência é calculado a partir da Equação (6-3).

$$Eficiência(\%) = \frac{VP + VN}{VP + FP + VN + FN} \times 100\% \quad (6-3)$$

6.2.1 Análise da RNAE

A RNAE foi treinada com cinco padrões de entrada, 2 padrões para a identificação de casos típicos de movimento (os mesmos para IM) , e três referentes a EEG espontâneo. A seleção desses padrões foi realizada em dois trechos, referentes a dois indivíduos, que ocorreram manobra de movimento. A rede detecta a variação que ocorre na ERD e na ERS baseado na imagem “fotográfica” dos padrões de entrada aprendidos.

Essa rede, conforme mencionado no Capítulo 5, possui 30 neurônios de entrada. Apesar da rede ser estática o reconhecimento foi realizado de forma dinâmica, simulando um processamento *online*. Logo, a análise do sinal é realizada em uma janela de tamanho 30 pontos que se desloca ponto a ponto no sinal. A cada janela a RNAE gera uma saída com valores entre 0 e 0,9, sendo 0,9 quando encontra o padrão de movimento ou IM, devido ao fato da rede ser estática, esta precisa ser igual (ou muito semelhante) ao padrão treinado. Quando o sinal corresponde a EEG espontâneo a saída é 0. Porém mesmo sendo estática, possui poder de generalização, colocando valores entre 0 e 0,9 de acordo com a similaridade com os padrões treinados referentes a esses padrões. Na Figura 6.11 pode ser observado o ponto de saída da rede dentro da janela em dois instantes, em (a) e (b) em azul tem-se o sinal original que está sendo percorrido pela janela em vermelho, em (c) e (d) mostra os pontos de saída da rede neural. O sinal da Figura 6.11 utilizado para o reconhecimento é de um voluntário diferente dos utilizados para o treinamento da rede.

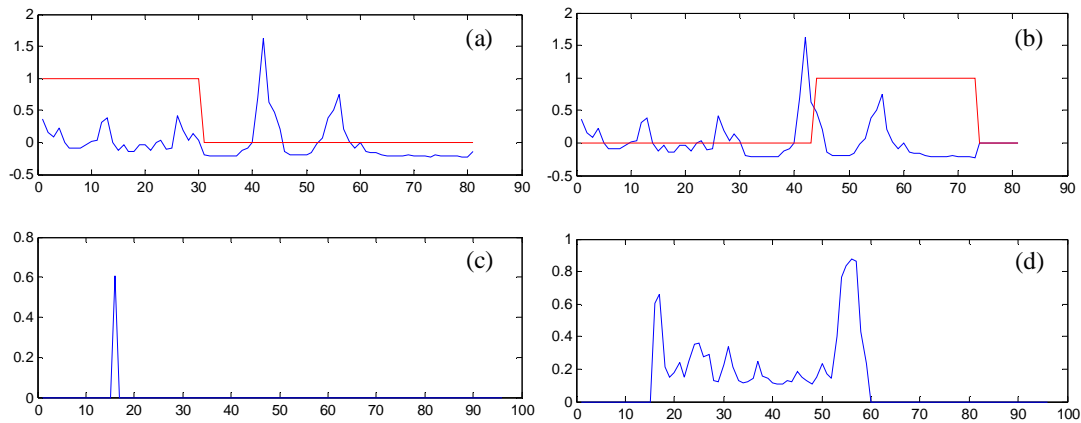


Figura 6.11 – Exemplo de reconhecimento pela RNAE: (a) e (b) em azul o sinal original a ser analisado, e em vermelho a janela percorrendo o sinal, e em (c) e (d) os pontos de saída da rede gerados janela a janela. Fonte: autor.

Com o intuito de analisar o valor de saída da rede foi criado um Sistema Simbólico (SS2) [66] baseado em regras, a fim de identificar a presença ou não de um padrão de movimento ou IM. Neste sistema foi criado um limiar de 70%, ou seja, se a saída da rede for maior que 0,7 significa que um padrão de movimento ou IM foi encontrado. Para análise dos resultados foram geradas duas tabelas, uma apenas para fins de armazenar os pontos de saída da rede e a segunda para fins de análise. As tabelas foram geradas automaticamente e possuem todos os resultados de saída da rede para cada arquivo, de cada voluntário. A segunda tabela possui a informação do nome do arquivo e o resultado do algoritmo de análise da saída da RNAE. A essa tabela foram acrescentadas colunas de análise dos dados para calcular os VP, VN, FP e FN com a finalidade de se obter a sensibilidade, a especificidade e a eficiência da RNAE. Um exemplo pode ser visualizado na Tabela 6.2. A tabela com os resultados da análise para a RNAE pode ser verificada na Tabela 6.3.

Tabela 6.2– Parte da tabela gerada automaticamente pelo algoritmo de análise de saída da RNAE, acrescentando as colunas de análise dos dados.

Nome do arquivo	Resultado do Limiar	VP	VN	FN	FP
Vol1_1_1_1_M_1	Mov ou IM	X			
Vol1_1_1_1_I_2	Mov ou IM	X			
Vol1_1_1_1_Basal1	Basal		X		
Vol1_1_1_1_M_3	Basal			X	
Vol1_1_1_1_I_4	Mov ou IM	X			
Vol1_1_1_1_Basal2	Mov ou IM				X

Tabela 6.3– Resultado da análise dos resultados do reconhecimento realizado pela RNAE.

Número de:	VP	VN	FN	FP
Total	1288	208	280	1280
Sensibilidade				82%
Especificidade				14%
Eficiência				49%

A RNAE obteve boa sensibilidade, ou seja, conseguiu detectar de forma eficiente as atividades de movimento e IM. Porém não obteve bons resultados em relação à detecção de EEG basal, indicado pela baixa especificidade. Essa baixa especificidade se deve aos padrões serem variantes no tempo e a rede ser estática. Sua característica estática se baseia na procura por “fotos”, isso gerou no caso do EEG basal poucos VN. Mostrando assim a necessidade da implementação de uma rede dinâmica.

6.2.2 Análise da RNAD1

A RNAD1 foi treinada com a energia média de dois dos voluntários, que conseguiram produzir os padrões de movimento (IM) de forma satisfatória. Esses sinais de entrada compreendem um conjunto de vetores padrão. Neste vetor o padrão de movimento possui 27 pontos, como o tamanho do sinal é de 81 pontos, foi gerado um padrão desejado composto por 3 vetores de tamanho 27, que assumem valores de 0 e 0,9 para EEG basal e movimento ou IM, respectivamente. Nota-se que a rede detecta a variação que ocorre na ERD e na ERS de forma mais eficiente do que uma rede estática, devido ao “aprendizado”

da dinâmica dos pontos.

Essa rede, conforme mencionado no Capítulo 5, possui 40 neurônios de entrada, ou seja, o treinamento é realizado janela a janela, com tamanho de janela igual a 40 pontos deslocando ponto a ponto. Da mesma forma que a RNAE, ocorre o reconhecimento dinamicamente, simulando um processamento *online*. A cada janela a RNAD1 gera uma saída com valores entre 0 e 0,9, sendo 0,9 quando ela encontra um padrão de movimento ou IM, e 0 para EEG espontâneo. Porém, no reconhecimento, os padrões de entrada identificados como atividade de movimento ou IM não necessariamente são iguais aos treinados, mas que possuam a mesma dinâmica de pontos ou similar, devido ao seu poder de generalização, colocando valores entre 0 e 0,9 de acordo com a similaridade com os padrões treinados.

Após o término da etapa de treinamento é necessário um algoritmo capaz de analisar o vetor de saída da rede, a fim de identificar a presença ou não de um padrão de movimento. Neste trabalho optou-se pela utilização da análise da média em um segmento de 10 pontos, e assim informar se o valor da média situa-se entre o valor desejado. Este valor desejado é chamado de sensibilidade da RNAD e possui a finalidade de criar um limiar na identificação destes padrões. Para essa rede foi adotado um valor de sensibilidade igual a 90%, isto é, um padrão somente irá ser identificado como padrão de movimento ou IM se o valor de saída do “filtro” ultrapassar um valor de 0,90, sabendo-se que o máximo é de 1 ou 100%.

Na Figura 6.12a pode ser observada a saída da rede em vermelho, e o sinal em azul é referente ao padrão de entrada. Na Figura 6.12b e Figura 6.12c o reconhecimento do sinal de outros voluntários. Porém o reconhecimento não é tão efetivo para outros indivíduos.




Figura 6.12 – Exemplo de reconhecimento pela RNAD1, estando em vermelho a saída da rede e em azul o sinal de entrada: (a) sinal original, (b) e (c) sinais de outros dois voluntários. Fonte: autor.

Foram geradas duas tabelas, uma apenas para fins de armazenar os pontos de saída da rede para posterior visualização dos resultados da rede. As tabelas foram geradas automaticamente e possuem todos os resultados de saída da rede para cada arquivo de cada voluntário. A segunda tabela possui a informação do nome do arquivo e o resultado do algoritmo de análise da saída da RNAD1. A essa tabela foram acrescentadas colunas de análise dos dados para se obter a sensibilidade, a especificidade e a eficiência da RNAD1, por meio do cálculo dos VP, VN, FP e FN. Os resultados finais da análise podem ser visualizados na Tabela 6.4.

Tabela 6.4 – Resultado da análise dos resultados do reconhecimento realizado pela RNAD1.

Número de:	VP	VN	FN	FP
Total	1248	952	328	528
Sensibilidade			79%	
Especificidade			64%	
Eficiência			72%	

Comparando-se a Tabela 6.3 com a Tabela 6.4 observa-se uma maior eficiência no reconhecimento quando utilizada a RNAD1 em relação à RNAE. Apesar de sua menor sensibilidade, possivelmente devido ao treinamento ter sido efetuado apenas para padrões de dois voluntários, sua especificidade foi substancialmente maior que a da RNAE, ou seja, teve uma maior detecção de VN, o que significa maior qualidade no reconhecimento nos trechos de EEG basal, quando comparado a RNAE. Essa maior eficiência se deve a forma do treinamento que é realizado de forma dinâmica.

6.2.3 Análise da RNAD2

A RND2 possui duas unidades de treinamento, e cada unidade possui as características básicas similares a RNAD1, como mencionado no Capítulo 5. A sua unidade de treinamento principal, que funciona como “memória” do sistema, foi treinada com a energia média de cinco dos voluntários. O sinal de entrada compreende um conjunto de vetores padrão. Da mesma forma que na RNAD1 o padrão de movimento neste sinal possui 27 pontos, como o tamanho do sinal é de 81 pontos, foi gerado um padrão desejado composto por 3 vetores de tamanho 27 para cada voluntário, que assumem valores de 0 e 0,9 para EEG basal e movimento ou IM, respectivamente. A RNAD2 tem por objetivo proporcionar uma maior eficiência, se comparada com a que a RNAD1. Não só por possuir uma maior quantidade de padrões de entrada, mas pela capacidade de adaptação, com os sinais de voluntários diferentes durante o processo *online*. E até mesmo a adaptação de um

mesmo indivíduo em utilizações com características diferentes da anterior.

A unidade principal, bem como as posteriores unidades de treinamento possui 40 neurônios de entrada, ou seja, o treinamento é realizado janela a janela de tamanho 40 pontos sendo deslocada ponto a ponto. Da mesma forma, ocorre no reconhecimento que é realizado dinamicamente, simulando um processamento *online*. A cada janela a RNAD2 gera uma saída com valores entre 0 e 0,9, sendo 0,9 quando ela encontra um padrão de movimento ou IM, e 0 para EEG espontâneo, da mesma forma que a RNAD1.

Para o treinamento da unidade principal foram utilizados os sinais da sessão 1 do primeiro dia de teste de 5 voluntários. Para cada voluntário novo a média dos trechos de movimento de sua primeira sessão é acrescentada como padrão de entrada e a rede é retreinada. Essa passa a ser a unidade principal especificamente para esse indivíduo. Neste trabalho foram feitos testes para todos os voluntários, incluindo os 5 que não fizeram parte do treinamento. Em seguida é realizada a calibração e a validação da nova rede, utilizando o registro da segunda sessão, conforme Figura 6.13, onde metade do número de trechos é adicionada, separadamente, a unidade principal que ganha mais um padrão de entrada para ser retreinada.

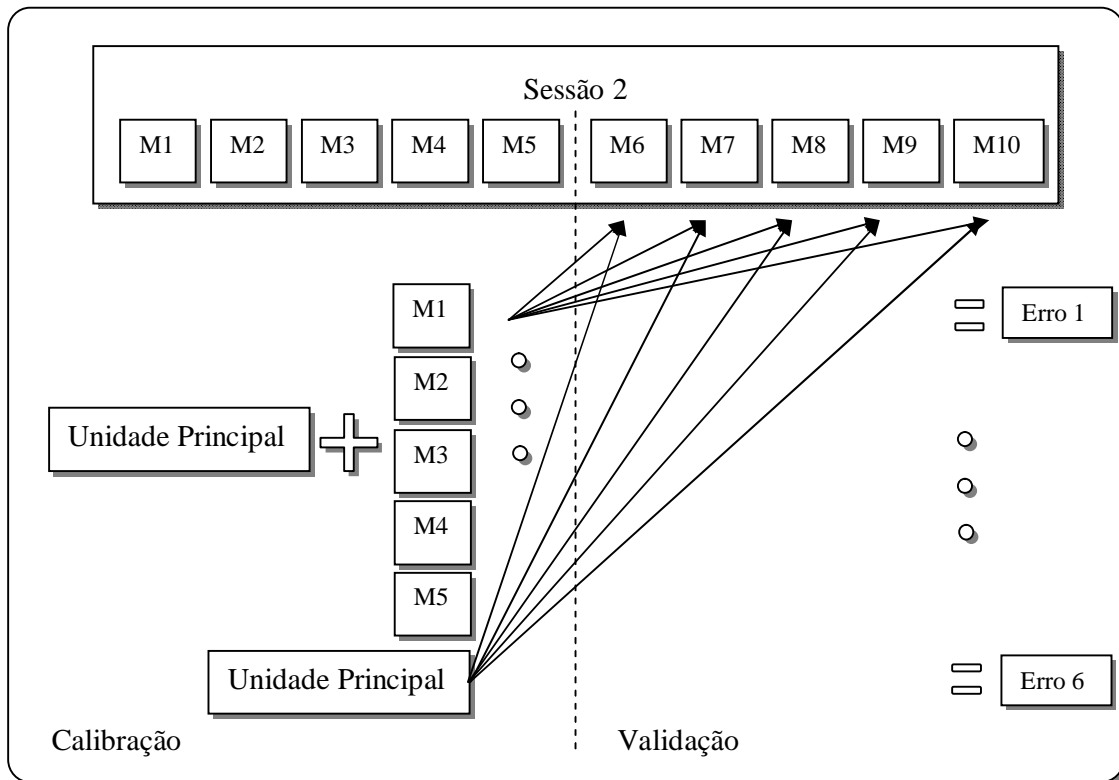


Figura 6.13 – Processo de calibração e validação da RNAD2. Fonte: autor.

As 6 redes treinadas no processo de calibração são validadas com os trechos da segunda metade do registro da segunda sessão. Como mencionado no Capítulo 5, a rede que obteve menor erro no reconhecimento foi adotada para a utilização no reconhecimento dos padrões em todos os registros daquele indivíduo, enquanto a aquisição possuir as mesmas características.

Todo o treinamento foi realizado de forma automática. Após o término da etapa de treinamento foi realizada a validação da rede por meio do reconhecimento nos diversos registros. No processo de reconhecimento é necessário um algoritmo capaz de analisar o valor de saída da rede, a fim de identificar a presença ou não de um padrão de movimento. Nesta rede optou-se pela utilização da análise da média em um segmento de 10 pontos, e assim informar se o valor da média situa-se entre o valor desejado, da mesma forma que se utilizou na RNAD1. Este valor desejado é chamado de sensibilidade da RNAD2 e possui a

finalidade de criar um limiar na identificação destes padrões. Para essa rede foi adotado, também, um valor de sensibilidade igual a 90%, isto é, um padrão somente irá ser identificado como padrão de movimento ou IM se o valor de saída do “filtro” ultrapassar um valor de 0,90, sabendo-se que o máximo é de 1 ou 100%.

Na Figura 6.14a pode ser observada a saída, em vermelho, do reconhecimento realizado para um sinal de voluntário que participou do treinamento pela unidade principal inicial. Na Figura 6.14b o reconhecimento para o mesmo voluntário, porém no segundo dia de aquisição, ou seja, após recalibração. Na Figura 6.14c e Figura 6.14d o reconhecimento do sinal de outro voluntário, para o primeiro dia de teste, quando ele é um novo indivíduo para o sistema e adquiriu sua unidade principal específica, e no segundo dia de teste, após a recalibração do sistema, respectivamente.




Figura 6.14 – Exemplo de reconhecimento pela RNAD2, estando em vermelho a saída da rede e em azul o sinal de entrada: (a) voluntário que participou do treinamento inicial, (b) dia diferente para o voluntário (a), (c) e (d) outro voluntário para o primeiro e para o segundo dia. Fonte: autor.

Foram gerados dois tipos de tabelas, uma apenas para fins de armazenar os pontos de saída da rede para posterior visualização e a segunda para fins de análise. As tabelas foram geradas automaticamente e possuem todos os resultados de saída da rede para cada arquivo de cada voluntário. O segundo tipo de tabela possui a informação do nome do arquivo e o resultado do algoritmo de análise da saída da RNAD2. A essa tabela foram acrescentadas colunas de análise dos dados para se obter a sensibilidade, a especificidade e a eficiência da RNAD2, por meio do cálculo dos VP, VN, FP e FN. Na Tabela 6.5 pode ser visualizado o resultado da análise geral de todas as saídas da RNAD2.

Tabela 6.5 – *Resultado geral da análise dos resultados do reconhecimento realizado pela RNAD2, para ambos os dias de teste.*

Número de:	VP	VN	FN	FP
Total	1352	1000	224	480
Sensibilidade				86%
Especificidade				68%
Eficiência				77%

Observando a Tabela 6.5 percebe-se a maior eficiência da RNAD2 quando comparada as outras redes desenvolvidas. A RNAD2 obteve uma maior sensibilidade devido a sua maior detecção de VP, ou seja, conseguiu identificar de forma mais eficiente quando ocorreu movimento e IM. Ainda obteve maior especificidade devido a sua maior detecção de VN, ou seja, conseguiu maior qualidade na classificação também para os trechos de EEG basal. Isso se deve ao processo de treinamento ser de forma dinâmica e a sua adaptação para cada novo indivíduo e a calibração que ocorre a cada vez que o sistema é reconectado ao indivíduo.

Resultados melhores podem ainda ser obtidos para as três redes desenvolvidas utilizando o sistema de forma *online*. Pois com um *feedback* para o usuário, ele poderá aprender a lidar com suas atividades cerebrais diminuindo o número de Falsos Positivos

(FP). Os FP estão relacionados à detecção pelo sistema de movimento ou IM no momento de EEG basal (sem movimento). Todos os voluntários comentaram da dificuldade de se manter sem pensar em nada durante os 10s de EEG basal, e alguns comentaram imaginar nesse período de tempo a IM que fariam no momento seguinte. Assim, os FP detectados não são em sua totalidade reais. Mais uma vez se confirma que a melhoria da qualidade de um sistema de ICM, principalmente quando se utiliza IM, pela utilização de um processamento *online*.

CAPÍTULO 7

Conclusão e Trabalhos Futuros

Uma interface cérebro máquina (ICM) é um sistema de comunicação em que mensagens ou comandos são enviados por um indivíduo ao meio externo sem passar através do caminho normal da informação. Uma ICM provê um método alternativo de interação com o meio, tendo como objetivo principal auxiliar pessoas que possuem dificuldade motora, ou nenhuma atividade muscular decorrente de alguma doença ou acidente. Hoje a aquisição e processamento de sinais de EEG é o método não invasivo e de mais baixo custo que vem sendo estudado por diversos grupos de pesquisa para uma ICM.

Nesta tese foi apresentado um sistema de processamento de sinal de EEG *off-line* para detecção do movimento e IM das mãos. Foram realizadas aquisições de sinais de EEG, em seguida algoritmos de pré-processamento foram utilizados para melhoria da relação sinal ruído e extração de características, e por último um processamento para reconhecimento de padrões.

A aquisição dos sinais foi realizada no córtex suplementar F3 e F4 e córtex pré-motor C3 e C4, e região parietal P3 e P4, utilizando o sistema internacional 10-20 de posicionamento dos eletrodos. Foi realizado um total de 80 registros, que foram particionados em 3056 trechos para cada canal.

Nesta tese foram apresentados os métodos utilizados no pré-processamento digital dos sinais de EEG. Por meio de técnicas de eliminação de artefatos de alta intensidade

relacionados a movimento ocular ou piscada palpebral, e artefato muscular, esses tipos de artefato foram eliminados com eficiência aumentando a relação sinal/ruído sem a necessidade da eliminação total dos trechos. O sinal dos canais C3 e C4 de EEG foram separados em seus ritmos pela DWT para a extração da característica relacionada ao ritmo μ . Com o objetivo de detectar ERD e ERS quando ocorre movimento ou IM, foi calculada a energia do ritmo μ do sinal, obtendo sua variação no decorrer do tempo. Ainda foi calculada a PSD do ritmo μ em C3 e C4 e uma comparação foi realizada por um sistema simbólico SS que determinou de que hemisfério se originou o movimento ou IM.

Os algoritmos de processamento desenvolvidos, baseados em RNAs, foram apresentados e comparados com o objetivo de detectar o melhor tipo de rede, entre as três, que possui maior eficiência no reconhecimento do movimento e IM. As RNADs se mostraram mais eficientes que a RNAE, 49%, por identificar os padrões de forma variante no tempo. Entre as duas redes dinâmicas, a RNAD2 (77%) se mostrou mais eficiente que a RNAD1(72%) devido a seu poder adaptativo relacionado a novos usuários de um sistema de ICM, e ainda se adaptar cada vez que o sistema é reconectado por meio de uma rápida recalibração.

Os resultados advindos deste trabalho, poderão ser usados em uma implementação de ICM *online*, sem a necessidade de muitas repetições do evento pelo indivíduo. Permitirão aumentar a adequação dos modelos e métodos já existentes, de maneira que a aplicabilidade da ICM se torne ainda mais eficiente.

Como contribuições principais desse trabalho tem-se a forma de eliminar os artefatos, o fato de utilizar apenas um trecho para o reconhecimento dos padrões de movimento e IM das mãos, e a introdução da utilização de RNAs dinâmicas no reconhecimento desses padrões. Ainda o desenvolvimento de uma RNA dinâmica

adaptativa, RNAD2, que ao se adaptar a novos indivíduos levando consigo a “memória” de treinamentos anteriores, obtém uma maior eficiência no reconhecimento dos padrões. Essa rede não é útil apenas para reconhecimento de padrões de movimento e IM, ela pode ser utilizada em uma gama muito mais vasta de sinais variantes no tempo, por exemplo, sinais de voz, ou mesmo em um sinal de EEG para auxílio em diagnóstico.

Como trabalhos futuros pretende-se utilizar um número maior de eletrodos e realizar uma filtragem espacial para melhoria da detecção dos padrões. Ainda, pretende-se implementar o algoritmo de pré-processamento e RNAD em *hardware*, em conjunto com o grupo de pesquisa em EEG e Realidade Virtual do GPEB da UFPE. Ainda gerar um *feedback* em tempo real para o voluntário, para que o mesmo possa aprender a lidar com suas atividades cerebrais, e como consequência melhorar a qualidade do reconhecimento dos padrões.

Referências

- [1] DUTTON, M., *Guia de sobrevivência do fisioterapeuta, Manejando condições comuns*, 2012.
- [2] ROSA, I. G., *Detecção Automática De Contração Muscular Utilizando A Eletromiografia De Superfície*, Tese de Doutorado, UFRJ, Rio de Janeiro, 2005.
- [3] KANSKI, J., J., BOWLING, B., *Oftalmologia Clínica, uma abordagem sistemática*, tradução da 7ª edição, Elsevier editora Ltda., 2012.
- [4] SANTOS FILHO, S. A., PROVENZANO, F., CAMÊLO, P., M., XAVIER, P., A., M., TIERRA-CRIOLLO, C., J., *Acionamento De Uma Garra Mecânica Por Meio Do Eletrooculograma*, 21º Congresso Brasileiro de Engenharia Biomédica, ISBN: 978-85-60064-13-7, 2008.
- [5] LIMA, L. A., DAHER D. V., LAMOUNIER JR., E. A., ANDRADE, A. O., *Sistema Baseado Em Eletrooculograma Para Controle De Dispositivos Computacionais*, VI Conferência de Estudos em Engenharia Elétrica (CEEL), Minas Gerais, 2008.
- [6] KANDEL, E., R., SCHWARTZ, J., H., JESSELL, T., M., *Principles of Neural Science*, 4ª Edição, 2000.
- [7] RODRIGUES, M., A., B., CUNHA, I., P., ANDRIANI, V., M., A., NETO, J., M., AZEVEDO, F., M., *Uma rede neural dinâmica para a identificação de padrões eletrográficos*. II Congresso Latino Americano de Ingeniería Biomédica, Habana, Cuba, 2011.
- [8] PINTO, L., C., *Neurofisiologia Clínica, Princípios Básicos e Aplicações*, 2ª Edição, Atheneu, 2010.
- [9] CHIEIA, M., A., T., *Doenças do Neurônio Motor(Motor Neuron disease)*. Revista de Neurociências V13 N3 (supl-versão eletrônica), jul/set, 2005.
- [10] DEFINO, H. L. A., *Trauma Raquimedular*, Simpósio: TRAUMA II, Capítulo II, Medicina, Ribeirão Preto, 32: 388-400, out./dez., 1999.
- [11] SIMPSON, R., C., *Smart Wheelchairs: A Literature Review*. Journal of

- Rehabilitation Research & Development, v. 42, p. 423-436, 2005.
- [12] GUYTON, HALL, *Tratado de Fisiologia Médica*, Tradução da 11ª Edição, Elsevier, 2006.
- [13] BARR, R.C., *Basic electrophysiology*, in *The Biomedical Engineering Handbook*, Bronzino J., Ed. Boca Raton, CRC Press, pp. 101-118, 1995.
- [14] HENNEBERG, K.A., *Principles of electromyography*, in *The Biomedical Engineering Handbook*, Bronzino J., Ed. Boca Raton, CRC Press, pp. 191-200, 1995.
- [15] SILVA, I. S. S., *Circuitos Mistos Reconfiguráveis Aplicados a Medição de Sinais Biomédicos: Rejeição de Interferência de Modo Comum*, Tese de Doutorado, Universidade Federal de Campina Grande, Paraíba, 2003.
- [16] MANUAL: 10/20 System Positioning, Trans Cranial Technologies Ltd, 2410 Fortis Tower, 77-79 Gloucester Road, Wanchai, Hong Kong, http://www.transcranial.com/local/manuals/10_20_pos_man_v1_0_pdf.pdf, acessado em 10/08/2013.
- [17] COLLURA, T., F., *History and Evolution of Electroencephalographic Instruments and Techniques*, Journal of Clinical Neurophysiology, 10(4);476-504, Raven Press, Ltd, New York, 1993.
- [18] PHAN, K., L., WAGER T., TAYLOR S., F., LIBERZON I., *Functional Neuroanatomy of Emotion: A Meta-Analysis of Emotion Activation Studies in PET and fMRI*, Elsevier, NeuroImage, Volume 16, Issue 2, June 2002, Pages 331–348, 2002.
- [19] HINTERBERGER, T., WIDMAN, G., LAL, T., N., HILL, J., TANGERMANN, M., ROSENSTIEL, W., SCHÖLKOPF B., ELGER C., BIRBAUMER, N., *Voluntary brain regulation and communication with electrocorticogram signals.*, Elsevier, Epilepsy & Behavior, Volume 13, Issue 2, August 2008, Pages 300–306, 2008.
- [20] LOTZE, M., MONTOYA, P., ERB, M., HÜLSMANN, E., *Activation of Cortical and Cerebellar Motor Areas during Executed and Imagined Hand Movements: An fMRI Study*, Journal of Cognitive Neuroscience 11:5, pp. 491–501, Massachusetts Institute of Technology, 1999.
- [21] NEUPER, C.; PFURTSCHELLER, G. *Motor imagery and ERD*. in: G. Pfurtscheller, F.H. Lopes da Silva (Eds.), *Event-related Desynchronization*, Revised edition. Handbook. Electroencephalogr. Clin. Neurophysiol., v.6, Elsevier, Amsterdam, p.303-325, 1999.
- [22] LAFLEUR, K., CASSADY, K., DOUD, A., SHADES, K., ROGIN, E., HE, B., *Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain–computer interface*, Journal of Neural Engineering, J. Neural Eng. 10

(2013) 046003 (15pp), 2013.

- [23] PFURTSCHELLER, G., BRUNNER, C., SCHLÖGL, A., LOPES DA SILVA, F. H. *Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery task*. NeuroImage. v.33, n.1, p.153-159, 2006.
- [24] PFURTSCHELLER, G. *Quantification of ERD and ERS in the time domain*. in: G. Pfurtscheller, F.H.; Lopes da Silva (Eds.), Event-related Desynchronization, Revised edition. Handbook. Electroencephalogr. Clin. Neurophysiol., v.6, Elsevier, Amsterdam, p.89-105, 1999.
- [25] PASCUAL-LEONE, A., AMEDI, A., FREGNI, F., MERABET, L. B., *The Plastic Human Brain Cortex*. Annual Review of Neuroscience. v.28, p.377-401, 2005.
- [26] NEUMANN, N., KÜBLER, A., *Training Locked-in Patients: A Challenge for the Use of Brain-Computer Interfaces*. IEEE Trans. Neur. Syst. Rehab. Eng. v.11, n.2, p.169-172, 2003.
- [27] GODÓI, A. C. B., *Detecção de Potenciais Evocados P300 para Ativação de uma Interface Cérebro Máquina*, dissertação de mestrado em engenharia, São Paulo, 2010.
- [28] DONCHIN, E., et al., *Event Related Brain Potentials in the study of consciousness, Consciousness and Self-Regulation*, v. 3, Plenum, New York, p.-121, 1983.
- [29] WOLPAW, J. R.; MCFARLAND, D. J.; VAUGHAN, T. M., *Brain computer-interface research at the Wadsworth Center*. IEEE Trans. Rehab. Eng., v.8, n.2, p.222-226, 2000.
- [30] BIRBAUMER, N., *Slow Cortical Potentials: Plasticity, Operant Control, and Behavioral Effects*, Neuroscientist, v. 5, n.2, p.74-78, 1999.
- [31] LEBEDEV, M. A.; NICOLELIS M. A. L. *Brain-machine interfaces: past, present and future*. Trends in Neurociences, v.29, n.9, p.536-546, 2006.
- [32] FETZ, E.E. *Operant conditioning of cortical unit activity*. Science, v.163, n. 3870, p.955-958, 1969.
- [33] NICOLELIS, M. A.; RIBEIRO, S. *Multielectrode recordings: the next steps*. Current Opinion in Neurobiology, v.12, n. 5, p.602-606, 2002.
- [34] VIDAURRE, C., SCHLÖGL, A., CABEZA, R., SCHERER, R., PFURTSCHELLER, G., *A fully on-line adaptive BCI*. IEEE Transactions on Biomedical Engineering, 53(6):1214–1219, Junho, 2006.

- [35] SANTOS FILHO, S. A., *Magnitude Quadrática da Coerência na Detecção da Imaginação do Movimento para Aplicação em Interface Cérebro-Máquina*, Tese de Doutorado, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.
- [36] OMIDVARNIA, A. H., ATRY, F., SETAREHDAN, S. K., ARABI, B. N., *Kalman filter parameters as a new EEG feature vector for BCI applications*, 13th European Signal Processing Conference, 2005.
- [37] HUANG, H. S., PAL, N. R., KO, L. W., LIN, C. T., *Automatic Identification of Useful Independent Components with a View to Removing Artifacts from EEG Signal.*, Proceedings of International Joint Conference on Neural Networks, Atlanta, Georgia, 2009.
- [38] TIERRA-CRIOLLO, C. J., *Monitorização Objetiva da Resposta à Estimulação Somato-Sensitiva Utilizando Parâmetros Espectrais*, Tese (Doutorado em Ciências)-COPPE/UFRJ, Rio de Janeiro, Brasil, 2001.
- [39] LOTTE, F., CONGEDO, M., L'ECUYER, A., LAMARCHE, F., ARNALDI, B., *A review of classification algorithms for EEG-based brain-computer interfaces*, Journal of Neural Engineering, 4, R1-R13, 2007.
- [40] YUGE, S.; NING, Y., LIHONG, Z., XINHE, X., *Research on feature extraction Algorithms in BCI*, Chinese Control and Decision Conference, pp. 4294-4298, 2008.
- [41] HAN, J., 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, Vol. 1, pp.428, 1999.
- [42] LEE, T. W., GIROLAMI, M., 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.
- [43] TING, W.; GUO-ZHENG, Y., BANG-HUA, Y., HONG, S., *EEG feature extraction based on wavelet packet decomposition for brain computer interface*. Measurement, Vol. 41 (6), pp. 618-625, 2008.
- [44] ANDERSON, C. W., STOLZ, E. A., SHAMSUNDER, S., *Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks*. IEEE Trans Biomed Eng., Vol.45(3), pp. 277-286, 1998.
- [45] PAUH, PERLIS, MALAYSIA, *Recognizing Motor Imagery using Dynamic Cascade Feed-forward Neural Networks*, 6th International Colloquium on Signal Processing & Its Applications (CSPA), 2010.
- [46] PALANIAPPAN, R., PARAMESRAN, R., NISHIDA, S., SAIWAKI, N., *A New Brain-Computer Interface Design Using Fuzzy ARTMAP*, IEEE Transactions on

Neural Systems and Rehabilitation Eng., Vol. 10 (3), pp. 140-148, 2002.

- [47] GARRETT, D., PETERSON, D. A., ANDERSON, C. W., THAUT, M. H., *Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification*, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 11 (2), pp. 141-144, 2003.
- [48] GYSELS, E., CELKA, P., *Phase Synchronization for the Recognition of Mental Tasks in Brain Computer Interface*, IEEE Trans. Neural and Rehab. Eng., Vol. 12 (4), pp. 406-415, 2004.
- [49] CHIAPPA, S., BENGIO, S., *HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems*, European Symposium on Artificial Neural Networks, Bruges (Belgium), pp. 199-204, 2004.
- [50] CHIAPPA, S., BARBER, D., *EEG classification using generative independent component analysis*, Neurocomputing, Vol.69, pp.769-777, 2006.
- [51] AHMADI, M., ERFANIAN, A., *An On-Line BCI System for Hand Movement Control Using Real-Time Recurrent Probabilistic Neural Network*. Proceedings of the 4th International IEEE EMBS Conference on Neural Engineering, Antalya, Turkey, 2009.
- [52] OZMEN, N. G., GUMUSEL, L., *Classification of real and imaginary hand movements for a BCI design*, IEEE, 2013.
- [53] ADDISON, P., S., *The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance*. New York: Taylor & Francis Group, 2002.
- [54] DE OLIVEIRA, H. M., *Análise de Sinais para Engenheiros – Uma abordagem via Wavelets*, Editora Brasport. Sociedade Brasileira de Telecomunicações, 2007.
- [55] DE OLIVEIRA, H. M., *Análise de Fourier e Wavelets: Sinais Estacionários e não Estacionários*, Editora Universitária, UFPE, 2007.
- [56] DAUBECHIES, I., *Orthonormal Bases of Compactly Supported Wavelets*, Communications on Pure and Applied Mathematics., vol. 41, pp.909-996, 1988.
- [57] BANG-HUA, Y., GUO-ZHENG, Y., RONG-GUO, Y., TING, W., *Adaptive subject-based feature extraction in brain-computer interfaces using wavelet packet best basis decomposition*. Med. Eng. & Physics., v.29, p. 48-53, 2007.
- [58] MATHWORKS Inc. URL: <http://www.mathworks.com/>. Visitado em 10/08/2013.

- [59] OPPENHEIM, A.V., SCHAFER, R.W., *Discrete-Time Signal Processing*, Second Edition, London: Prentice-Hall International, 1999.
- [60] WELCH, P., D., *The use of fast Fourier transforms for the estimation of power spectra: A method based on time averaging over short modified periodograms*. IEEE Transactions on Audio and Electroacoustics, vol.15, pp. 70-73, 1967.
- [61] BRAGA, A., P., CARVALHO, A., P., L., F., LUDERMIR,, T., B., *Redes Neurais Artificiais*, 2^a edição, Editora LTC, 2007.
- [62] GUPTA, M. M., JIN, L., HOMMA, N., *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*, IEEE PRESS, WILEY-ITERSCIENCE, 2003.
- [63] HAYKIN, S., *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman, 2001.
- [64] MINSKY, M. L., PAPERT, S., A., *Perceptrons: An Introduction to Computational Geometry*, The MIT Press, 1969.
- [65] DE AZEVEDO, F. M., *Contribution to the Study of Neural Networks in Dynamical Expert System*. Tese de Doutorado, Institut d'Informatique, FUNDP, Namur, Bélgica, 1993.
- [66] RODRIGUES, M. A. B., *Sistema Para Detecção E Classificação Automática De Apnéias Do Sono A Partir De Registros Polissonográficos*, Tese de Doutorado, Universidade Federal de Santa Catarina, fevereiro, 2002.
- [67] EDFbrowser. URL: <http://www.teuniz.net/edfbrowser/>. Visitado em 10/08/2013.
- [68] STECKLOW, M. V., *Imagética Motora Em Tarefa Complexa: Análise Na Banda Alfa Do Eletroencefalograma*, Dissertação de Mestrado, UFRJ, Rio de Janeiro, 2006.
- [69] KASTELEIJN-NOLST TRENITE, D.G., DA SILVA, A.M., RICCI, S., BINNIE, C.D., RUBBOLI, G., TASSINARI, C.A., et al., 1999. *Video-game epilepsy: a European study*. *Epilepsia* 40 (Suppl. 4), 70–74.
- [70] MUNHOZ, P. R., *Procedimentos, Funções & Dlls para Delphi*, Visual books Ltda, Copyright© 2002 by Visual Books, maio de 2002.
- [71] VARDHAN P., MAJUMDAR, K, *Automatic Seizure Detection In Ecog By DB4 Wavelets And Windowed Variance: A Comparison*, In proceeding of: Communications and Signal Processing (ICCSP), International Conference on Source: IEEE Xplore, 2011.
- [72] MOUSA, K. W., MURUGAPPAN, M., AHMMAD, R. B., *Pnn Based Driver Drowsiness Level Classification Using Eeg*, *Journal of Theoretical and Applied*

Information Technology, Vol. 52 No.3, 30th June, 2013.

- [73] NIANQIANG L., YONGLING W., *Study Of The Denoising And Feature Extraction Based On Eyes-Closed EEG Signal*, International Conference on Information, Business and Education Technology (ICIBIT), 2013.
- [74] RAMOS, J. L. A., DE S., *Controle de Torque de um Exoesqueleto Atuado por Músculos Pneumáticos Artificiais Utilizando Sinais Eletromiográficos*, Dissertação de Mestrado, PUC, Rio de Janeiro, abril, 2013.
- [75] FERDJALLAH, M., WERTSCH, J., J., SHAKER, R., *Spectral analysis of surface electromyography (EMG) of upper esophageal sphincter-opening muscles during head lift exercise*. J Rehabil Res Dev. May-Jun;37(3):335-40, 2000.
- [76] HAYKIN, S., MOHER, M., *Sistemas de Comunicação*, quinta edição, ARTMED Editora S. A., 2009.
- [77] LATHI, B. P., DING, Z., *Sistemas de Comunicações Analógicas e Digitais Modernos*, quarta edição, Editora LTC, 2012.
- [78] JOHNSON, D. E., HILBURN, J., L., JOHNSON, J., R., *Fundamentos de Análise de Circuitos Elétricos*, Editora LTC, 4ª edição, 2000.
- [79] MUTHUKUMARASWAMY, S. D., JOHNSON, B. W., MCNAIR, N. A., *Mu rhythm modulation during observation of an object-directed grasp*. Cognitive Brain Research, v.19, n.2, p.195-201, 2004.
- [80] PAINOLD, A. M., ANDERER, P., HOLL, A. K., LETMAIER, M., SALETU-ZYHLARZ, G. M., SALETU, B., BONELLI, R. M., *EEG low-resolution brain electromagnetic tomography (LORETA) in Huntington's disease*, J Neurol, DOI 10.1007/s00415-010-5852-5, 2010.
- [81] BOOS, C. F., SCOLARO, G., PEREIRA, M. C. V., AZEVEDO, F., M., *Analysis Of Pre-Processing Methods For Artificial Neural Network Pattern Recognition Of Eeg Signals*. In: World Congress on Medical Physics and Biomedical Engineering, Heidelberg, Germany: Springer, v. 39. p. 558-561, 2012.
- [82] STECKLOW, M. V., *Imagética Motora Em Tarefa Complexa: Análise Na Banda Alfa Do Eletroencefalograma*, Dissertação de Mestrado, Universidade Federal Do Rio De Janeiro, Rio de Janeiro, Junho, 2006.
- [83] BARRETO, J. M., AZEVEDO, F., M., LIMA, W., C., *Internal model construction using feedforward neural networks: the case of a second order system*. In: 11th BENELUX Meeting on System and Control, Veldhoven, Holanda, 1992.
- [84] PILLA JÚNIOR, V., *Detecção de Padrões Eletroencefalográficos Relacionados ao*

Movimento para uma Interface Cérebro-Computador, Dissertação de Mestrado, CEFET-PR, Curitiba, 1999.

Apêndice

APÊNDICE 1

Termo de Consentimento livre e esclarecido



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ELETRÔNICA E SISTEMAS

Termo de Consentimento Livre e Esclarecido

Projeto: “Interfaceamento Homem-Máquina Por Meio De Técnicas De Processamento De Sinais Bioelétricos.”

Pesquisadores: Marilú Gomes Netto Monte da Silva e Marco Aurélio Benedetti Rodrigues.

Contato: Laboratório de Engenharia Biomédica – CTG \ UFPE, 4º andar, sala 412; fone: 2126-8210; email: gomes.marilu@gmail.com.

Contato: Comitê de Ética em Pesquisa – UFPE; Av. da Engenharia s/n, 1º andar, sala 4, CEP: 50740.600; fone: 2126-8588; email: cepccs@ufpe.br.

Você está sendo convidado para participar da pesquisa “**Interfaceamento Homem-Máquina Por Meio De Técnicas De Processamento De Sinais Bioelétricos.**” Você foi selecionado por não estar enquadrado nos critérios de exclusão. Sua participação não é obrigatória, logo a qualquer momento você pode desistir de participar e retirar seu consentimento. Sua recusa não trará nenhum prejuízo em sua relação com o pesquisador ou com a Universidade Federal de Pernambuco. Os objetivos desse estudo é desenvolver um sistema que permita uma maior mobilidade a pessoas com dificuldades na motricidade, através de técnicas de processamento de sinais aplicadas a sinais bioelétricos capturados. Respostas serão geradas com o intuito de criar uma interação homem-máquina. Sua participação nesta pesquisa consistirá na aquisição de seus sinais cerebrais, do músculo e do movimento do olho por equipamentos específicos de acordo com o protocolo redigido pelo pesquisador, para que por meio destes se consiga o controle homem-máquina. Os

procedimentos realizados na pesquisa seguem protocolos padronizados e vastamente utilizados, corroborando, dessa forma, para a segurança e viabilidade da pesquisa. O voluntário será preparado para a aquisição do sinal cerebral com a colocação dos 23 eletrodos instalados no couro cabeludo, para detecção da atividade cerebral, com a utilização de gel condutor e fita adesiva. Serão realizados testes com o indivíduo com os olhos abertos e fechados, mas sempre acordado. Para a captação do sinal muscular serão dispostos dois eletrodos sobre cada músculo, com uma distância entre eles de 20 mm. Para isso serão utilizados eletrodos de superfície duplos descartáveis. Para a captação do EOG serão utilizados 5 eletrodos de superfície descartáveis, dois colocados ao lado de cada olho para medição de movimentos horizontais, e os outros dois um acima e outro abaixo do olho direito, para medição de movimentos verticais. Um eletrodo de referência será posto na testa. Além disso, os voluntários desse estudo serão indivíduos saudáveis não apresentando nenhum tipo de risco físico, porém com um risco mínimo de constrangimento. Os benefícios relacionados com a sua participação são de fornecer os sinais bioelétricos para o desenvolvimento de um sistema que irá auxiliar pessoas com problema na motricidade, que poderão, a partir do desenvolvimento dessa pesquisa, utilizar garras mecânicas, cadeira de rodas, computador, entre outros, apenas com seus sinais bioelétricos, diminuindo assim as limitações desses indivíduos. Um benefício relacionado ao voluntário pesquisado será a possibilidade de controlar equipamentos e jogos, por exemplo vídeo games apenas com seus sinais bioelétricos. Os dados serão armazenados no Laboratório de Engenharia Biomédica sob-responsabilidade da doutoranda Marilú Gomes Netto Monte da Silva, pesquisadora responsável pelo projeto. Qualquer informação obtida que não esteja listada no protocolo será confidencial, e asseguramos o sigilo sobre sua participação. Os dados não serão divulgados de forma a possibilitar sua identificação, de maneira sigilosa, assegurando sua privacidade. Você receberá uma cópia deste termo onde consta o telefone e o endereço da instituição e do pesquisador. Dessa forma poderá tirar suas dúvidas sobre o projeto e sua participação, agora ou a qualquer momento.

O (a) voluntário (a) _____, CPF número: _____ telefone _____ concorda com a realização do teste e permite a utilização de fotos ou de qualquer material que seja necessário para a realização da pesquisa.

Declaro que entendi os objetivos, riscos e benefícios de minha participação na pesquisa e concordo em participar.

Assinatura do voluntário: _____

Testemunha da pesquisa (1): _____

Testemunha da pesquisa (2): _____

Assinatura do Pesquisador: _____ Data: ____/____/____

Observações:
