

Rhycardo Luiz Monteiro

**Uso de Redes Neurais ARTMAP Nebulosas para a classificação
de padrões em sinais ECoG relacionados ao movimento dos
dedos.**

Ilha Solteira
2015



Rhycardo Luiz Monteiro

**Uso de Redes Neurais ARTMAP Nebulosas para a classificação
de padrões em sinais ECoG relacionados ao movimento dos
dedos.**

Anna Diva Plasencia Lotufo
Orientadora

Jozué Vieira Filho
Co-orientador

Tese apresentada à Faculdade de Engenharia –
UNESP – Campus de Ilha Solteira, como parte dos
requisitos para obtenção do título de Doutor em
Engenharia Elétrica.

Área de Conhecimento: Automação

Ilha Solteira
2015

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Monteiro, Rhycardo Luiz.

M775u Uso de Redes Neurais ARTMAP Nebulosas para a classificação de padrões em sinais ECoG relacionados ao movimento dos dedos. / Rhycardo Luiz Monteiro. Ilha Solteira: [s.n.], 2015
101 f. : il.

Tese (doutorado) – Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de Conhecimento: Automação, 2015

Orientador: Anna Diva Plasencia Lotufo

Co-orientador: Jozué Vieira Filho

Inclui bibliografia

1. Rede neural artificial. 2. Artmap nebulosa. 3. Bci. 4. Ecog
5. Reconhecimento de padrões.

CERTIFICADO DE APROVAÇÃO

TÍTULO: Uso de Redes Neurais ARTMAP Nebulosas para a classificação de padrões em sinais ECoG relacionados ao movimento dos dedos

AUTOR: RHYCARDU LUIZ MONTEIRO

ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

CO-ORIENTADOR: Prof. Dr. JOZUE VIEIRA FILHO

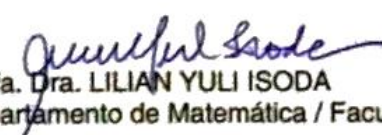
Aprovado como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:



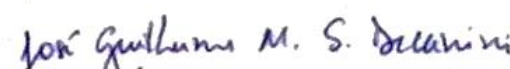
Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



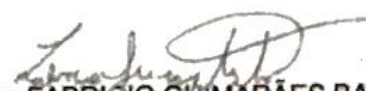
Prof. Dr. NOBUO OKI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. LILIAN YULI ISODA
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. JOSÉ GUILHERME MAGALINI SANTOS DECANINI
Câmpus de Presidente Epitácio / Instituto Federal de São Paulo - IFSP



Prof. Dr. FABRÍCIO GUIMARÃES BAPTISTA
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru

Data da realização: 28 de setembro de 2015.

Aos meus pais pelo legado e à
minha esposa Sheila, pela grande
mulher que é.

Agradecimentos

Gostaria de agradecer a todos aqueles que de alguma maneira me apoiaram e me incentivaram no transcorrer deste trabalho. Inicialmente, agradeço à minha esposa Sheila, por seu amor, por seu apoio e presença em minha vida. Aos meus filhos Lucas, Felipe e Isabela pelo orgulho que me proporcionam. À minha mãe, D. Therezinha e ao meu pai, Nery pelo exemplo de perseverança, aos meus irmãos Jhony, Vera e Nelma pelo apoio. Ao meu amigo Osmair de Araújo (*in memoriam*), pois sua necessidade foi a motivação primeira dessa pesquisa. Ao Prof^o Dr. Samuel Romero da Universidade de Granada pela contribuição inicial à este trabalho. À Prof^a. Dra. Anna Diva Plasencia Lotufo, minha orientadora e ao meu co-orientador Prof^o Dr. Jozué Vieira Filho pelo empenho e dedicação na orientação deste trabalho, sempre dispostos a discutir e conversar, incentivando a alcançar o objetivo que traçamos juntos, sinceros agradecimentos. À UNEMAT e meus colegas de trabalho pelo apoio e incentivo. À UNESP e ao Departamento de Engenharia Elétrica, a todos os professores que fizeram parte do meu crescimento profissional e, em especial ao Prof. Dr. Carlos Roberto Minussi e ao Prof. Dr. Rubén Augusto Romero Lázaro, pela assistência, e finalmente a todos colegas que por vezes me ajudaram mesmo que indiretamente. À CAPES pelo apoio financeiro através da bolsa de estudos.

RESUMO

O reconhecimento de padrões aplicado a sinais cerebrais é essencial para a implementação de interfaces computacionais que permitam comandar dispositivos de auxílio a indivíduos com limitações motoras. A identificação de características relacionadas com movimentos dos membros do corpo, tal como os dos dedos das mãos, exige uma sequência de etapas que inclui a aquisição e o pré-processamento dos sinais, a extração de características e classificação de dados do sinal. Esses sinais, chamados ECoGs, podem ser obtidos diretamente do cérebro através de implantes na região que gera as decisões de movimento, que é o córtex motor primário. Tais sinais são superiores em informação, qualitativa e quantitativamente, em relação aos sinais chamados EEG, obtidos na superfície do couro cabeludo. O pré-processamento consiste na preparação dos sinais para serem processados através de técnicas de seleção de canais relevantes, janelamento e filtragem para seleção de bandas de frequência portadoras de informação. A extração de características pode ser feita utilizando-se estes sinais no domínio da frequência e em seguida submetendo-os a autoregressão. A classificação se deu com o uso de redes neurais artificiais do tipo ARTMAP-Nebulosa, tendo como entrada matrizes compostas por dados processados provenientes dos sinais ECoG e de luva de dados, obtidos simultaneamente do mesmo indivíduo, durante uma seção experimental. Esse trabalho conseguiu ao final, gerar os sinais da luva a partir dos sinais ECoG. O coeficiente de correlação médio obtido foi de 0,91, evidenciando a eficiência do modelo proposto.

Palavras-chave: Rede neural artificial. ARTMAP-nebulosa. BCI. ECoG. Reconhecimento de padrões.

ABSTRACT

The pattern recognition signals applied to the brain is essential for the implementation of computational interfaces allowing control devices to aid people with physical limitations. The identification of features associated with body movements of the members, such as the fingers, requires a sequence of steps which includes the acquisition and pre-processing of signals, extraction of features and classification of signal data. These signals, called ECoG can be obtained directly from the brain through implants in the region that generates the motion decisions, which is the primary motor cortex. Such signs are superior in information qualitatively and quantitatively compared to the known EEG signals obtained on the surface of the scalp. The pre-processing consists in preparation of the signals to be processed through the relevant channel selection techniques, windowing and filtering for selecting frequency band information carrier. The feature extraction can be done by using these signals in the frequency domain and then subjecting them to autoregression. The classification is made using artificial neural networks ARTMAP-Fuzzy type, having as input matrices composed of processed data from the ECoG signals and data glove, both obtained from the same subject during the experimental section. This work could ultimately, generate sleeve signals from the ECoG signals. The average correlation coefficient obtained was 0.91, showing the efficiency of the proposed model.

Key Words: Artificial neural network. ARTMAP-fuzzy. BCI. ECoG. Pattern recognition.

LISTA DE FIGURAS

Figura 1- Publicações relevantes sobre a temática BCI.	19
Figura 2- Estrutura de um neurônio.....	26
Figura 3- (a) Propagação do Impulso Nervoso; (b) Aspectos anatômicos do impulso nervoso	27
Figura 4- Mapa funcional do hemisfério esquerdo do cérebro.....	29
Figura 5- Detalhe de aquisição de sinal cerebral (a) EEG – eletrodos no escalpo; (b) ECoG – eletrodos colocados diretamente na superfície do cérebro (córtex).....	30
Figura 6- Comparação entre sinais obtidos da atividade cerebral: (a) Tabela de características, (b) Localização do sensor e (c) Exemplo de sinal.....	32
Figura 7- Diagrama de possíveis transições de estado para movimento de dedo.....	34
Figura 8- Possíveis movimentos dos dedos da mão	35
Figura 9- Principais conceitos de Reconhecimento de Padrões.	38
Figura 10- Estrutura típica de um Sistema de RP	39
Figura 11- Sistema de RP reduzido.	42
Figura 12- Tipos de treinamentos resultantes das fronteiras de decisão	43
Figura 13- Estrutura de uma Rede ART-1.....	50
Figura 14- Estrutura de uma rede ART-Nebulosa.....	52
Figura 15- Arquitetura da Rede ARTMAP	53
Figura 16- Fluxograma do algoritmo de treinamento de uma rede de ARTMAP-Nebulosa. ...	55
Figura 17- Fluxograma do algoritmo de teste de uma rede de ARTMAP-Nebulosa.....	56
Figura 18- Efeitos da variação do parâmetro de vigilância	56
Figura 19- Fluxo de operação de uma BCI.....	58
Figura 20- Esquema comparativos entre (a) ações baseadas em músculos e, (b) as ações baseadas em BCI.	59
Figura 21- Sequência de processamento de sinais em uma BCI.	61
Figura 22- Gráfico comparativo de técnicas de aquisição de sinais cerebrais.	62
Figura 23- (a) Microgrid, (b) Macrogrid para ECoG, c) Corte de um microgrid, (d) Instalação cirúrgica de um macrogrid para ECoG.....	63
Figura 24- Gráfico do Filtro Elíptico.....	66
Figura 25- Fluxograma da Fase de Treinamento da BCI.	71
Figura 26- Escolha da localização anatômica do implante no cérebro.....	73

Figura 27- Esquema geral da realização do experimento.....	74
Figura 28- Estrutura dos dados no sinal da amostra.....	75
Figura 29- Pré-processamento de uma janela de sinal.....	76
Figura 30- Sinais da luva de dados para os 10 primeiros experimentos.....	77
Figura 31- Gráficos de Sinais: (a) gravado e o (b) gerado pelo modelo.....	78
Figura 32- Modelo do neurônio de McCulloch-Pitts.....	92
Figura 33- Funções de não linearidade.....	93
Figura 34- Exemplos de RNAs com diferentes camada e topologias.....	93
Figura 35- Arquitetura de RNA Perceptron multicamadas com duas camadas ocultas.....	94
Figura 36- Aprendizagem supervisionada.....	95
Figura 37- Aprendizagem não-supervisionada.....	96
Figura 38- Casos especiais de aprendizagem.....	96
Figura 39- Arquitetura do neurônio Perceptron.....	97
Figura 40- Modelo ADALINE.....	97
Figura 41- Modelo MADALINE.....	97

LISTA DE TABELAS

Tabela 1- Ritmos cerebrais e suas frequências.....	33
Tabela 2- Exemplo de aplicações de Reconhecimento de Padrões.....	37
Tabela 3- Marcos históricos relacionado com redes ART na literatura.....	49
Tabela 4- Equivalências entre as redes ART1 e ART-Nebulosa.....	53
Tabela 5- Coeficientes de correlação obtidos para os dedos da mão.....	79
Tabela 6- Tabela de resultados finais da BCI Competition IV.....	79
Tabela 7- Efeitos da variação no tamanho da janela.....	80

LISTA DE ABREVIATURAS

ADALINE	<i>ADaptive LINear Element</i>
AR	Autoregressivo
ART	<i>Adaptive Resonance Theory</i>
BCI	<i>Brain Computer Interface</i>
CSP	<i>Common Spatial Pattern</i>
DFT	<i>Discrete Fourier Transform</i>
ECG	Eletrocardiograma
ECoG	Eletrocorticograma
EEG	Eletroencefalograma
FFT	<i>Fast Fourier Transform</i>
fNIR	<i>Functional near-infrared spectroscopy</i>
fMRI	<i>Functional magnetic resonance imaging</i>
GN	<i>Grossberg Network</i>
IA	Inteligência Artificial
IC	<i>Intencional Control</i>
k-NN	<i>k-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analise</i>
LPF	<i>Local Potencial Field</i>
LTM	<i>Long-Term Memory</i>
MADALINE	<i>Many ADALINE</i>
PDS	Processamento Digital de Sinais
PET	<i>Positron emission tomography</i>
RNA	Redes Neurais Artificiais
RP	Reconhecimento de Padrões
STFT	<i>Short Time Fourier Transform</i>
STM	<i>Short-Term Memory</i>
SOM	<i>Self-Organized Map</i>
SU	<i>Single Unit Action Potencial</i>
SVM	<i>Support Virtual Machine</i>
VCC	Tensão Corrente Contínua

LISTA DE SÍMBOLOS

Símbolos latinos

A	matriz com padrões de entrada
B	vetor com padrões de saída
b	elementos do vetor B
C	número de classes
c	expoente que denota matriz complementar
Cue	tempo de sinalização
D	dimensão do vetor de padrões
D'	dimensão do conjunto de tuplas de características
delay	tempo de retardo
f	função genérica
F	função transformada de Fourier
F₀, F₁ e F₂	camadas de uma rede ART
Hn	magnitude de resposta a frequência do filtro
I	matriz de entrada codificada de uma rede ART
I_a	matriz decodificada sob a matriz A de rede ARTMAP
I_b	matriz decodificada sob o vetor B de rede ARTMAP
J	neurônio vencedor
k	vetor de classes
k_i	<i>i</i> -ésima classe do padrão
learningFase	tempo de treinamento
lenCue	tempo de sinalização
lenFB	tempo de <i>feedback</i>
lenWindow	tamanho da janela
m	número de amostras de padrões disponíveis
M	dimensão do vetor de classes
P	função probabilidade de um padrão pertencer a uma classe
p	função densidade de probabilidade condicional
qsi	incremento
r	coeficiente de correlação linear

r_x	função autocorrelação
S	soma dos quadrados dos afastamentos
$S1$	indivíduo experimentado de número 1
<i>Sample</i>	tempo decorrido de evento
Rn	função racional de Chebyshev de ordem n
\mathcal{R}	função risco de erro condicionado de um padrão pertencer a uma classe
t	coeficiente de Student
T	vetor de treinamento
\mathfrak{S}	conjunto de amostras de padrão
T	expoente que denota uma matriz transposta
<i>testFase</i>	tempo da fase de teste
<i>Trial</i>	tempo de avaliação
w_i	matriz de pesos <i>feedforward</i>
w_j	matriz de pesos <i>feedback</i>
W_a	matriz de pesos da sub-rede ARTa
W_b	matriz de pesos da sub-rede ARTb
W_{ab}	matriz de pesos da inter-ART
W_i	i -ésima janela
x	vetor de características de padrão
x_i	i -ésima observação ou padrão
\bar{X}	amostra X
Y'	n-uplas de características
\bar{Y}	amostra Y
Z	vetor de espaços

Símbolos Gregos

α	taxa de escolha
β	taxa de aprendizagem da rede ART
γ	<i>ripple</i> na banda de passagem
δ'	função delta de Kronecker
δ	<i>ripple</i> da banda de rejeição
λ	função perda atribuída a classificação errada
M	média

ρ_a	parâmetro de vigilância para a sub-rede ARTa
ρ_b	parâmetro de vigilância para a sub-rede ARTb
ρ_{ab}	parâmetro de vigilância para a inter-ART
σ	desvio padrão
ω	banda de frequência
μ	média de valores de uma amostra

SUMÁRIO

1	INTRODUÇÃO	17
1.1	CONTRIBUIÇÃO DO TRABALHO	19
1.2	ORGANIZAÇÃO DO TRABALHO	20
2	ESTADO DA ARTE	21
2.1	INTRODUÇÃO	21
2.2	DEFINIÇÃO DO PROBLEMA	22
2.3	ANÁLISE DAS PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS	23
3	SINAIS CEREBRAIS	25
3.1	NEURÔNIOS E O IMPULSO NERVOSO	25
3.2	O CÉREBRO E SUAS ESTRUTURAS	27
3.3	SINAIS CEREBRAIS	29
3.4	OS SINAIS ECOG	30
3.5	OUTROS MÉTODOS DE MEDIÇÃO DA ATIVIDADE CEREBRAL	31
3.6	ARTEFATOS	32
3.7	RITMOS CEREBRAIS	33
3.8	SINAIS ECoG RELATIVOS AOS MOVIMENTOS DOS DEDOS	34
3.9	BASE DE DADOS DE SINAIS ECoG	34
3.10	SINAIS CEREBRAIS NO COMANDO DE MOVIMENTOS DO CORPO	35
4	O RECONHECIMENTO DE PADRÕES	36
4.1	A IMPORTÂNCIA DO RECONHECIMENTO DE PADRÕES	37
4.2	CONCEITOS	37
4.3	SISTEMA DE RECONHECIMENTO DE PADRÕES	39
4.3.1	Fase de treino-aprendizagem	39
4.3.2	Fase de reconhecimento	40
4.3.3	Considerações sobre sistemas de RP	41
4.3.4	Projeto de sistema de reconhecimento de padrões	42
4.4	ABORDAGENS DE RECONHECIMENTO DE PADRÕES	43
4.4.1	Abordagem estatística	43

4.4.2	Abordagem sintática	45
4.4.3	Abordagem difusa	45
4.4.4	Abordagem neuronal	45
5	REDES NEURAIS ARTMAP-NEBULOSAS	47
5.1	TEORIA DA RESSONÂNCIA ADAPTATIVA	47
5.2	REDES NEURAIS ART	48
5.2.1	Redes neurais ART-1	50
5.2.2	Redes neurais ART-nebulosa	51
5.3	REDES NEURAIS ARTMAP	53
5.3.1	Rede neural ARTMAP-nebulosa	54
5.3.2	Parâmetros de vigilância e sua escolha	56
6	INTERFACE CÉREBRO COMPUTADOR.....	57
6.1	INTRODUÇÃO	57
6.2	TIPOS DE BCI.....	59
6.2.1	Transmissão de dados	59
6.2.2	Invasibilidade	60
6.2.3	Sincronismo	60
6.2.4	Sistemas híbridos.....	60
6.3	O SISTEMA BCI	60
6.4	AQUISIÇÃO DE SINAIS	61
6.4.1	Sinais e resolução espacial.....	61
6.4.2	Sensores.....	63
6.5	PRÉ-PROCESSAMENTO.....	63
6.5.1	Seleção de canais	63
6.5.2	Janelamento	64
6.5.3	Filtragem.....	65
6.6	EXTRAÇÃO DE CARACTERÍSTICAS	66
6.6.1	Conversão para o domínio da frequência	66
6.6.2	Autoregressão	67
6.7	CLASSIFICAÇÃO DE SINAIS	68
6.7.1	Análise discriminante linear.....	68
6.7.2	k-vizinhos mais próximos	68
6.7.3	Máquinas de vetor de suporte.....	69

6.7.4 Redes neurais	69
6.8 DESEMPENHO DE BCI.....	69
7 APLICAÇÃO E RESULTADOS	71
7.1 PARADIGMA EXPERIMENTAL.....	72
7.2 AQUISIÇÃO DE SINAIS	73
7.3 PRÉ-PROCESSAMENTO.....	75
7.3.1 Seleção de canais	75
7.3.2 Filtragem	75
7.4 EXTRAÇÃO DE CARACTERÍSTICAS	76
7.5 CLASSIFICAÇÃO DE PADRÕES	77
7.6 APLICAÇÃO E RESULTADOS	78
8 CONCLUSÃO E TRABALHOS FUTUROS	81
8.1 CONCLUSÕES	81
8.2 PERSPECTIVAS FUTURAS	82
8.3 SUGESTÕES PARA ESTUDOS FUTUROS	83
REFERÊNCIAS	84
APÊNDICE A	90
ANEXO A	100
ANEXO B	101

CAPÍTULO 1

INTRODUÇÃO

Atualmente, a Interface Cérebro-Computador (BCI), constitui o estado-da-arte no desenvolvimento de interfaces homem-computador. Ela proporciona a distância mais curta entre a origem de uma decisão no cérebro humano e o hardware propriamente dito.

Para Wolpaw e Wolpaw (2012), uma BCI trata-se basicamente de um sistema, hardware e software, que processa sinais elétricos oriundos da atividade cerebral e comunica padrões identificados aos dispositivos externos. Sua aplicação se estende desde proporcionar mobilidade a indivíduos lesionados, portadores de limitação motora através de exoesqueletos, à aplicações no entretenimento e educação quando associada à Realidade Virtual, e tais possibilidades tem seus limites ampliados a cada dia que passa.

A obtenção de informações diretamente do cérebro nos arremete ao estudo dos sinais elétricos de EEG (eletroencefalograma) obtidos a partir do couro cabeludo, conhecidos na medicina e usados para identificar anomalias e mal funcionamento daquele órgão. Entretanto, reconhecer padrões relacionados com atividades específicas do corpo humano é uma tarefa de grande complexidade.

Mais recentemente, com o aperfeiçoamento de implantes cerebrais, é possível obter sinais com baixo ruído através de matriz de eletrodos na superfície do córtex cerebral: o ECoG. Sua riqueza de informação permitiu identificar e explorar novas faixas de frequência, mas em contrapartida tem uma complexidade de modelagem superior aos EEG.

O Reconhecimento de Padrões (RP) é um recurso usual em casos onde a parametrização ou modelagem matemática do fenômeno tem alto nível de complexidade, como é o caso dos sinais cerebrais que comandam movimentos do corpo humano.

O RP é o ramo da pesquisa que objetiva a classificação de objetos físicos ou lógicos (padrões) em um número de categorias ou padrões. A classificação consiste em atribuir classes para as amostras, baseado em suas características ou atributos. (THEODORIDIS; KOUTROUMBAS, 2009)

As técnicas de Inteligência Artificial como as Rede Neurais Artificiais (RNA), proporcionam uma solução eficiente na extração de características.

O uso intensivo de RNA, segundo Wolpaw e Wolpaw (2012), no reconhecimento de padrões sugere a possibilidade de identificar nos sinais ECoG, características que expressem o comando de movimentos ou a intenção de movimento, a exemplo do que já vem sendo feito com sinais EEG.


As RNA do tipo ARTMAP Nebulosa diferenciam-se das demais por serem capazes de garantir o agrupamento de elementos nas categorias criadas pelo sistema e também de aprender novos padrões, características desejáveis para a aplicação proposta neste trabalho. (CARPENTER et al., 1992).

O impacto social do uso de BCI na mobilidade de pessoas lesionadas seria significativo, devido ao alto número de portadores de deficiência motora existente, sendo apenas no Brasil cerca de 13 milhões de pessoas (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA-IBGE, 2014), aproximadamente 7% da população. Esse fato justifica o interesse cada vez maior nessa classe de interface homem-máquina. Sua importância aumenta quando se considera o uso de BCIs em exoesqueletos na melhoria da mobilidade de pessoas da faixa etária acima de 80 anos, cerca de 1,9% da população brasileira. (IBGE, 2014)

Um indicador de relevância de um determinado objeto de pesquisa é a produção científica a seu respeito.

Observe no gráfico da Figura 1, o crescimento nos últimos 15 anos do número de publicações relevantes sobre a temática BCI. (WOLPAW; WOLPAW, 2012)

Figura 1- Publicações relevantes sobre a temática BCI.



Fonte: Wolpaw e Wolpaw (2012) ampliado.

1.1 CONTRIBUIÇÃO DO TRABALHO

Para um percentual entre 15 e 30% dos indivíduos, as BCIs não respondem adequadamente, os quais são conhecidos como BCI-analfabetismo. Isso ocorre provavelmente em função de alguma variação no arranjo cognitivo do cérebro, que gera um padrão de sinais, especificamente nas frequências mais baixas, diferente do encontrado em grande parte dos indivíduos. (DICKHAUS et al., 2009)

Segundo Wolpaw e Wolpaw (2012), a aplicabilidade futura das BCIs está condicionada aos seguintes fatores críticos: o desenvolvimento de hardware de aquisição de sinais confortáveis, convenientes e estáveis; à validação e disseminação das BCIs e, ainda, à confiabilidade comprovada para diferentes grupos de indivíduos.

A maioria dos modelos procura capturar alterações nas características dos sinais para identificar padrões de comportamento. As pesquisas atuais apresentam soluções particulares que não podem ser estendidas a outros cenários, pois soluções abrangentes necessitariam de algoritmos que detectem particularidades e realizem adaptações de forma automática. Tal abordagem permitiria também a portabilidade do método tanto para populações e membros do corpo distintos, como para neuroimplantes (matriz de eletrodos implantadas no cérebro) com outras configurações. Esses aspectos constituem um espaço de soluções ainda a ser explorado.

Apesar do modelo a ser proposto usar dados de sinais obtidos por procedimentos invasivos, espera-se que as evoluções das técnicas de aquisição de dados permitam obtê-los

externamente. Assim sendo, pela disponibilidade de informações proporcionada pelo ECoG é superior à dos EEG (GRAIMANN; ALLISON; PFURTSCHELLER, 2010), possa conferir-lhe maior disseminação.

1.2 ORGANIZAÇÃO DO TRABALHO

O trabalho foi organizado em sete capítulos como segue:

O Capítulo 1 apresenta uma introdução do trabalho explicitando os objetivos da tese e procura justificar a aplicabilidade do modelo proposto e por fim apresenta a organização do trabalho.

No Capítulo 2 é apresentado o Estado da Arte no uso de BCIs, uma exposição objetiva do problema e uma breve apresentação da bibliografia relevante que deu suporte de conhecimento a este trabalho.

O Capítulo 3 é uma exposição sobre os sinais cerebrais desde a sua origem, características e conceitos e finaliza discutindo sua tipologia e as formas de aquisição destes sinais. O conteúdo desse capítulo dá suporte de conhecimento tanto para o processamento dos sinais cerebrais como para a compreensão das RNA.

Já no Capítulo 4, a abordagem teórica apresentada é sobre o Reconhecimento de Padrões, seus conceitos e tipologia.

No Capítulo 5 são abordados os conceitos e desenvolvimento de redes neurais, percorrendo também sobre o paradigma ART e por fim sobre as redes ARTMAP nebulosas e suas aplicações.

O Capítulo 6 apresenta conceitos, definições e métodos ligados à BCIs, bem como uma descrição e comparativo das principais metodologias aplicadas no reconhecimento de padrões em sinais cerebrais do tipo ECoG.

O Capítulo 7 inicia apresentando o paradigma experimental do caso e, em seguida apresenta um modelo de reconhecimento de padrões aplicável em sinais ECoG relacionados ao movimento de dedos das mãos.

Finalmente, o Capítulo 8 apresenta as conclusões obtidas através neste trabalho, as perspectivas advindas dele e sugestões de trabalhos futuros.

CAPÍTULO 2

ESTADO DA ARTE

2.1 INTRODUÇÃO

Em 2002, John Donoghue e sua equipe da Universidade de Brown implantaram eletrodos no córtex motor de macacos, os quais foram posteriormente treinados para manipular joystick e controlar o cursor do monitor de vídeo de um computador. Em paralelo com os sinais dos joysticks, os sinais corticais referentes ao movimento deles joysticks foram capturados e processados. Ocorreu que, uma vez desativado o joystick destes macacos, eles continuaram controlando o cursor, diretamente através do cérebro. A publicação deste experimento tornou-se um marco para as pesquisas sobre BCI. (SERRUYA et al., 2002).

Estes resultados motivaram a criação de diversos grupos de pesquisa na temática, com objetivo de desenvolver próteses para indivíduos lesionados. Wolpaw e Wolpaw (2012) estimam que cerca de 70 à 80% das pessoas com deficiências graves poderiam ser beneficiadas pelos sistemas de BCI atuais.

Os eventos e competições como o *BCI Award*, *The Annual BCI Research Award*, *BCI Competition* e outros, são atualmente fortes indicadores do estado-da-arte das pesquisas na área de BCIs e apresentam as mais recentes tendências da época de sua realização.

Institutos europeus (*Pascal Network of Excellence*) e universidades européias (*Graz University of Technology - Áustria*) e asiáticas na China (*Donghua University*) e Malasia

(Universiti Utara Malaysia), estão entre os grandes agentes de pesquisas nessa temática e possuem centros de pesquisas dedicados com produção científica considerável e relevante. (WOLPAW; WOLPAW, 2012)

Estudos recentes demonstram que ECoG pode fornecer informações não apenas sobre os movimentos, mas incluem aspectos comportamentais relevantes que poderão ser explorados num futuro próximo. (SCHALK, 2010)

O estudo intenso de BCIs, dado a diversidade de métodos existentes para extração de características e classificação, deu origem à uma classe de software dedicada ao desenho, teste e uso de BCIs, em tempo-real ou off-line. Pertencem a essa classe os aplicativos: o BCI2000 que disponibiliza módulos inclusive de pré-processamento, elaborado com contribuição de laboratórios do mundo inteiro; o BCILab – que é um módulo para MATLAB, de código aberto e extensa coleção de métodos, permitem prototipagem, testes em tempo-real, avaliação de desempenho; já o aplicativo *open source* OpenVIBE mantém contínua atualização a partir de contribuições comunitárias. (BRUNNER et al., 2013)

O uso de redes neurais da família ART (CARPENTER et al., 1992) é uma possibilidade não suportada por nenhum deles diretamente.

2.2 DEFINIÇÃO DO PROBLEMA

O cérebro, em seu córtex que responde pelo controle motor do corpo, produz sinais que podem ser subproduto da atividade-cerebral (EEG) ou resultado direto dela (ECoG). O problema consiste em examinar a possibilidade de reconhecer nos sinais ECoG as leituras relativas ao movimento de membros do corpo, especificamente os dos dedos das mãos.

Deste modo, a solução considerada nesta Tese foi o desenvolvimento de modelo de sistema de reconhecimento de padrões relativos ao movimento dos dedos das mãos embutidos em sinais ECoG, capturados diretamente do córtex motor primário, fazendo uso de redes neurais artificiais do tipo ARTMAP-Nebulosa (CARPENTER et al., 1992) para a classificação dos referidos padrões. Não existe um trabalho de referência direta à um caso desses, apenas em correlatos EEG, que são sinais mixados, portadores de ruídos significativos e de baixo nível de informação. Portanto, não há como assegurar que são 100% aplicáveis aos ECoGs.

2.3 ANÁLISE DAS PRINCIPAIS REFERÊNCIAS BIBLIOGRÁFICAS

Nas últimas décadas, as redes neurais artificiais têm-se apresentado com ferramentas bastante eficientes na solução de problemas baseados na inferência sobre dados. A evolução delas tem sido resultado de um esforço para aumentar sua capacidade de generalização. A expectativa de reconhecer registro do movimento de membros do corpo, em sinais oriundos do cérebro, suscitou possibilidade do uso de redes baseadas no paradigma ART para o reconhecimento desses padrões.

As contribuições baseadas em técnicas e metodologias para reconhecimento de padrões em sinais cerebrais do tipo ECoG são recentes, e quase inexistentes se considerada classificação por RNA.

A tecnologia com maior disseminação são mesmo aquelas voltadas para EEG. Assim, Norani et al. (2010), apresenta uma revisão abrangente do estado-da-arte em BCIs, com tipologia funcional e de classificadores, apontando uma similaridade entre as técnicas de RP e de BCI, sugerindo, portanto, um exame das metodologias de RP para fins de adoção de um projeto funcional que se adeque ao uso de RNA em sinais ECoG.

Em Wolpaw e Wolpaw (2012), apresenta uma documentação abrangente sobre o tema BCI, com uma abordagem detalhada sobre os aspectos biológicos e técnicos que envolvem desde a geração, captação e processamento dos sinais cerebrais, sua principal contribuição foi a compreensão integral dos processos envolvidos numa BCI e também como as informações estão contidas nas diversas bandas de frequência, o que subsidiou a escolha delas. Além disso, permitiu ampliar as opções metodológicas para as etapas de seleção de características e a de classificação em si.

Os aspectos biológicos que não foram totalmente esclarecidos nas bibliografias anteriores, tais como a influência da morfologia cerebral e sua relação com o posicionamento dos implantes e, por consequência, a seleção de canais, foram elucidados nos livros de (JUNQUEIRA; CARNEIRO, 2006; BEAR et al., 2015).

Em Oppenheim e Schafer (1975) e Madisetti (2010), foram apresentados elementos para escolha dos métodos de tratamento de sinais no domínio da frequência, na escolha de tipo e algoritmo de transformação. Apresentou também o diferencial no emprego de Wavelets, o que foi refutado para o presente caso devido ao fato de que a temporariedade seria acrescida no janelamento.

Para Duda et al. (2001) a abordagem de RP, diferente em alguns aspectos de Theodoridis e Koutroumbas (2009), mas contribuíram para o entendimento das fases que envolvem a RP e permitiram construir um projeto customizado para o caso, semelhante ao de (FRED, 2015).

Os trabalhos de Carpenter e Grossberg (1987) e Carpenter et al. (1992) elucidaram a Teoria da Ressonância Adaptativa, o que confirmou sua adequabilidade para o caso de tratamento de sinais daquela natureza. Lopes et al. (2005) contribuiu para a elaboração de algoritmo para as rede ARTMAP-Nebulosa na fase de treinamento, e Decanini et al. (2011) para a fase de teste.

O trabalho de Ravi, Palaniappan e Hengb (2006) discorre sobre o uso de redes ARTMAP-Nebulosa para RP em sinais EEG, contribuiu no entendimento do uso de redes dessa natureza em sinais cerebrais de forma geral.

Os artigos de Wang, Schalk e Ji (2011), Bougrain e Liang (2009), Hazrati e Hofmann (2012), Flamary e Rakotomamonjy (2012), tratam do RP referentes ao movimento de dedos em sinais ECoG, usando classificadores e métodos diferentes, mas que contribuíram significativamente na escolha de técnicas de pré-processamento.

Cumpramos ressaltar que literatura acerca da aplicação de RNA, especificamente a ARTMAP-Nebulosa no reconhecimento de padrões em sinais ECoG é inexistente. Assim, a possibilidade de um ganho em performance com a aplicação da mesma pelas razões a serem expostas no decorrer deste trabalho é uma possibilidade de interesse científico.

CAPÍTULO 3

SINAIS CEREBRAIS

Este capítulo apresenta a fonte dos sinais cerebrais desde as interações fisiológicas que produzem os impulsos nervosos, passando por uma apresentação do cérebro com ênfase na atividade do córtex, até a aquisição de dados oriundos da atividade cerebral. Serão abordados também alguns aspectos relacionados com os sinais que geram o movimento de dedos.

3.1 NEURÔNIOS E O IMPULSO NERVOSO

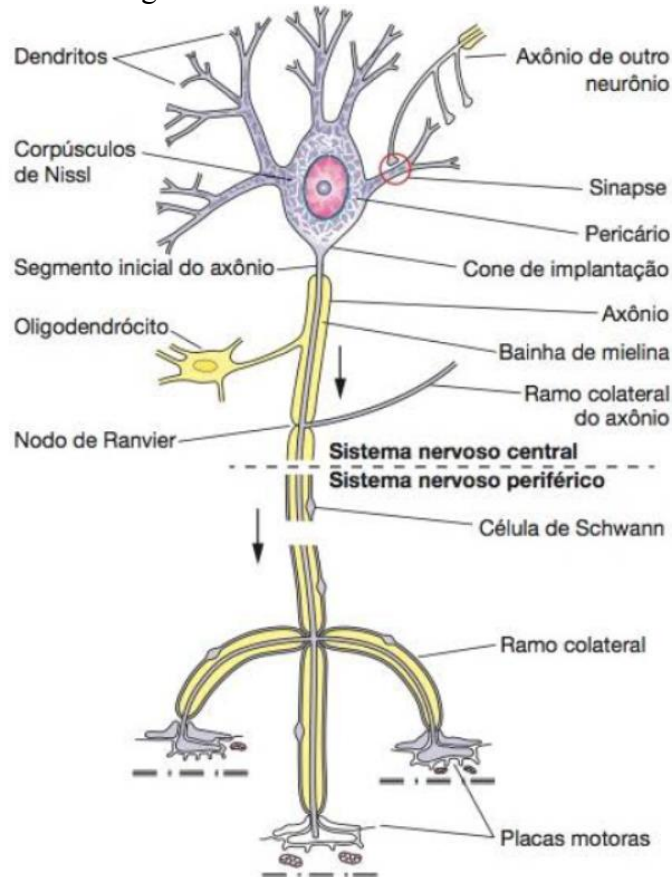
Os neurônios, de acordo com Junqueira e Carneiro (2006), são células especializadas que formam o tecido nervoso que compõe o sistema nervoso de todos os seres vivos. Os neurônios são os elementos fundamentais na constituição do sistema nervoso, exercendo funções distintas de acordo com a sua posição e morfologia. Estima-se que o cérebro humano possua cerca de 100 bilhões destas células. A estrutura de um neurônio é basicamente a mesma em todos os seres vivos, constituindo-se de três componentes, conforme ilustra a Figura 2:

- **Corpo celular ou soma:** contém o núcleo e o pericário, é nesse componente que ocorre praticamente todas as reações metabólicas da célula;
- **Dendritos** são ramificações arborescentes ligadas ao corpo celular que recebem impulsos de outras células através de conexões chamadas sinapses. Ao passar por uma sinapse, o sinal elétrico pode sofrer alterações. Na sinapse, os sinais elétricos ficam sujeitos a bloqueio total ou parcial, ou ainda receber ganho. Assim, as sinapses podem ser consideradas como elementos que conduzem e transformam também o sinal elétrico que recebem;

- **Axônio ou fibra nervosa:** trata-se de um prolongamento que se origina no corpo celular e termina em ramificações que transmitem o impulso à outros neurônios. Ao longo de sua extensão, revestindo o axônio está a bainha de mielina, um recobrimento descontínuo e isolante térmico que atua como um facilitador da transmissão do impulso. A interface entre as células de Schwann é o nodo de Ranvier;

O sentido do impulso nervoso parte sempre dos dendritos para o soma e depois para o axônio, conforme é possível observar na Figura 2.

Figura 2- Estrutura de um neurônio



Fonte: Junqueira e Carneiro (2006).

O impulso nervoso atua através do mecanismo chamado bomba de sódio, baseado no transporte de íons de sódio e potássio através da membrana plasmática.

Uma região do axônio pode assumir três estados, conforme ilustra o item (a) da Figura 3:


- **Repouso** – É o estado básico de um neurônio, obtido quando três íons de sódio são bombeados através da membrana citoplasmática para fora, e apenas dois íons de

potássio afluem para dentro do neurônio, criando assim, por convenção, um potencial negativo de cerca de -65mV em seu interior e positivo em seu exterior. Esse estado também é conhecido como polarizado;

- **Despolarizado** - Quando o neurônio é estimulado, a permeabilidade da membrana é alterada, e o sódio faz o caminho inverso migrando para o interior da fibra, ocasionando o aumento da concentração interna de íons, tornando-se com potencial positivo internamente de cerca de $+30\text{mV}$. Em consequência disso, a membrana se torna permeável a poucos íons de potássio, que se transportam para fora do neurônio, ficando carregado negativamente do lado externo. Essa polarização se propaga no axônio no sentido do soma para a extremidade;
- **Repolarizado** - A alta concentração de íons de potássio provoca o seu retorno de íons de sódio para o exterior reestabelecendo a eletronegatividade na fibra. Essa repolarização se propaga pela mesma trajetória da polarização.

O item (b) da Figura 3 apresenta a anatomia da movimentação do impulso ao longo do axônio, especificamente nos nodos de Ranvier.

Figura 3- (a) Propagação do Impulso Nervoso; (b) Aspectos anatômicos do impulso nervoso



Fonte: Amabis e Martho (2004).

3.2 O CÉREBRO E SUAS ESTRUTURAS

Segundo Gartner e Hiatt (2007), o cérebro é reconhecidamente a estrutura mais complexa do ser humano, formado por subsistemas especializados em tarefas específicas. O tecido cerebral é formado por dois tipos de célula: os neurônios e as células da glia ou neuroglia. O cérebro humano é formado por quatro estruturas: o cerebelo que está ligado a aprendizagem

motora, o hipotálamo que é regulador do metabolismo e atividades autônomas, o tálamo cuja função principal é tratar os estímulos recebidos pelo sistema nervoso e o córtex cerebral.


O córtex é a camada mais externa do cérebro cuja espessura varia de 2 a 6 mm, e é constituído de dois hemisférios idênticos que se comunicam através do corpo caloso, sendo que cada um controla o lado oposto do corpo. Tem superfície irregular, cheia de protuberâncias intercaladas por sulcos que aparentam enrugamento. (BEAR et al., 2015)

O córtex possui 30 bilhões de neurônios composto de 5 tipos de células nervosas, das quais cerca de 70% estão perpendiculares à superfície. O córtex é a estrutura responsável por processar o pensamento, movimento voluntário, a linguagem, o julgamento e a percepção; o que o torna a mais importante para aplicação de BCI. (JUNQUEIRA; CARNEIRO, 2006)

Cada função é desempenhada por uma região específica do córtex. Para identificar a correspondência entre o sinal elétrico obtido e a tarefa executada é necessário um mapeamento funcional, conforme ilustra a Figura 4.

Para Gartner e Hiatt (2007), a execução de qualquer ação motora do corpo, independente da complexidade, exige uma sequência de etapas. Mover um dedo, levantando-o e abaixando-o repetidamente, envolve duas etapas desempenhadas por regiões corticais distintas. A primeira delas é a preparação e ocorre na área Pré-Motora, se ela depende de um estímulo visual, a ativação ocorre na área da Associação Somato-Sensitiva. A segunda fase é a execução e é resultado da ativação no Córtex Motor Primário. A partir dessa região, impulsos elétricos se propagam pelo trato córtico-espinhal até chegar aos músculos, que serão excitados eletricamente para produzir o movimento desejado.

Figura 4- Mapa funcional do hemisfério esquerdo do cérebro.



Fonte: Bear et al. (2015).

Assim, conforme se pode inferir, a simples intenção de movimento provoca o desencadear de tarefas mentais com atividades elétricas decorrentes.

3.3 SINAIS CEREBRAIS

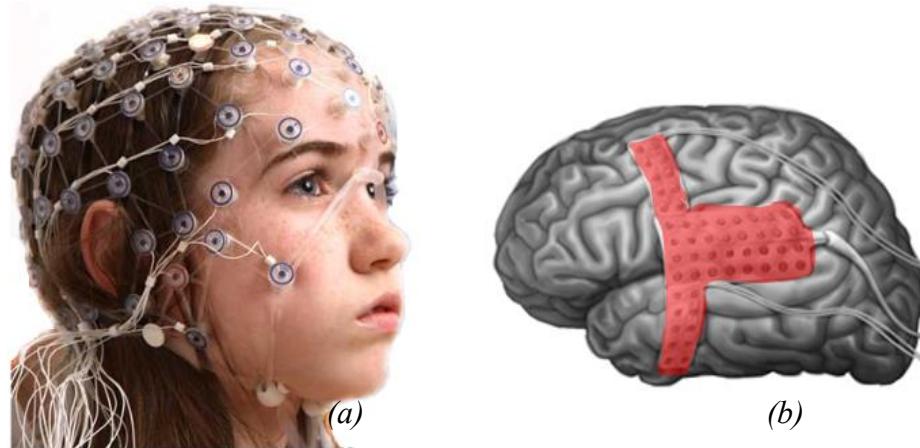
Segundo Junqueira e Carneiro (2006), as chamadas células Gliais atuam conferindo ganho aos potenciais no ambiente extracelular. Esses potenciais são chamados potenciais de campo local (*Local Potencial Field - LPF*) e podem se capturados externamente.

Os potenciais de campo local gravados com ponto de referência inativo, filtrados com frequência abaixo de 100 Hz e o dispositivo de ganho possuir uma constante de tempo inferior a 1 s, correspondem ao Eletroencefalograma (EEG). (BEAR et al., 2015)

Segundo Wolpaw e Wolpaw (2012), Hans Berger foi o primeiro estudioso a usar EEG qualitativamente, em 1924. Seu uso regular é no diagnóstico de problemas neurológicos. Atualmente, uma combinação com métodos de imagética motora permite investigar e identificar registros mentais de imagens.

O EEG é um método não invasivo de aquisição de sinais a partir de eletrodos instalados sobre o couro cabeludo, conforme apresenta o item (a) da Figura 5.

Figura 5- Detalhe de aquisição de sinal cerebral (a) EEG – eletrodos no escalpo; (b) ECoG – eletrodos colocados diretamente na superfície do cérebro (córtex).



Fonte: Center for Neurological and Neurodevelopmental Health - CNNH (2015) adaptado.

3.4 OS SINAIS ECOG

Os eletrodos de aquisição podem também ser implantados cirurgicamente na superfície do cérebro, permitindo registrar sinais a frequências superiores à 100 Hz, o Eletrocorticograma – ECoG. Tais implantes constituem-se normalmente de uma matriz de eletrodos de 64 a 128 canais. Por se tratar de um procedimento invasivo, o dispositivo implantado pode sofrer rejeição do organismo ou ainda ter sua função comprometida pela contínua adaptação do organismo, recobrando-o com um tecido que altere as características do sinal. (WOLPAW; WOLPAW, 2012)

Estudos têm mostrado que os ECoG carregam em certas bandas¹, informações precisas sobre a atividade de tarefas relacionadas com execução motora e planejamento, processamento auditivo e atenção visual-espacial, sugerindo essas faixas como um indicador robusto e geral da função cortical local. O sinal ECoG também amplia a compreensão dos processos pois dada a sua alta resolução permite estabelecer uma relação entre as diversas funções desempenhadas pelos membros do corpo. (HILL et al., 2012)

De acordo com Haider, Ishak e Adznan (2010), são vantagens de sinais EEG em relação ao ECoG:

¹ com ênfase na faixa da Gama alta

- Não é invasiva e não representa riscos ao paciente;
- Localiza atividades cerebrais que envolvem muitos neurônios;
- Apresenta nos registros dados suficientes para um diagnóstico neurológico;
- Os custos de aquisição são relativamente reduzidos;
- Atividades mentais específicas podem ser identificadas com clareza na mudança dos sinais.

As vantagens do ECoG se comparadas ao EEG são:

- Resolução espacial² superior à do EEG, ou seja, pequena área fornece muita informação;
- Registra sinais com menor ruído, pois são captados próximo da fonte. Os sinais do cérebro sofrem mixagem ao passarem pelo osso do crânio e outros tecidos, o que produz ruído nos sinais EEG;
- Mais informações podem ser extraídas dos sinais pois existem mais faixas de frequência disponíveis do que no EEG;
- BCIs baseadas em ECoG necessitam de dados mais precisos por isso exigem tempo de treinamento menor e permitem executar operações de precisão.

A Figura 5 apresenta os locais de captura dos sinais EEG e os ECoG.


3.5 OUTROS MÉTODOS DE MEDIÇÃO DA ATIVIDADE CEREBRAL

Existem outros métodos de obtenção de sinais elétricos, dos quais a maioria são ainda experimentais e/ou não apresentam dados conclusivos ou sua viabilidade ainda é comprometida pelos custos envolvidos. O LPF e o SU (*Single Unit Action Potencial*) são formas eficientes de aquisição de sinais, entretanto, o risco decorrente da invasibilidade é considerável. (ORTIZ-ROSÁRIO; ADELI, 2013).

A Figura 6 ilustra um comparativo entre o EEG, ECoG e outros dois.

² Resolução espacial: densidade de informação obtida.

Figura 6- Comparação entre sinais obtidos da atividade cerebral: (a) Tabela de características, (b) Localização do sensor e (c) Exemplo de sinal.



Fonte: Ortiz-Rosário e Adeli (2013).

Métodos baseados em imagética também permitem inferir sobre a atividade cerebral. Em geral, estão baseados nas alterações fisiológicas na região cerebral em atividade, tais como a tomografia e a ressonância magnética, onde um *scanner* rotativo detecta variações eletromagnéticas do cérebro, por isso são bastante precisos. O inconveniente desses métodos é que o tempo necessário para se detectar essas variações é relativamente longo se comparado aos métodos de leitura direta do sinal elétrico.

3.6 ARTEFATOS

Os sinais elétricos obtidos estão sujeitos a interferência de fatores internos e externos, são os chamados “artefatos”. O corpo humano todo produz sinais, rítmicos ou não, durante atividades motoras. Esses sinais também se propagam pelo corpo e podem chegar à região de aquisição de EEG e ECoG com relativa facilidade, são os chamados “artefatos”. O mais intenso deles é o eletrocardiograma (ECG), sinais produzidos pela atividade muscular do coração, mas outros sinais são interferentes também, como é o caso do movimento das pálpebras em piscar de olhos e movimento dos membros. (WOLPAW; WOLPAW, 2012)

Artefatos de origem externas são conhecidos e podem ser removidos por filtragem, é o caso daquele induzido pela corrente alternada de alimentação dos equipamentos de medida, cuja frequência é de 60 Hz. O suor e a má fixação de eletrodos podem ocasionar flutuação de impedância, no caso de EEG. (GRAIMANN; ALLISON; PFURTSCHELLER, 2010)

No caso dos EEG, a passagem dos sinais do córtex para o escalpo tem em seu percurso camadas diversas de tecidos e o osso do crânio, o que produz uma mixagem de tais sinais

impossibilitando assim que sejam obtidos com fidelidade e nitidez, o que não acontece com os ECoG. (WOLPAW; WOLPAW, 2012)

3.7 RITMOS CEREBRAIS

As ondas cerebrais podem apresentar diferentes atividades rítmicas. Para Montenegro e Cendes (2011), fatores como o estado de consciência, idade, cansaço mental e morfologia craniana interferem na sua interpretação diagnóstica. Esses ritmos são classificados de acordo com a frequência. A fonte de sinais emite sinais de variadas frequências simultaneamente, entretanto, as mais relevantes do ponto de vista clínico são apresentadas na Tabela 1:

Tabela 1- Ritmos cerebrais e suas frequências.

Ritmo	letra	descrição
Ritmo delta	δ	$\leq 3,5$ Hz
Ritmo teta	θ	4-7,5 Hz
Ritmo alfa	α	8-13 Hz
Ritmo beta	β	14-30 Hz
Ritmo gama	γ	60-100 Hz
Ondas pi	π	Ondas lentas posteriores da juventude
Ritmo phi	φ	Ondas lentas posteriores ao fechamento ocular
Ritmo kappa	κ	Ritmo temporal anterior <i>alfa-like</i>
Atividade sigma	ς	Fusos de sono
Ondas rho	ρ	POSTS
Ritmo mu	μ	ritmo do córtex motor
Ondas lambda	λ	Ondas occipitais positivas na vigília
Ritmo tau	τ	Ritmo alfa fisiológico na região temporal
Ondas zeta	ζ	Onda delta agudizada
Ritmo gama alta	γ	100-300 Hz

Fonte: Caboclo (2015) ampliada.

Observa-se que alguns ritmos (em cinza) não são relevantes por não ocorrerem em todos os indivíduos. De acordo com Wolpaw e Wolpaw (2012), acima de 200Hz outras estruturas como o Hipocampo (~250 Hz) e o Tálamo (~600 Hz) passam a contribuir.

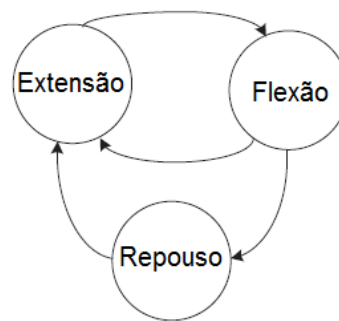
3.8 SINAIS ECoG RELATIVOS AOS MOVIMENTOS DOS DEDOS

Segundo Menezes (2011), mesmo admitindo que o neurônio possui um número finito de estados, o elevado número de estados resultantes da combinação dos neurônios no cérebro torna pouco prática a sua abordagem como um sistema de estados finitos.

Entretanto, para Wang, Schalk e Ji (2011), é possível modelar o movimento dos dedos em transições de estados, conforme se observa na Figura 7, e usar as restrições anatômicas de movimento para otimizar a busca de parâmetros cinemáticos a serem identificados nos sinais cerebrais.

Isso sugere que algumas regiões do cérebro respondem a modelagem próxima a de sistema de estados finitos.

Figura 7- Diagrama de possíveis transições de estado para movimento de dedo



Fonte: Wang, Schalk e Ji (2011).

Admitir a existência de estados intermediários para obter o efeito de movimentos de diferentes amplitudes aumentaria a complexidade do modelo paramétrico, então é razoável admitir que uma abordagem conexionista para identificação de padrões em sinais de origem cerebrais relativas à movimento de dedos parece ser mais eficiente. Não se pode ignorar o fato do sistema sempre considerar estados anteriores. Assim sendo, qualquer que seja o modelo a reproduzir os movimentos dos dedos a partir dos sinais do cérebro, não produzirão resultados satisfatórios se usá-los em sequência aleatória.

3.9 BASE DE DADOS DE SINAIS ECoG

A crescente preocupação com o uso de seres humanos em pesquisas deu origem à uma série de rígidos padrões a serem seguidos para experiências dessa natureza, razão pela qual sob certas circunstâncias se torna mais viável o reuso de dados coletados por outras instituições para outros fins.

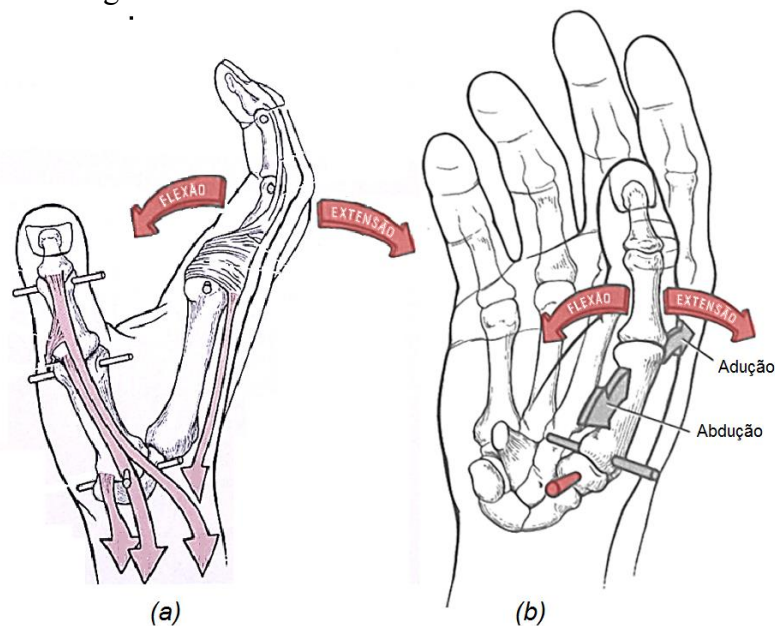
Dados para estes fins necessitam ser confiáveis e já bastante disseminados em pesquisas. É o caso dos sinais ECoG, pois o fato de serem invasivos e de alto custo de implantação, sua viabilidade só se confirma se os números de experimentos vinculados forem significativos.

A plataforma móvel para gravação de sinais ECoG tem sido uma forma de estender o acompanhamento da evolução de pacientes com epilepsia e outras anomalias cerebrais, evitando assim sua permanência no hospital. É comum solicitar ao paciente a submissão a experimentos antes da remoção do implante.

3.10 SINAIS CEREBRAIS NO COMANDO DE MOVIMENTOS DO CORPO

Segundo Newmann (2011), todo e qualquer movimento de membros do corpo humano é executado através de um complexo de músculos, que agem sobre uma estrutura biomecânica, os ossos. Os graus de liberdade de movimento são determinados pelas articulações. Os músculos desenvolvem basicamente duas ações: flexão e extensão. Tais ações são comandadas pelo cérebro através de impulsos nervosos originados no córtex. A Figura 8 mostra os possíveis movimentos do dedo indicador (a) e do polegar (b), sendo que cada movimento desses está ligado à 3 ou 4 fibras nervosas.

Figura 8- Possíveis movimentos dos dedos da mão



Fonte: Newmann (2011) adaptado.

CAPÍTULO 4

O RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões, antes de 1960, se resumia em aplicações de estatística teórica. O advento dos computadores sugeriu novos estudos para sua aplicação em RP e a disseminação das técnicas de automação industrial apontou a necessidade de novos modelos para tratar e recuperar informações a partir de conjunto de dados. Os resultados relevantes impulsionaram o RP à exploração nas atuais fronteiras do conhecimento, tornando-o um importante componente dos sistemas de tomada de decisão. (THEODORIDIS; KOUTROUMBAS, 2009)

O RP é, essencialmente, uma compilação de variados problemas, em que as soluções utilizam técnicas projetadas para atender especificidades de problemas de outras áreas. Assim, o RP contém contribuições da Teoria da Decisão, Teoria da Autômata, Teoria da Probabilidade, lógica nebulosa, etc. Por essa razão é possível utilizá-lo em diversas as áreas do conhecimento científico.

Reconhecimento de padrões – o ato de pegar dados brutos e agir baseado na “categoria” do padrão – tem sido crucial para nossa sobrevivência; por mais de milhões de anos temos desenvolvido um sistema neural cognitivo altamente sofisticado para tais tarefas. (DUDA; HART; STORK, 2001, p. 3)

O RP, segundo Theodoridis e Koutroumbas (2009), “É uma área de pesquisa que tem por objetivo a classificação de objetos (padrões) em um número de categorias ou classes”. Essas duas definições identificam em comum a ação de organizar os objetos em categorias baseadas em determinados critérios. Independente da natureza, os processos de geração de dados sempre transferem algum tipo de informação através dos dados gerados. A estrutura é o modo como a

informação pode ser organizada para identificar as relações entre as variáveis do processo. Estas variáveis exercem um papel importante e são fundamentais em RP.

4.1 A IMPORTÂNCIA DO RECONHECIMENTO DE PADRÕES

Qualquer problema de RP implica essencialmente em uma tarefa de classificação. O crescente interesse na área de RP decorre do fato das esferas de conhecimento demandarem de aplicações cada vez mais complexas voltadas para identificação de regularidades em dados, exigindo assim recursos computacionais cada vez maiores (DUDA; HART; STORK, 2001).

A Tabela 2 apresenta, uma relação de aplicações voltadas para alguns domínios de problemas emergentes juntamente com padrões (entradas) e classes associadas (saídas).

Tabela 2- Exemplo de aplicações de Reconhecimento de Padrões.

Problema	Entradas	Saídas
Reconhecimento de voz	sinais de voz	Palavras, identidade do locutor
Testes não invasivos / destrutivos	Ultra-sons, emissão de ondas acústicas, imagem	Presença / ausência de anomalia
Detecção / diagnóstico de doenças	ECG, EEG, ultra-sons	Tipos de condições cardíacas, classes de estados cerebrais, patologias
Identificação de recursos naturais	Imagens multi-espectrais	Formas de terrenos, vegetação
Reconhecimento aéreo	Infravermelhos, imagens de radar	Tanques, campos de cultivo, estradas, tráfego
Reconhecimento de caracteres (leitores de página, códigos de barras, matrículas)	Imagens de varrimento óptico	Caracteres alfanuméricos
Identificação e contagem de células	Slides de amostras de sangue, micro-seccionamento de tecidos	Tipos de células
Detecção de falhas (placas de PC, circuitos integrados, texturas)	Imagens	Aceitação / rejeição
Robótica	Imagens de interiores ou exteriores em 3D, luz estruturada, laser, imagem estéreo	Identificação de objetos, tarefas industriais

Fonte: Fred (2015).

4.2 CONCEITOS

Embora conceitos geralmente obedecem a um senso comum, a definição precisa de alguns conceitos é importante para o entendimento dos métodos de RP e impedem que a flexibilização dos mesmos distorça o seu real sentido. De acordo com Theodoridis e Koutroumbas (2009), são eles:

Padrão: pode ser entendido como um objeto, entidade, evento ou processo que possa ser identificado sem a necessidade de ser definido precisamente.

Classe: trata-se de conjunto de padrões que tem em comum determinadas características. Alguns autores como Wangenheim e Wangenheim (2003), fazem distinção entre classe e categoria, afirmando que classes tem fronteiras definidas e categorias tem limites imprecisos ou aproximados.

Característica: dado ou atributo extraído de uma determinada amostra. Considerando um padrão genérico que possui associado um vetor de características x , com t características, então temos na Equação (1):

$$x = [x_1, x_2, \dots, x_t]^T \quad (1)$$

Cada vetor identifica apenas um padrão ou objeto. O índice T denota a transposição do vetor. Essa extração de características pode ser feita através de medida ou também por processamento.

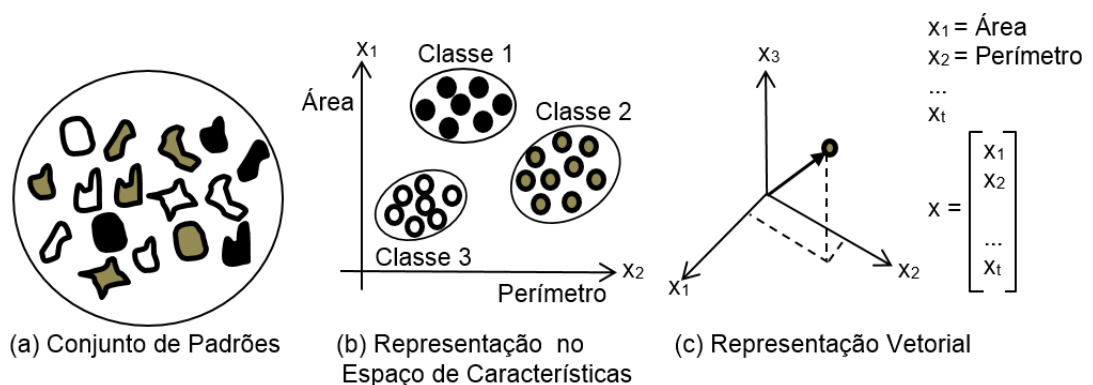
Classificação: consiste em atribuir classes específicas para as amostras do conjunto de acordo com suas características.

Classificador: dispositivo ou algoritmo que especifica uma função de decisão, que mapeia a amostra em pontos no Espaço das Características, agrupando-os em conjuntos que representam as classes.

Ruído: são falhas, distorções ou ainda imprecisão que ocorrem durante processo de aquisição dos dados.

A Figura 9 ilustra e exemplifica alguns dos principais conceitos.

Figura 9- Principais conceitos de Reconhecimento de Padrões.



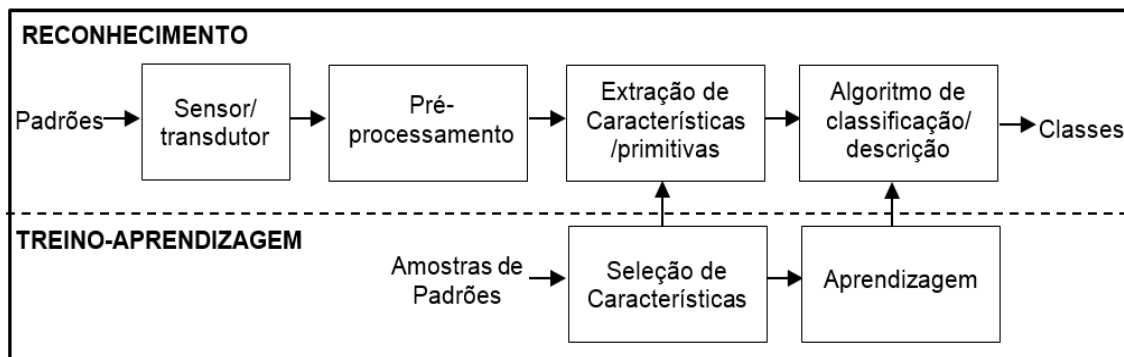
Fonte: do próprio autor.

4.3 SISTEMA DE RECONHECIMENTO DE PADRÕES

O projeto de um sistema de RP se desenvolve em etapas com graus de complexidade variando de acordo com o problema. Sua eficiência está diretamente relacionada com a correta aplicação e a otimização em cada etapa. Não há unanimidade entre os principais autores estudados na representação de um sistema de RP (TEODORIDS; KOUTROUMBAS, 2009; DUDA; HART; STORK, 2001), provavelmente porque a RP consolidou-se a partir de contribuições de outras áreas e cada uma delas tem especificidades, o que torna difícil compor um fluxograma genérico.

Na proposta de Fred (2015), que parece mais abrangente, um sistema de RP se desenvolve em duas fases: a fase de reconhecimento ou fase operacional, e a fase de treino-aprendizagem, conforme se observa na Figura 10.

Figura 10- Estrutura típica de um Sistema de RP .



Fonte: Fred (2015) adaptada.

4.3.1 Fase de treino-aprendizagem

Para Duda, Hart e Stork (2001), nessa fase ocorre o treinamento do sistema para que a etapa de classificação reconheça e decida se o dado de entrada possui ou não as características desejadas. A Fase de Treino-aprendizagem realiza a seleção de características a partir de um conjunto de objetos de exemplo, também chamado de conjunto de treino ou amostra. A partir das características obtidas segue-se o processo de aprendizagem propriamente dito.

A escolha das características é a seleção dos parâmetros que melhor definem o objeto de acordo com sua natureza, a natureza da aplicação e a tecnologia existente. O conjunto de medidas e valores obtidos nessa fase devem ser similares para objetos da mesma classe e distintos para classes diferentes. A escolha criteriosa de características pode evitar a redundância na fase de classificação.

A aprendizagem é a etapa que define ou estima as funções de decisão a ser usadas pelo algoritmo de classificação. De acordo com Theodoridis e Koutroumbas (2009), existem basicamente três formas de aprendizagem:

- **Supervisionada** – ocorre a partir de classes pré-definidas e padrões do conjunto de treinamento, identificados como pertencentes à alguma delas. Dada a Equação (2), admite-se a existência de um conjunto de amostras de padrões (\mathfrak{S}) em que suas classes são conhecidas;

$$\mathfrak{S} = \{(x_1, k_1), (x_2, k_2), \dots, (x_m, k_m)\} \quad (2)$$

Sendo x_i – representa a i -ésima observação ou padrão

k_i – representa a classe do padrão

m – número de amostras disponíveis

- **Não-supervisionada** - ocorre quando as classes não são conhecidas inicialmente, elas são identificadas pela similaridade entre os padrões de entrada, ou seja, o formalismo é idêntico ao anterior, entretanto o k_i é desconhecido;
- **Semi-supervisionada** – É similar as supervisionadas, no entanto, existem na amostra padrões que diferem excessivamente e não se identificam com classe alguma pré-estabelecida. A aprendizagem semi-supervisionada torna-se importante quando o projetista tem à disposição um número reduzido de dados.

4.3.2 Fase de reconhecimento

Para Duda, Hart e Stork (2001), a também chamada de Fase Operacional, é a fase que, a partir do conjunto de classes e características identificados na fase anterior, enquadra-se um conjunto maior de padrões. Geralmente, subtrai-se do conjunto total de padrões uma pequena parte representativa para uso na Fase de Treino-aprendizagem, deixando-se a grande massa de padrões para a Fase de Reconhecimento.

A etapa Sensor/Transdutor é aquela em que ocorre a aquisição dos padrões por meio de algum dispositivo de entrada/saída. Esta etapa se encerra com o armazenamento do padrão em algum meio eletrônico.

O Pré-processamento prepara os dados para serem tratados na etapa posterior, eliminando ruídos, melhorando e realçando a qualidade dos dados adquiridos na etapa anterior. Diversos procedimentos podem ser aplicados com esse objetivo, tais como filtragem, ganho, etc. Em alguns casos a normalização é exigida, ou seja, a conversão proporcional dos dados dentro de uma faixa de valores, geralmente 0 e 1. Essa fase se encerra com a obtenção de padrões com qualidade.

A Extração de Características visa identificar nos dados, as características que permitam o reconhecimento de padrões, ou seja, obter um conjunto de características com dimensão inferior que o dado bruto, que mesmo assim permita discriminá-lo. Essa seleção é processada a partir de características já identificadas na fase de treino-aprendizagem. (THEODORIDIS; KOUTROUMBAS, 2009)

A etapa de aplicação do Algoritmo de Classificação utiliza o vetor de características para atribuir cada objeto à uma classe. A diferença de valores atribuídos às características dos objetos de diferentes classes influencia no grau de dificuldade do problema. O problema mais crítico nessa etapa é a escolha do classificador, pois influencia demasiadamente na eficiência do processo. (DUDA; HART; STORK, 2001)

Os classificadores diferem no desempenho e na estratégia de separação de padrões. Em certos casos não há opção na escolha de classificador.

Essa etapa pode ser desenvolvida usando técnicas diversas e é o fator mais relevante que distingue as abordagens a serem apresentadas nos itens seguintes.

4.3.3 Considerações sobre sistemas de RP

Apesar do fluxo da Figura 10 representar uma perspectiva ampla, a sua aplicação apresenta alguns problemas que exigirão adaptações. A primeira e a mais evidente é de que em sistemas de aprendizagem não-supervisionada as fases de treino e reconhecimento ocorrem simultaneamente, sem a necessidade de amostra de padrões.

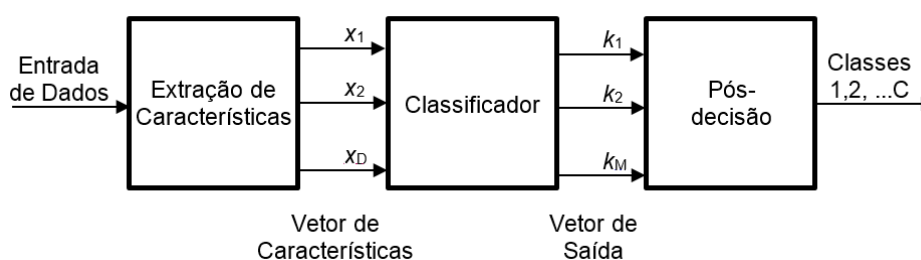
Para Duda, Hart e Stork (2001) o fluxo é único e sequencial com três etapas: pré-processamento, extração de características e classificação, executadas num sentido e depois no reverso. Para Theodoridis e Koutroumbas (2009) em fase única, cinco etapas são necessárias: aquisição de dados, geração de características, seleção de características, desenho do classificador e sistema de avaliação, executadas sequencialmente mas sempre considerando a possibilidade de retornar a alguma das anteriores.

4.3.4 Projeto de sistema de reconhecimento de padrões

Um projeto de sistema de RP inicia com a seleção de amostras que sejam representativas e em seguida efetua-se a escolha das características.

Considerando que as etapas principais de um sistema de RP podem ser representadas como no diagrama da Figura 11, as quais tem objetos de entrada associados a um vetor x , cuja dimensão é D , e saída associada a um vetor de classes de dimensão M . Considerando que x está associado a um número de classes k , então, o aumento da dimensão do vetor de característica minimiza a ocorrência de erros, no entanto aumenta a complexidade do problema com o aumento na exigência de recursos. (DUDA; HART; STORK, 2001)

Figura 11- Sistema de RP reduzido.




Fonte: Duda, Hart e Stork (2001)

O classificador é a função que define as fronteiras de decisão que delimitam as classes no espaço de características, como ilustra a Figura 12, ele deve ter uma boa capacidade de generalização. Assim, três situações são admissíveis (DUDA; HART; STORK, 2001):

- **Sub-treinamento** – tem fronteira de decisão muito simples, seu desempenho na classificação é em geral insatisfatório, a exceção de problemas simples linearmente separáveis, como ilustra o item (a) da Figura 12;
- **Super-treinamento** – tem fronteiras demasiadamente complexas, seu desempenho na classificação é eficiente, entretanto, exige elevado número de recursos e interações e tende a responder bem apenas ao conjunto de treinamento, só é satisfatório para pequenas amostras, como ilustra o item (b) da Figura 12;
- **Treinamento adequado** – fronteira de decisão otimizada, seu desempenho admite a ocorrência de algum erro, mas é eficiente e satisfatório na classificação de padrões, conforme o item (c) da Figura 12.

Figura 12- Tipos de treinamentos resultantes das fronteiras de decisão



Fonte: Duda, Harte e Stork (2001).

O desempenho do classificador está diretamente relacionado ao tamanho da amostra de objetos, o número de características e também de sua complexidade.

Por mais simples que seja um problema de RP sempre haverá a possibilidade de requerer que a dimensão da amostra de objetos para treinamento seja uma função exponencial da dimensão do vetor de características. Esse fenômeno é conhecido como a “maldição da dimensionalidade”, pois amplia em muito a complexidade do problema (JAIN; DUIN; MAO, 2000).

4.4 ABORDAGENS DE RECONHECIMENTO DE PADRÕES

Historicamente, a abordagem estatística de RP e a sintática são as mais antigas, algum tempo depois surgiram as abordagens conexionista ou neuronal, com o advento das RNA e também os métodos voltados para programação matemática. (JAIN; DUIN; MAO, 2000)

Apesar da classificação das abordagens em RP considerarem limites bem definidos entre elas, em geral, sob a ótica do par problema-solução, considera-se a possibilidade de combinação entre elas, o que na prática é bastante usual. A própria literatura acerca de RP faz considerações e interpretações diferentes acerca de métodos e abordagens.

Segundo Duda, Hart e Stork (2001), é possível classificar o RP nas abordagens a seguir.

4.4.1 Abordagem estatística

Trata-se de uma abordagem clássica e bastante disseminada, evoluiu da Teoria de Decisão Bayesiana, onde os modelos probabilísticos regem definição das características das classes. Essa teoria provê bases para modelar as fontes que geraram os padrões.

Os métodos estatísticos permitem obter resultados com rapidez e se adequam em circunstâncias onde o aspecto mais importante é evidenciar tendências relevantes e descartar as que não são.

Segundo Duda, Hart e Stork (2001), a classificação é feita identificando-se a probabilidade de um padrão pertencer ou não a uma determinada classe, e também associando a decisão a um fator de risco na ocorrência de erro.

Considere o vetor de padrões $\mathbf{x} = (x_1, x_2, \dots, x_D) \in \mathbb{R}^D$ tal que D é o número de características. Considere também as classes $\mathbf{k} = \{k_1, k_2, \dots, k_M\}$ em RP. A abordagem Bayesiana supõe que as probabilidades $P(k_i)$ de cada classe e as densidades de probabilidade condicional $p(x|k_i)$ de x com respeito a cada uma das classes k_i tal que $i = 1, 2, \dots, M$, são conhecidas.

Admite-se classificar um padrão x como associado à uma classe k_i , sendo esta a de maior probabilidade.

Podemos então utilizar o teorema de Bayes para calcular a probabilidade $P(k_i|x)$, que é a probabilidade de x pertencer à classe k_i , pelas Equações (3) e (4):

$$P(k_i|x) = \frac{P(k_i) p(x|k_i)}{p(x)} \quad (3)$$

$$p(x) = \sum_{i=1}^M p(x|k_i) \cdot P(k_i) \quad (4)$$

Sendo: $p(x|k_i)$ - densidade de probabilidade

$p(x)$ - fator de evidência para ajustar escala para que a soma de todas as probabilidades posteriores seja 1;

A decisão possui um risco de erro condicionado, podendo ser calculado pela Equação (5):

$$\mathcal{R}(k_i|x) = \sum_{j=1}^c \lambda(k_i|k_j) \cdot P(k_j|x) \quad (5)$$

Sendo: $\lambda(k_i|k_j)$ – função perda atribuída à classificação errada, atribuído valor 1 para classificação correta e 0 para as erradas. Como na Equação (6).

Sendo assim:

$$\lambda(k_i|k_j) = \begin{cases} 0 & \text{se } i = j \\ 1 & \text{se } i \neq j \end{cases} \quad (6)$$

E o risco condicional definido pela Equação (7):

$$\mathcal{R}(k_i|x) = 1 - P(k_i|x) \quad (7)$$

4.4.2 Abordagem sintática

Em casos em que um padrão é definido pela inter-relação entre as características, ou seja, existem características descritoras primitivas ou sub-padrões, comuns entre elas, é possível estabelecer um conjunto estruturado. Nestes casos, as classes são definidas pela similaridade de estrutura dos padrões.

A estratégia assim definida é interessante para RP em estudos de linguagem, onde os padrões complexos (frases) são quebrados em sub-padrões (palavras) e a gramática seria o classificador destes padrões.

4.4.3 Abordagem difusa

Trata-se da abordagem em que é importante considerar um certo grau de incerteza nas características e na classificação dos padrões. É um método não-determinístico geralmente vales da lógica nebulosa. Neste caso, a Teoria dos Conjuntos Difusos é empregada para conferir ao modelo o grau de incerteza.

4.4.4 Abordagem neuronal

Trata-se da abordagem inspirada nos neurônios biológicos, faz uso de um conjunto de neurônios artificiais interconectados por sinapses sobre as quais aplica-se pesos diferentes, modificados até reproduzirem os resultados corretos, esboçando assim um comportamento inteligente, capaz de aprender determinadas tarefas sem que sejam necessariamente formalizadas matematicamente. Por essa razão, é vista como um dispositivo tipo “caixa preta”, dispensando assim um conhecimento prévio de muitos elementos do padrão. Isso a torna ideal

para problemas de RP em fala, escrita, imagens e etc. nessa abordagem a quantidade de processamento gerado é grande (JAIN; DUIN; MAO, 2000).

O próximo capítulo trata das RNA do tipo ARTMAP Nebulosa, sua origem, característica e topologia, bem como a adequabilidade desta abordagem conexionista na solução de problemas de RP.

CAPÍTULO 5

REDES NEURAIAS ARTMAP-NEBULOSAS

As redes neurais artificiais constituem-se atualmente num recursivo conjunto de formalismos bioinspirados para solução de problemas relacionados ao Reconhecimento de Padrões. A diversidade de estratégias adotadas para essa abordagem é crescente. A compreensão dos conceitos, princípios e especificidades em que se baseiam, conferem aos pesquisadores elementos para escolha da RNA que melhor se adapta ao seu problema, a respeito das quais é possível encontrar no Anexo A desse trabalho. As redes neurais ARTMAP Nebulosas, baseadas na Teoria da Ressonância Adaptativa (ART) apresentam-se como uma solução viável para solução de problemas de RP.

5.1 TEORIA DA RESSONÂNCIA ADAPTATIVA

O modelo ART tem como antecedente Von der Malsburg que em 1973 apresentou uma RNA de mapa de características auto-organizável como objetivo de modelar o córtex visual. Posteriormente, Teuvo Kohonen apresenta o conceito de Mapa Auto-organizável (*Self-Organizing Maps* – SOM), que acabaram por influenciar Gail Carpenter e Steven Grossberg a criarem a Teoria da Ressonância Adaptativa. (AMORIM, 2006)

A motivação destes trabalhos foi a solução do dilema plasticidade–estabilidade, que pode ser definido em 3 pontos (CARPENTER et al.,1992):

- **Plasticidade** – capacidade de um sistema de aprendizagem de se adaptar quando submetido a novas informações e se manter estável mesmo quando houver informação irrelevante entre elas;

- **Estabilidade** – capacidade de um sistema em preservar seu conhecimento adquirido e mantendo a capacidade de armazenar novas informações;
- Capacidade de um sistema em alternar a escolha que vai priorizar, seja a plasticidade ou estabilidade.

A Teoria da Ressonância Adaptativa se caracteriza como uma resposta a esse dilema. As RNAs que contemplam esse paradigma permitem aprendizagem incremental, em ambientes não-estacionários, estável e rápida. Permite uma generalização múltipla para um reduzido número de padrões de treinamento. São adequadas para aplicações que necessitem modelar previsão, busca, aprendizagem, RP em tempo real e aplicações para engenharia. (CARPENTER; GROSSBERG, 1987)

A estabilidade em redes ART é inerente, pois os processos de adaptação dos pesos tendem a diminuir até a sua estabilização. No RP, quando um padrão de entrada não se enquadra em alguma classe já existente uma nova é criada. Para não comprometer a estabilidade como ocorrem em outras RNAs, um mecanismo de vigilância controla as novas entradas e sua inclusão ou não em classes já existentes. (AMORIM, 2006; CARPENTER; GROSSBERG, 1987)

5.2 REDES NEURASIS ART

A rede neural do tipo ART incorpora o modelo de aprendizagem competitiva sob uma estrutura de controle auto-organizável. Sendo assim, o reconhecimento e o aprendizado autônomo permanecem estáveis independente da sequência de padrões de entrada. (AMORIM, 2006)

A Tabela 3 lista alguns marcos históricos de propostas de redes de arquitetura ART encontradas na literatura a partir do levantamento de Amorim (2006), até o ano de 2005.

Tabela 3- Marcos históricos relacionado com redes ART na literatura.

Ano	Arquitetura	Referência
1976	GN	Grossberg
1987	ART1 ART2	Carpenter Carpenter
1990	ART3	Carpenter
1991	ART 2-A ARTMAP <i>Fuzzy-ART</i>	Carpenter Carpenter Carpenter
1992	<i>Fuzzy-ARTMAP</i> AFCL <i>Fuzzy Min-Max Neural Network(FMMNN)</i>	Carpenter Newton Simpson
1993	LAPART <i>Simplified Fuzzy-ARTMAP (SFAM)</i> <i>Fusion ARTMAP</i>	Healy Kasuba Asfour
1994	IAFC	Kim
1995	ART-EMAP <i>Adaptive Hamming Net (AHN)</i> ARAM PROBART	Carpenter Hung Tan Marriot
1996	Gaussian-ARTMAP FasArt hART-J	Williamson Cano-Izquierdo Barfai
1997	<i>Supervised AHN (SAHN)</i> hART-S mART ART-LD FasBack dART, dARTMAP Cascade-ARTMAP PNN-ART	Hung Barfai Kim Zhou-J. Cano-Izquierdo carpenter Tan Lim
1998	ARTMAP-IC LAPART2 <i>Multi-channel ART (MART)</i> <i>Boosted ARTMAP</i>	Carpenter Healy Fernández-Delgado Verzi
1999	<i>Fuzzy (Supervised) AHN</i> ARTEX <i>FA Variant</i> oFAM dFasArt	Hung Grossberg Georgiopoulos Dagher Parrado-Hernández
2000	MicroARTMAP (μ ARTMAP) HART & HARTMAP FANNC	Gómez-Sánchez Anagnostopoulos Zhou-Z.
2001	<i>Ellipsoid ART (EA) & Ellipsoid ARTMAP (EAM)</i> <i>Safe μARTMAP</i>	Anagnostopoulos Gómez-Sánchez
2002	<i>semi-supervised Ellipsoid ARTMAP (ssEAM)</i> ART-C	Anagnostopoulos He
2003	AFC <i>Default ARTMAP</i>	Sapozhnikova Carpenter
2004	<i>Simplex ARTMAP (SAM)</i> <i>Analog-ART1</i> ARTSTREAM	Gomes Rajasekaran Grossberg
2005	GreyART <i>PolyTope ARTMAP (PTAM)</i> <i>Overlapping PolyTope ARTMAP (OPTAM)</i>	Yeh Gomes Gomes

Fonte: Amorim (2006).

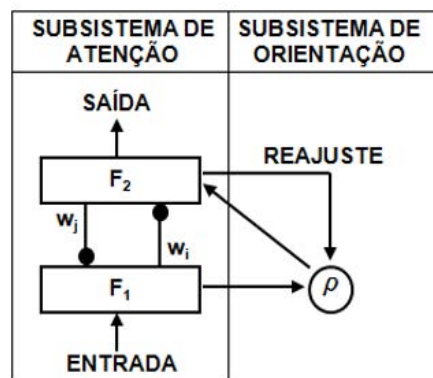
A aprendizagem em uma rede ART ocorre quando a informação dos neurônios oscila entre as suas camadas, alterando seu estado de ativação até chegar a um equilíbrio (ressonância). Caso não ocorrer ressonância em nenhuma classe a partir de um padrão de entrada, uma nova classe será criada. A capacidade da rede ART de se adaptar e se reorganizar com rapidez lhe conferiu plasticidade e estabilidade superior aos outros modelos de RNA até então propostos.

5.2.1 Redes neurais ART-1

Para Freeman e Shapura (1991), a rede ART-1 evoluiu da *Grossberg Network* (GN) e trata-se de uma rede não supervisionada que admite apenas padrões de entrada binários. Tecnicamente pode ser vista como um conjunto de equações diferenciais não-lineares que contemplam características de plasticidade-estabilidade com aprendizagem incremental.

Uma rede ART-1, conforme a Figura 13, tem arquitetura constituída de dois subsistemas: o Subsistema de Atenção e o Subsistema de Orientação, eles atuam na verificação de similaridade entre um padrão presente e um neurônio treinado e um outro padrão apresentado, dessa forma habilitam ou não o treinamento do neurônio, de acordo com (CARPENTER et al. (1992).

Figura 13- Estrutura de uma Rede ART-1.



Fonte: Carpenter, Grosberg e Rosen (1991).

Para Carpenter et al. (1992), o Subsistema de Atenção possui duas camadas de neurônios: F_1 e F_2 . A camada F_1 processa dados de entrada, armazenando o vetor de entrada A e concatenando seu complemento A^c ao final da cadeia, ficando a entrada I definida como na Equação (8):

$$I = [A A^c] \quad (8)$$

A ocorrência de uma entrada provoca o surgimento de traços de memória de curta duração (*Short-Term Memory – STM*) que são padrões de ativação destas unidades.

A camada F_2 , agrupa padrões de treinamento em categorias internas de reconhecimento (*clusters*) aprendidas pela rede. Esses campos são conectados com pesos de conexão do tipo *feedforward* (w_i) e *feedback* (w_j) que são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento, podem ser chamados também de memórias de longa duração (*LTM - Long-Term Memory*) pois representam a memória que permanece quando se retira o padrão de entrada em F_1 . (CARPENTER et al., 1992)

O Subsistema de Orientação é caracterizado pelo parâmetro de vigilância ρ , que gerencia a busca de coincidência de padrões no processo de aprendizagem, inibindo unidades em F_2 . Caso a atividade em F_2 for elevada e suficiente, esse subsistema fica desativado permitindo que unidades (neurônios) em F_2 possam ser ativadas, conforme (FREEMAN; SHAPURA, 1991).

A rede ART-2 possui a mesma arquitetura da ART-1 e tem a capacidade de categorizar padrões digitais e também analógicos. Possui mecanismos de normalização e filtragem que permitem eficiente eliminação de ruídos. (CARPENTER; GROSSBERG, 1987).

5.2.2 Redes neurais ART-nebulosa

De acordo com Carpenter e Grossberg (1992), a rede ART-Nebulosa possui uma arquitetura similar a da ART-1, porém, adota no lugar da teoria clássica de conjuntos, a teoria de conjuntos nebulosos ou *Fuzzy*. Na visão de Amorim (2006), uma camada adicional F_0 deve ser considerada, esta incorpora a codificação de I , conforme ilustra a Figura 14.

A camada F_0 tem a mesma dimensão M do padrão, já a camada F_1 tem dimensionalidade $2M$. A camada F_2 é a camada de representação de categoria interna cada uma ligada a uma unidade (neurônio).

Nela, a aprendizagem ocorre da seguinte forma:

Na camada F_0 , o padrão é recebido e a entrada I é codificada e recebida por F_1 e F_2 .

Na camada F_2 o vetor de treinamento T_j é calculado com uso do operador AND-nebuloso, conforme a Equação (9):

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (9)$$

sendo o parâmetro α uma taxa de escolha arbitrada pelo usuário e tem baixa magnitude ($\alpha \approx 0$). O neurônio vencedor J , corresponde ao índice do maior T_j . Essa função de escolha de categoria é conhecida como Lei de Weber.

Em seguida, já no Subsistema de Orientação verifica se I pertence a classe w_j , assim sendo, a função de casamento da Equação (10) resulta num valor que é comparado ao parâmetro de vigilância ρ :

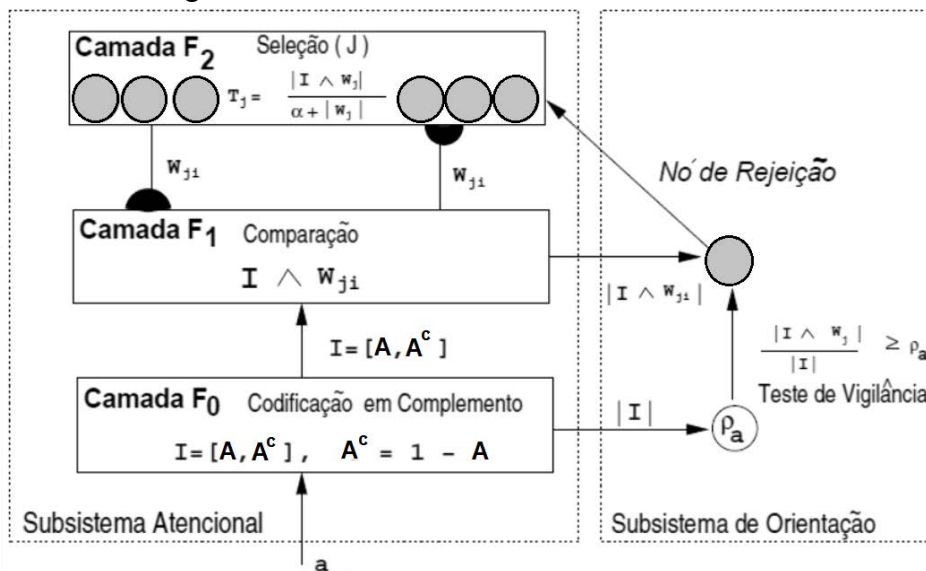
$$f(I, w_j) = \frac{|I \wedge w_j|}{|I|} \geq \rho \quad (10)$$

Caso resulte em verdadeira, diz-se que houve ressonância, o peso w_j é atualizado e a rede aprende um novo padrão de entrada, caso contrário um novo neurônio é criado para aprender um novo padrão. Assim que as condições de casamento são satisfeitas é ativado o estado de ressonância e ocorre aprendizagem definida na Equação (11):

$$w_j^{novo} = \beta(I \wedge w_j^{ant}) + (1 - \beta)w_j^{ant} \quad (11)$$

sendo que β denota a taxa de aprendizagem e w_j denota o j -ésimo peso de neurônio vencedor corrente (ant) ou novo(novo).

Figura 14- Estrutura de uma rede ART-Nebulosa



Fonte: Amorim (2006).

O parâmetro β expressa a velocidade de aprendizagem e $\beta \in (0,1]$. Assim, quando $\beta=1$, temos a maior velocidade de aprendizagem.

Para Amorim (2006), a rede ART-Nebulosa difere da ART-1 principalmente porque o fluxo de informações entre F_1 e F_2 é feito pelo conjunto único de pesos w_j e por necessitar de

pré-processamento (normalização) para evitar a proliferação de categorias, e também pela lógica de operadores adotada, conforme a Tabela 4.

Tabela 4- Equivalências entre as redes ART1 e ART-Nebulosa.


Características	ART1	ART - Nebulosa
Natureza dos Dados	Binário	Contínuo (em $[0, 1]$)
Operador	<i>AND</i> lógico (\cap)	<i>AND fuzzy</i> (\vee)
Função de Escolha de Categoria	$\frac{ I \cap w_j }{ w_j }$	$\frac{ I \wedge w_j }{\alpha + w_j }$
Critério de coincidência	$\frac{ I \cap w_j }{ I } \geq \rho$	$\frac{ I \wedge w_j }{ I } \geq \rho$
Aprendizagem <i>fast-learning</i>	$w_J(n+1) = I \cap w_J(n)$	$w_J(n+1) = I \wedge w_J(n)$

Fonte: Amorim (2006) modificado.

5.3 REDES NEURAIAS ARTMAP

As redes ARTMAP diferenciam-se da ART por ser supervisionada e formada por dois módulos ART: a sub-rede ARTa, que recebe e processa um padrão de entrada apresentado e uma sub-rede ARTb, que configura a resposta desejada para o padrão apresentado. Um módulo de memória associativa, denominado InterART, interliga os módulos da sub-rede e realiza o mapeamento, ilustrado na Figura 15, conforme Carpenter e Grossberg (1987).

Figura 15- Arquitetura da Rede ARTMAP



Fonte: Carpenter e Grossberg (1987).

O erro preditivo é corrigido por uma regra, o *match tracking*, que controla o incremento mínimo (ϵ) contínuo do parâmetro de vigilância da ARTa. Cada módulo ART possui uma matriz de pesos associados que são inicializadas como uma matriz unitária, considerando assim inicialmente todas as atividades inativas. O estado dessas atividades pode ser alterado com a ocorrência de ressonância entre os padrões de entrada e saída. (LOPES; MINUSSI; LOTUFO, 2005).

5.3.1 Rede neural ARTMAP-nebulosa

A rede ARTMAP-Nebulosa difere da ARTMAP clássica, basicamente por adotar a teoria de conjuntos nebulosos no tratamento dos padrões.

De acordo com Canuto et al. (1999) esse tipo de aprendizagem oferece a vantagem de fácil extração de conhecimento, pois a associação de padrões é alcançada por neurônios individuais; inexistência de perda do aprendizado pelo fato de implementar os neurônios individualmente; a rápida aprendizagem em decorrência da verificação rápida e constante da saída; aprendizagem estável e o reconhecimento e predição.

Segundo Canuto et al. (1999), existem também alguns inconvenientes como a proliferação de categorias devido à sensibilidade aos ruídos, ocasionando má classificação, o que pode ser reduzido com a escolha adequada dos parâmetros de vigilância e um pré-processamento adequado.

O uso de RNA, tal como os processos de RP, ocorre em duas fases, a fase de treinamento e a fase de teste, que serão descritas a seguir.

i. Fase de Treinamento

As matrizes \mathbf{I}_a e \mathbf{I}_b são obtidas pela concatenação da matriz \mathbf{A} (dados de entrada) e \mathbf{B} (dados de saída) com seus respectivos complementos. Os parâmetros de vigilância ρ_a , ρ_b e ρ_{ab} e os percentuais de atualização aplicados aos pesos, α e β , devem ser definidos de forma empírica embora haja uma certa lógica implícita na escolha dos mesmos. Os parâmetros de vigilância pertencem ao intervalo $[0,1]$ representam na prática a proximidade esperada das características do padrão com as de uma categoria já identificada. Assim, caso o padrão não alcance esse índice, uma outra categoria é criada, ou seja, quanto maior é o valor, mais fino e rigoroso é a adaptação da rede. Tem-se como entrada a matriz \mathbf{A} e como saída o vetor \mathbf{B} , o resultado é expresso nas matrizes de peso \mathbf{W}_a , \mathbf{W}_b e \mathbf{W}_{ab} , que serão usadas na etapa de testes. (LOPES et al., 2005)

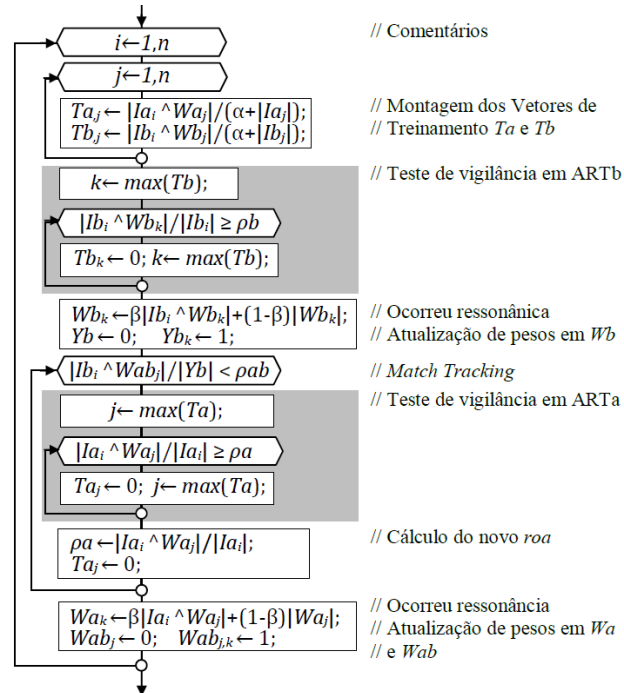
O *match tracking* atua, no caso de ARTMAP-nebulosas, toda vez que ocorre ressonância entre padrões de entrada e saída, os pares a e b associados as ART_a e ART_b devem ser confirmados pelo teste da Equação (12):

$$|x^{ab}|_i = \frac{|y_i \wedge w_j^{ab}|}{|y_i|} \quad (12)$$

Caso $|x^{ab}|_i \geq \rho_{ab}$, o par é confirmado nas matrizes de peso, caso contrário deve se buscar outro índice j até que o critério seja satisfeito. (CARPENTER; GROSSBERG, 1987).

Para compreensão da fase de treinamento da rede ARTMAP-Nebulosa, o fluxograma da Figura 16 está devidamente comentado. Ele foi obtido a partir de Lopes et al. (2005), que se encontra no Anexo B desse trabalho, adaptado para o paradigma estruturado e comentado.

Figura 16- Fluxograma do algoritmo de treinamento de uma rede de ARTMAP-Nebulosa.



Fonte: do próprio autor.

ii. Fase de Teste

O algoritmo de teste da RNA segue um roteiro específico proposto por Decanini et al. (2011):

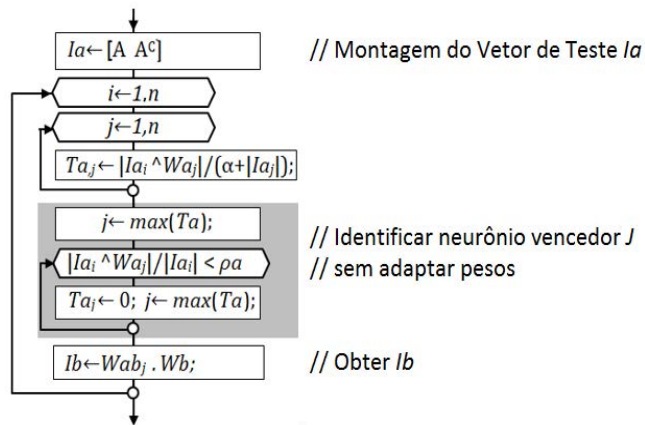
1. Determinar os vetores de teste a e I_a ;
2. Identificar o neurônio vencedor J da rede ARTa, sem adaptar pesos;
3. Calcular I_b a partir de B , conforme as equações (13) e (14):

$$\mathbf{I}_b \equiv \mathbf{W}_J^{ab} \mathbf{W}^B = [b_1 \ b_2 \ \dots \ b_{M_b} \ b_1^c \ b_2^c \ \dots \ b_{M_c}^c] \quad (13)$$

$$\mathbf{B} = [b_1 b_2 \ \dots \ b_{M_b}] \quad (14)$$

O fluxograma do algoritmo de teste assemelha-se ao trecho de *match tracking* da fase de treinamento, porém sem adaptação dos pesos, conforme a Figura 17.

Figura 17- Fluxograma do algoritmo de teste de uma rede de ARTMAP-Nebulosa.



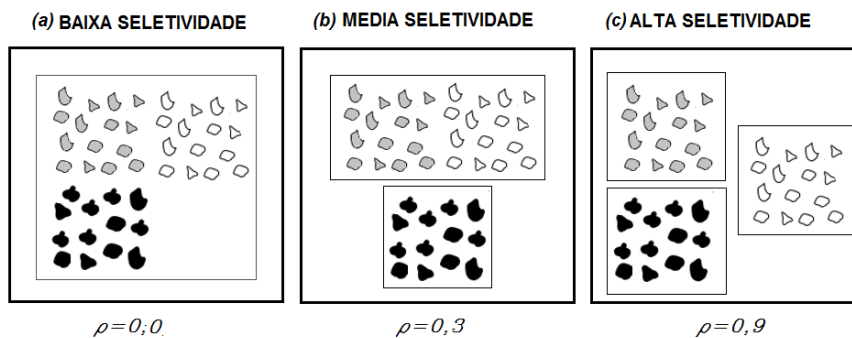
Fonte: do próprio autor.

Em termos práticos, a identificação do neurônio vencedor (J) permite apontar no vetor de padrões de saída B, aquele cujo valor corresponderia ao padrão de saída interpolado.

5.3.2 Parâmetros de vigilância e sua escolha

O parâmetro mais crítico no treinamento de uma rede de arquitetura ART é o parâmetro de vigilância. Sua função é controlar a resolução do processo de classificação dos padrões de entrada. O valor desse tem relação direta com a seletividade, conforme a Figura 18. Assim, valores baixos produzem baixa seletividade como ilustra a figura abaixo.

Figura 18- Efeitos da variação do parâmetro de vigilância



Fonte: do próprio autor.

O próximo capítulo trata da classe de aplicações chamada BCI, adequada para solução de problemas como o objeto desta pesquisa.

CAPÍTULO 6

INTERFACE CÉREBRO COMPUTADOR

O fascínio pelo cérebro inspirou o cientista alemão Hans Berger a criar a eletroencefalografia em seres humanos e a especular em seu *Elektrencephalogramm* em 1929, sobre a possibilidade de ler pensamentos através do traçado do EEG usando métodos matemáticos de análise. (BIRMAUMER, 2006).

Mais tarde Grey Walter, um dos pioneiros da EEG, construiu o primeiro analisador de frequência na expectativa de poder identificar pensamentos e linguagem no EEG humano. Em 1969, ele publicou suas experiências demonstrando que macacos aprendiam a controlar disparos elétricos no córtex motor primário. (DONCHIN; SPENCER; WIJESINGHE, 2000)

Dessa época aos dias atuais, técnicas de análise matemática, estatísticas e de inteligência artificial se somaram ao rol de ferramentas disponíveis para análises dessa natureza.

Esse capítulo faz uma apresentação da interface BCI como um sistema a ser consolidado a partir do embasamento de Reconhecimento de Padrões e de Redes Neurais Artificiais exposto em capítulos anteriores. A partir desse capítulo a abordagem se torna mais restritiva, na medida em que diante do conjunto de opções metodológicas apresentadas e as existentes, selecionam-se as que se adaptam aos termos desta pesquisa, justificando a escolha adotada.

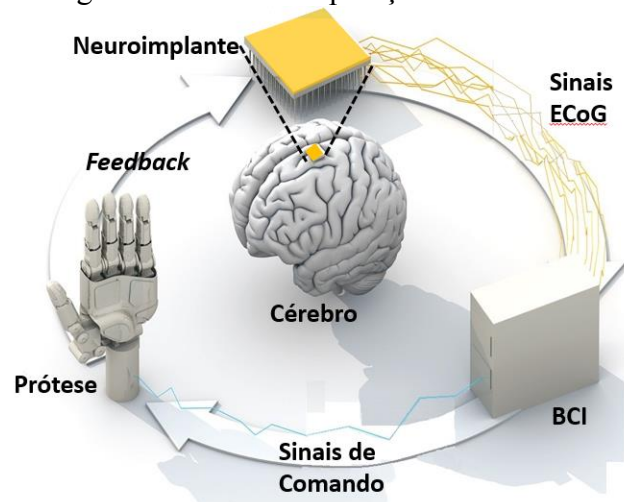
6.1 INTRODUÇÃO

A primeira evidência da relação entre a atividade elétrica cerebral e os estímulos dos sentidos foi constatada pelos estudos do físico Richard Caton em 1875 (CATON, 1875) e, em

1973, Jacques Vidal conseguiu identificar movimento dos olhos baseando-se em sinais EEG captados por sensores no escalpo (VIDAL, 1973).

Essa interface, tecnicamente, busca processar sinais obtidos diretamente do cérebro, identificando nestes sinais as ações determinadas mentalmente e comunicando esses comandos à dispositivos externos. Para o caso dos sinais ECoG, estes são captados por um neuroimplante, conforme a Figura 19.

Figura 19- Fluxo de operação de uma BCI.



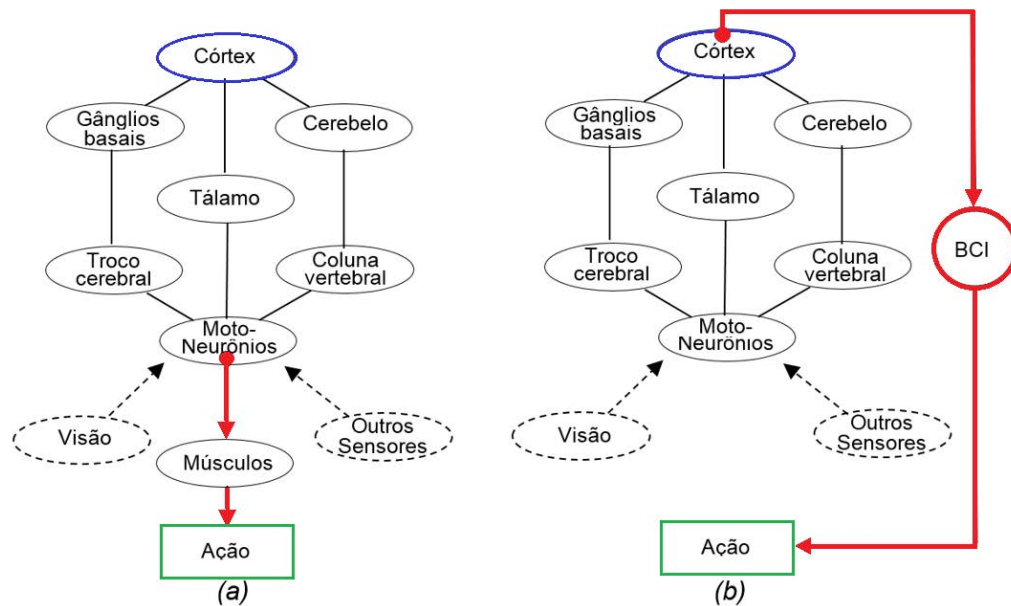
Fonte: do próprio autor.

O *feedback* presente na Figura 19 pode ser proporcionado pelos olhos do indivíduo. A quantidade de dados e estudos que explorem essa experiência ainda é escassa, pois deveria ocorrer apenas com indivíduos com o sistema motor danificado ou ausente. Segundo Graitmann, Allison e Pfurtscheller (2010), consistem num longo e elaborado treinamento visando diminuir a atividade na banda Teta e aumentando na banda Beta. Mesmo assim, apenas de 60 a 70% de indivíduos conseguem resultados satisfatórios em BCIs baseadas em EEG.

A neuroprótese é apenas uma sugestão de aplicação, mas já é usual em jogos, exoesqueletos, sistemas de controle de atenção de motorista, entre outros.

Conforme descrito no Capítulo 2 deste trabalho, a origem dos sinais da atividade motora do ser humano é o córtex cerebral. Para concretizar uma ação através dos membros do corpo o sinal passa interagindo com diversas estruturas do sistema nervoso. Essa interação é um processo metabólico e, demanda de um certo tempo, cerca de 100 ms (WOLPAW; WOLPAW, 2012).

Figura 20- Esquema comparativos entre (a) ações baseadas em músculos e, (b) as ações baseadas em BCI.



Fonte: Wolpaw e Wolpaw (2012).

A BCI proporciona um trajeto mais curto no corpo e de mais rápida resposta, pois é essencialmente eletrônica. A forma de interação dessas estruturas é conhecida pela medicina, e está relacionada ao processo cognitivo, o que é específico para cada indivíduo. O fluxo da informação é diferente quando se usa os músculos, em relação ao uso de BCI, conforme a Figura 20 (WOLPAW; WOLPAW, 2012).

6.2 TIPOS DE BCI

Segundo Norani, Mansor e Khuan (2010), a diversidade de métodos de implementação de BCIs sugere sua classificação de acordo com alguns critérios:

6.2.1 Transmissão de dados

A abordagem inicial para estes sistemas se resumia a aplicações estáticas circunscritas às salas de laboratórios (*stand-alone*). Assim sendo, os dados eram transmitidos por fios, ligando sensores e o restante da BCI. Com o advento seguro e de baixo custo de *hardware* e *software* para transmissão sem-fio, as aplicações ganharam plataforma móvel, podendo ser experimentadas de forma mais extensiva.

6.2.2 Invasibilidade

Quanto à aquisição de dados podem ser invasivos, quando o sensor é implantado diretamente no cérebro e os não invasivos – quando os sensores são externos à caixa craniana.

Para Anupama, Cauvery e Lingaraju (2012), admite-se ainda a classe dos parcialmente invasivos, que ocorre quando sensores são implantados no interior do crânio, entre a dura-mater e o córtex. A intensidade dos sinais obtidos é inferior à dos métodos plenamente invasivos mas tem uma durabilidade maior, já que o risco de ser encoberto por tecido cicatricial é menor e utiliza a mesma tecnologia dos métodos não invasivos. Para esses autores o ECOG é parcialmente invasivo.

6.2.3 Sincronismo

O sistema BCI é síncrono quando, estando operando, sua saída é afetada diretamente pelos desejos e intenções do usuário. Já os sistemas assíncronos são implementáveis em duas formas:

- **2-estados:** possuem a vantagem do usuário poder comandar simultaneamente mais de um dispositivo e ser mais flexível no controle deles;
- **3-estados** – essa é uma concepção de solução complexa, pois requer a análise contínua dos sinais, identificando se o usuário está produzindo sinais de controle em padrão reconhecível pela BCI: o controle intencional (IC); ou em outra atividade (ocioso, sonhando, etc.); o não controle (NC). O terceiro estado é o retorno ao IC. A duração dos estados é definida pelo sistema.

6.2.4 Sistemas híbridos

Nesses sistemas sinais de duas fontes são processados simultaneamente. Tais entradas podem ser do mesmo cérebro ou combinação de sinais do cérebro com os de outra procedência, de uma mão, por exemplo. Sua construção pode ser feita com mais de uma BCI em série, onde a saída de uma forneça entrada para outra. A vantagem dessa configuração é que uma das entradas possa funcionar com uma chave ativadora ou inibidora da outra.

6.3 O SISTEMA BCI


O formalismo a ser empregado na construção de uma BCI corresponde a de um problema de Reconhecimento de Padrões, pois essencialmente trata-se de identificar classes e características nos sinais correspondentes às ações executadas, a priori, por músculos do corpo.

Um sistema BCI corresponde à um problema de RP clássico, onde os padrões de entrada correspondem aos sinais cerebrais e as classes correspondem aos possíveis estados associados como por exemplo, a posição de membros. Entretanto, as características que definem cada padrão não são claramente conhecidas dada a complexidade do sistema nervoso.

Por outro lado, uma modelagem através de formalismo matemático-físico apresentaria também restrições pelo mesmo motivo. Todos esses fatos sugerem uma abordagem neural para o RP, pois tem a capacidade de adquirir conhecimento exclusivamente pelos dados de entrada, através de uma aprendizagem que envolve alto grau de liberdade.

É possível assim, adotar o fluxo proposto por Norani, Mansor e Khuan (2010), para sinais EEG e adaptado para sinais ECoG, conforme a Figura 21, que consiste nas etapas de aquisição e pré-processamento dos sinais, extração de características e sua posterior classificação. Tal proposta pode ser vista como uma versão simplificada e ajustada da apresentada na Figura 21.

Figura 21- Sequência de processamento de sinais em uma BCI.



Fonte: Norani, Mansor e Khuan (2010) adaptado.

Esse fato sugere, até pela similaridade, seguir as mesmas ferramentas utilizadas nos sistemas existentes já aplicados à EEG com eficiência, porém, com as devidas adaptações. A seguir são descritas as etapas, bem como as metodologias e processos que envolvem cada uma delas.

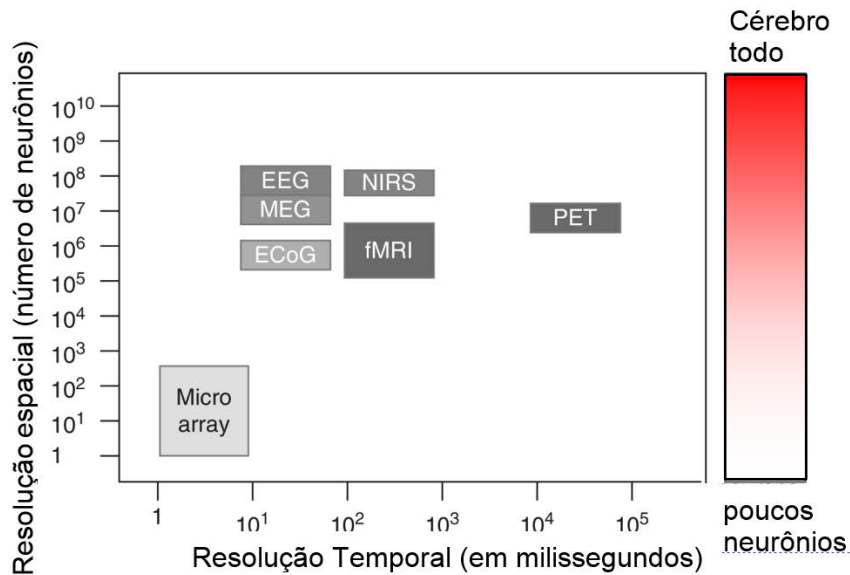
6.4 AQUISIÇÃO DE SINAIS

6.4.1 Sinais e resolução espacial

Como já exposto no tópico 3.5 deste trabalho, um dos fatores determinantes para eficiência de uma BCI é a resolução espacial e temporal do método de aquisição de sinais.

A Figura 22 apresenta a resolução em diferentes técnicas de aquisição de sinais cerebrais. O gradiente colorido representa a porção do cérebro medida num experimento.

Figura 22- Gráfico comparativo de técnicas de aquisição de sinais cerebrais.



Fonte: Wolpaw e Wolpaw (2012) adaptado.

Para Wolpaw e Wolpaw (2012), os métodos baseados em fNIR, atuam na captura de radiações infravermelhas que transpassam o cérebro. Entretanto, por estar vinculado ao fluxo sanguíneo, é considerado lento para uso em BCI's. Já nos fMRI as leituras das variações no fluxo sanguíneo são baseadas em magnetômetros e por isso tem resolução temporal lenta. Os métodos fNIR já encontram alguma aplicação em BCI, mas o fMRI ainda não encontram aplicação em BCI por causa da robustez de suas máquinas.

As tecnologias atuais disponíveis para aquisição de dados fazem uso de dois métodos: medida do campo elétrico - medição elétrica direta no tecido extracraniano (EEG) ou intracraniano (ECoG e micro-array) e os de medição da variação de campo eletromagnético modificado pelo metabolismo do cérebro e pelo fluxo sanguíneo (PET, fNIR e fMRI). (WOLPAW; WOLPAW, 2012)


Um estudo recente realizado por Chao et al. (2010) avaliou o reconhecimento em sinais ECoG de macacos, de movimentos de mão e braços por vários meses. E constataram não só que os padrões identificados permaneceram estáveis e inalterados em precisão. O sinal não degrada nem em características elétricas, inclusive os modelos usados para identificação desses padrões permaneceram eficazes por longo período. Isso permite concluir pela confiabilidade dos sinais ECoG

A superioridade qualitativa e quantitativa dos sinais ECoG em relação aos EEG foi identificada recentemente em estudos com seres humanos por (BALL et al., 2009; GUNDUZ et al., 2009; KUBANEK et al., 2009; PISTOHL et al., 2007; SCHALK et al., 2008; SANCHEZ et al., 2008; WALDERT et al., 2008).

6.4.2 Sensores

Para Graimann, Allison e Pfurtscheller (2010), a superioridade dos sinais ECoG em relação ao EEG é considerável, pois o ECoG possui fonte isolada de ruídos e resolução espacial maior. O ECoG possui também uma largura de banda de 0-300Hz, superior ao EEG que é de 0-40Hz, pois o couro cabeludo atua como filtro passa-baixa; também a amplitude que nos ECoG é de 50-100 mV, já nos EEG fica entre 10-20mV. Apesar do cuidado na colocação do implante de forma a cobrir região do córtex motor é uma operação imprecisa. É importante identificar e selecionar os eletrodos localizados na região de interesse, pois isso resulta em precisão da informação e redução do esforço computacional. A Figura 23 ilustra alguns tipos de implantes cerebrais.

Figura 23- (a) Microgrid, (b) Macrogrid para ECoG, c) Corte de um microgrid, (d) Instalação cirúrgica de um macrogrid para ECoG.



Fonte: Hazrati e Hofmann (2012) ampliado.

6.5 PRÉ-PROCESSAMENTO

6.5.1 Seleção de canais

Para Flamary e Rakotomamonjy (2012), a colocação dos implantes é uma operação imprecisa, no entanto é possível localizar a região dos sinais de interesse. A seleção de canais permite descartar sinais redundantes, manter os mais relevantes reduzindo a complexidade dos problemas e o esforço computacional e ainda aumentar o desempenho da estimação.

Os métodos mais populares são Algoritmos Genéticos, os algoritmos de informação mútua, o Critério de Fisher e a técnica do Padrão Espacial Comum (*Common Spatial Pattern* -

CSP). Além disso, outras abordagens com base em decomposição Wavelet e combinações ou evoluções dos métodos anteriores (MARTINEZ; IZQUERDO; IBARROLA, 2015). Estudos de Graimann, Allison e Pfurtscheller (2010) também acrescentam o teste estatístico paramétrico t de Student e o coeficiente de correlação bisserial, o que é referendado também por Duda, Hart e Stork (2001). No parecer de Arvaneh, Guan e Ang (2011) a diferença de performance entre os métodos usuais de seleção de canais EEG é sensível apenas para amostras pequenas e números pequenos de canais selecionados. No trabalho de Chiang et al. (2012) o mesmo padrão se repete para os sinais ECoG. Apesar de tecnicamente aplicável, nenhum trabalho relevante sugeriu o uso de análise de variância.

O método mais simples promove a desativação de canais que não exibam mudança de estado quando um dedo é movimentado por exemplo, quando o problema envolve movimento de dedos (LABBÉ; TIAM; RAKOTOMAMONJY, 2010). Apesar de facilmente implementável, a questão da similaridade e relevância não é detectada por ele, o que sugere a busca de métodos estatísticos já experimentados para seleção desses canais.

O teste t de Student é um teste de hipóteses paramétrico e consiste em formular uma hipótese nula ($\mu_x = \mu_y$) e uma hipótese alternativa. O cálculo do valor de t conforme (15), uma vez posicionado na curva de distribuição t , é possível determinar a densidade de probabilidade, permitindo aceitar ou rejeitar as hipóteses propostas. Na Equação (15), X e Y denotam as amostras e μ a média, S é a soma do quadrado dos afastamentos, (SOUZA, 1989).

$$t = \frac{(\bar{X} - \bar{Y}) - (\mu_{\bar{X}} - \mu_{\bar{Y}})}{S_{\bar{X} - \bar{Y}}} \quad (15)$$

Esse método é largamente utilizado em BCIs para EEG (GRAIMANN, ALLISON; PFURTSCHELLER, 2010; MIRANDA, 2014; CHOI, 2013, WOLPAW; WOLPAW, 2012).

6.5.2 Janelamento

Em alguns trabalhos, a segmentação da amostra facilita a extração de características. Cada segmento (janela) possui um comprimento definido. É possível criar janelas sobrepondo a parte final da janela anterior. Esse procedimento permite registrar em cada janela o seu estado anterior. Para esse trabalho decidiu-se não explorar essa possibilidade nessa fase do RP, pois será considerado na classificação.

O critério para definição do tamanho da janela geralmente é empírico, mas nesse caso tem-se um parâmetro de referência: o tempo que um sinal leva do córtex ao sistema motor do

corpo humano que é de 100ms aproximadamente, conforme (WOLPAW; WOLPAW, 2012). Isso significa que caso houvesse um possível feedback para reformular e interferir na decisão de movimento, isso não seria possível em menos de 100ms, mesmo que involuntário.

6.5.3 Filtragem

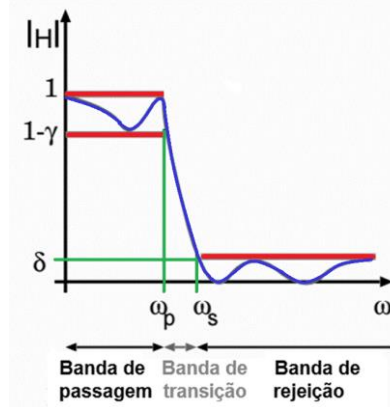
A filtragem consiste na remoção de ruídos característicos, conhecidos como “artefatos”, provenientes da rede elétrica e da atividade muscular de outros órgãos do corpo, tais como olhos, coração, etc.

O encapsulamento do córtex na caixa craniana o mantém isolado das fontes de artefatos. Um sinal ECoG sem filtragem apresenta qualidade bastante superior à de um sinal EEG filtrado (GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

De acordo com Sanchez et al. (2008) e Wolpaw e Wolpaw (2012) a flexão dos dedos está contida em bandas de frequência específicas de ECoG, desde então, essas bandas identificadas têm sido usadas intensivamente para extração de características. A dinâmica dos sinais gerados no córtex cerebral parece correlacionar-se com uma variedade de tarefas visuais, auditivas e motoras e, para efeitos dessa análise podem ser agrupados em quatro faixas de frequência: os potenciais lentos (1-60 Hz) que compreende ritmos como alfa, beta, etc., banda gama (60-100 Hz), banda gama rápida (100-300 Hz) e os agrupamentos despolarizados (300-6 kHz).

A separação do sinal em bandas pode ser efetuada com eficiência por filtragem. Apesar das informações contidas nas faixas abaixo de 60Hz, estima-se que as bandas superiores possuem uma carga maior de informação. Os filtros elípticos permitem efetuar a mais curta transição entre a banda passante e a banda de rejeição, como se observa na Figura 24. Esses filtros têm oscilações controladas tanto na banda passante como na banda de rejeição. (DINIZ et al., 2014)

Figura 24- Gráfico do Filtro Elíptico.



Fonte: Oppenheim e Schafer (1975).

A Equação (16) representa a magnitude da resposta em frequência (H_n) de um filtro elíptico passa-baixa, onde R_n é uma função racional de Chebyshev de ordem n . (OPPENHEIM; SCHAFFER, 1975; MADISETTI, 2010)

$$|H_n(j\omega)| = \frac{1}{\sqrt{1 + \epsilon^2 R_n^2(\omega p / \omega s)}} \quad (16)$$

Sendo: Banda de Passagem: $[0, \omega p]$
 Ripple na banda de passagem: γ
 Banda de transição: $[\omega p, \omega s]$
 Ripple da Banda de Rejeição: δ

6.6 EXTRAÇÃO DE CARACTERÍSTICAS

6.6.1 Conversão para o domínio da frequência

A ferramenta de maior uso no processamento de sinais digitais (PDS) é a Análise de Fourier que permite representar sinais no domínio da frequência. (DINIZ et al., 2014)

A transformação aplicada a sinais não-periódicos, como é o caso dos biosinais, para o domínio da frequência induz uma perda de informação no domínio do tempo, o que constitui sua principal limitação. A mudança de domínio aponta as frequências componentes do sinal, mas não quando elas ocorrem.

Alguns métodos minimizam essas perdas como é o caso da transformada de Fourier de curta duração (*Short Time Fourier Transform* -STFT) tem sido muito utilizada em PDS biológicos. (VETTERLI; KOVACEVIC, 1995)

Esse método multiplica o sinal por uma janela não nula no intervalo de tempo da referida análise e posterior transformação, assim sendo, o sinal pode ser considerado localmente estacionário. (OCAZIONEZ, 2009; INGLE; PROAKIS, 2012)

Métodos voltados para transformada *Wavelet* são também muito utilizados (DINIZ et al., 2014), e surgiram como uma alternativa ao STFT. Entretanto, para o presente caso, as informações referentes ao tempo não são importantes, uma vez que o sinal já foi segmentado em janelas de tempo, das quais se deseja obter as características, tornando importante apenas ocorrência de frequências e sua magnitude. Assim, optou-se por adotar a Transformada Discreta de Fourier (*Discret Fourier Transform - DFT*).

O algoritmo que implementa essa transformada de forma eficiente é chamado de Transformada Rápida de Fourier (*Fast Fourier Transform – FFT*), que é bastante usual em PDS e baseia no método de desbrobramentos sucessivos. A Equação (17) se refere a transformada DFT. (OPPENHEIM; SCHAFER, 1975)

$$F(u) = \frac{1}{N} \sum_{x=0}^{N-1} f(x)e^{-j2\pi/N} \quad (17)$$

Sendo que $F(u)$ é a transformada de $f(x)$ no intervalo 0 à $N-1$.

6.6.2 Autoregressão

A autoregressão é o método estatístico de estimação para séries históricas e procura aproximar um dado sinal por uma equação. Os coeficientes de autoregressão são utilizados com frequência para extrair características de vetores de sinais EEG relacionadas com ações motoras. Existem várias formas de determinar os coeficientes de autoregressão, o método de Burg encontra-se entre os principais.

De acordo com Bokehi, Simpson e Infantosi (1993), o Método de Burg é um modelo autoregressivo (AR) baseado na máxima entropia, utilizando um critério de mínimos quadrados. Nele, o comportamento matemático da série histórica (sinal) é caracterizado pela estimação de um número determinado de coeficientes. Esse método calcula todos os coeficientes diretamente dos dados. É recursivo e mais rápido que os demais e usa uma quantidade de coeficientes de ordem inferior à de outros métodos. A Equação (18) descreve matematicamente o referido método.

$$r_x(m) = \sum_{k=1}^N a_k r_x(m-k) + \sigma_\varepsilon^2 \delta'_m, \quad m = 0, \dots, N \quad (18)$$

$r_x(m)$ é a função de autocorrelação de x , σ é o desvio padrão e δ'_m é a função delta de Kronecker.

6.7 CLASSIFICAÇÃO DE SINAIS

De acordo com Aydemir (2011), a literatura apresenta diversos algoritmos de classificação de sinais EEG, tais como a Análise Linear de Discriminante (LDA), k-vizinhos mais próximos (k-NN), Máquinas de Vetor de Suporte (SVM), classificador de Markov oculto e as redes neurais. Uma avaliação nos métodos citados indica que o desempenho está fortemente relacionado com a dimensão do hiperplano de representação das características.

Praticamente não existem trabalhos relacionados com hiperplanos de baixa dimensão pois a eficiência do classificador está diretamente relacionada a sua dimensionalidade. Fatores como sensibilidade, especificidade, capacidade discriminante e tempo computacional também influenciam na performance do classificador. Segundo Aydemir (2011), o número de planos usados para representar o espaço de características do método determina sua dimensionalidade, sendo que a complexidade tem relação direta com a dimensionalidade.

6.7.1 Análise discriminante linear

A LDA parte do pressuposto de que duas classes estão sob distribuição normal com matrizes de igual covariância. A separação no hiperplano ocorre encontrando-se a projeção dos dados do treinamento de forma a obter a máxima distância entre as classes.

O principal objetivo é resolver a Equação (19):

$$y = z^t x + z_0 \quad (19)$$

em que x é o vetor de características, z e z_0 são vetores determinados pela maximização dos espaços entre as classes e minimização de variância entre as classes. Segundo Aydemir (2011), possui dimensionalidade 6-D.

6.7.2 k-vizinhos mais próximos

Suponha-se um conjunto D' de n -uplas (x_1, x_2, \dots, x_n) , em que (x_1, x_2, \dots, x_n) pertence à classe k . Para classificar a nova n -upla $Y' = (y_1, y_2, \dots, y_n)$, calcula-se as distâncias de Y a D e considera-se as n -uplas de treinamento mais próximas. Então Y será classificada como

pertencente a classe mais frequente. Segundo Aydemir (2011), esse método possui dimensionalidade 3-D.

6.7.3 Máquinas de vetor de suporte

No SVM os objetos são mapeados em categorias, divididos por um espaço claro e mais amplo possível. Os novos exemplos são então mapeados no mesmo espaço e atribuídos como pertencentes a uma categoria baseados em qual o lado do espaço eles são colocados. De acordo com Aydemir (2011), possui dimensionalidade 6-D.

6.7.4 Redes neurais

Para alguns autores a capacidade de generalização da SVM é superior à da RNA do tipo *Backpropagation* e tem dimensionalidade equivalente (BYVATOV et al., 2003; LIN, 2004; TYAGI, 2008). Entretanto, outros autores afirmam que dependendo do contexto de aplicação essa situação pode não ser conclusiva (BALABIN; LOMAKINA, 2011).

Para RNAs baseadas no paradigma da ART, apresentada no capítulo anterior, não existem estudos comparativos, entretanto a capacidade de generalização das RNAs ART é superior às suas antecessoras *backpropagation*, o que infere a possibilidade de generalização igual ou superior as SVM.

Em alguns trabalhos voltados para o RP de EEG em BCIs, a adoção das RNAs do tipo ARTMAP-nebulosa apresentou bons resultados, tais como (PALANIAPPAN; PARAMESRAN, 2002; RAVI; PALANIAPPANC; HENGB, 2006; ANDREWS, KIONG; KANNAN, 2015). Espera-se uma eficiência maior quando aplicados às ECoG, face a maior quantidade de informação disponível e ao baixo nível de ruído.

6.8 DESEMPENHO DE BCI

De acordo com Souza (1989), o parâmetro estatístico Coeficiente de Correlação Linear expressa a dispersão de uma amostra em relação ao valor esperado. Trata-se de um coeficiente adimensional r que varia de $-1,0 \leq r \leq 1,0$.

A proximidade com o valor 1,0 ou -1,0 indica respectivamente forte correlação positiva ou negativa. Já a proximidade com o valor 0 conota inexistência de correlação.

A Equação (20) define o coeficiente de correlação r , a partir de uma amostra de tamanho n , sendo x e y variáveis em que, uma representa a amostra e a outra representa o conjunto de valores esperado y ,

$$r = \frac{n \sum XY - \sum X \cdot \sum Y}{\sqrt{n \sum X^2 - (\sum X)^2} \cdot \sqrt{n \sum Y^2 - (\sum Y)^2}} \quad (20)$$

Assim sendo, espera-se coeficientes com valores próximos de 1,0, o que atestaria a viabilidade do modelo proposto.

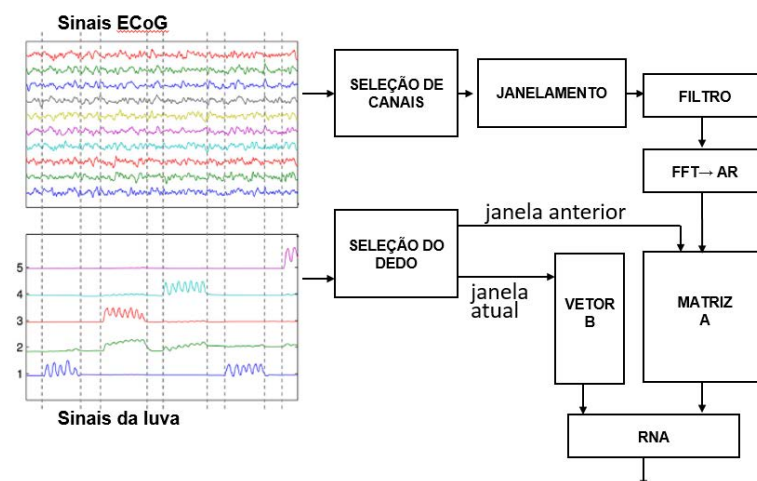
CAPÍTULO 7

APLICAÇÃO E RESULTADOS

Nota-se que, para atingir os objetivos desta pesquisa, há necessidade de construção de uma BCI. Como deseja-se prioritariamente comprovar a viabilidade do método, optou-se por uma BCI *stand-alone*, assíncrona e cujos dados foram obtidos por métodos invasivos.

O fluxograma de Figura 25 apresenta os principais procedimentos para a fase de treinamento. As etapas (blocos) já foram descritas no capítulo anterior, os parâmetros de sua implementação serão a seguir discutidos.

Figura 25- Fluxograma da Fase de Treinamento da BCI.



Fonte: do próprio autor.

7.1 PARADIGMA EXPERIMENTAL

O conjunto de dados foi obtido a partir de implante temporário, sob a dura-mater, no lado esquerdo do cérebro, em três pacientes portadores de epilepsia do Harborview Hospital, Seattle nos EUA, para fins clínicos de monitoração intracraniana. Posteriormente, concordaram em registrar anonimamente as seções de experimentos antes da remoção dos implantes. Tais experimentos foram acompanhados pelos respectivos neurologistas para atestar o estado de normalidade do cérebro dos pacientes, antes, durante e após o experimento. Os procedimentos foram realizados por uma equipe mista de pesquisadores dos Departamentos de Física e de Medicina da Universidade de Washington, e do Departamento de Saúde de Seattle; satisfizeram às recomendações de ética interna norte-americanas.

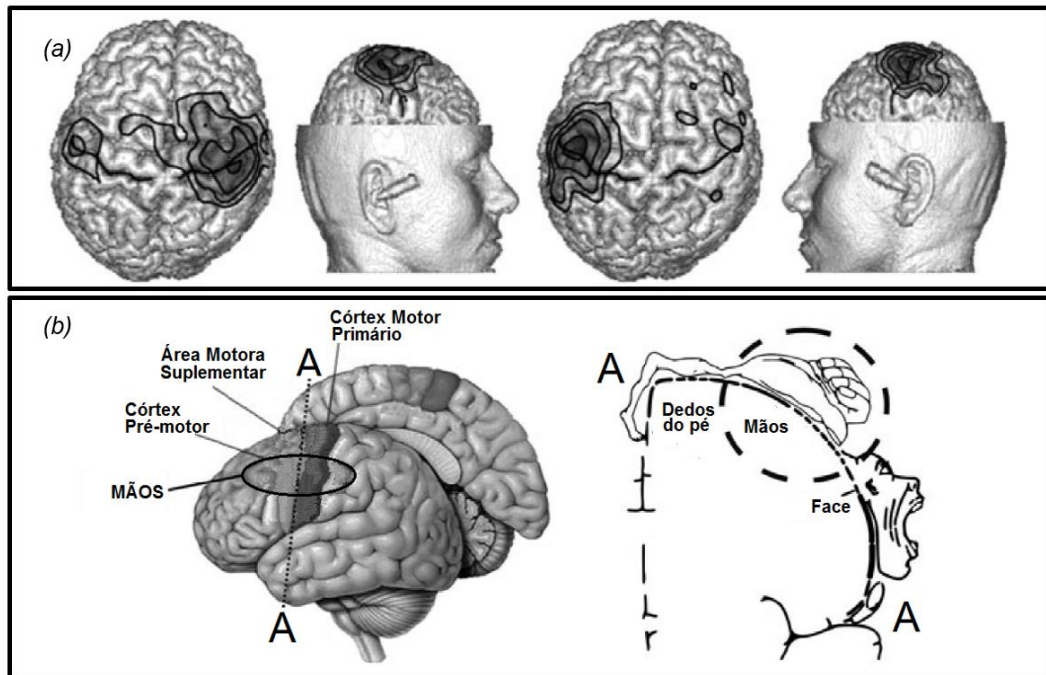
Esse mesmo conjunto de dados foi disponibilizado para o instituto europeu Pascal, que os tornou público para realização da 4ª versão do evento *BCI Competition*, em 2008 (MILLER; SCHALK, 2008), originando dezenas de trabalhos, dentre os quais (FLAMARY; RAKOTOMAMONJY, 2012; BOUGRAIN; LIANG, 2009). A abordagem deste trabalho considerou apenas os dados do primeiro indivíduo (*SI*) da base de dados.

Cada implante continha uma matriz de eletrodos de platina configurados num arranjo matricial de 8 colunas com número de linhas variando para cada indivíduo. O diâmetro dos eletrodos era de 4 mm (2,3 mm exposto), distanciados entre si em 1 cm.

O implante de cada indivíduo possui uma quantidade específica de canais variando entre 48 à 62, correspondente ao número de eletrodos. O indivíduo *SI* foi amostrado com 62 canais. Os sinais foram adquiridos tendo como referência o couro cabeludo. Foram amostrados em 1 kHz e filtrados para uma banda passante entre 0,15 e 200 Hz.

Como o objetivo deste trabalho é voltado para identificação de padrões dos dedos das mãos, a localização do implante seguiu a prescrição dos mapas de anatomia funcional, especificamente na região do Córtex Motor Primário e Pré-motor, conforme ilustra a Figura 26, apresentando em (a) a localização anatômica em relação à cabeça e ao cérebro do paciente, e em (b) o mapa funcional para localização do implante.

Figura 26- Escolha da localização anatômica do implante no cérebro.



Fonte: Graimann, Allison e Pfurtscheller (2010).

De acordo com Marques (2012), indivíduos epilépticos exibem um padrão de sinais ECoG sensivelmente alterados somente na região do foco epileptogênico nos momentos de crise e pré-crise, o que não descredencia quaisquer resultados obtidos a partir de seus sinais ECoG, desde que se assegure a normalidade do estado cerebral do paciente.


7.2 AQUISIÇÃO DE SINAIS

Os indivíduos foram orientados a mover um dedo específico mediante à apresentação da palavra correspondente à sua identificação (por exemplo: "polegar") em um monitor de vídeo colocado na lateral da cama, e um dispositivo registrou os sinais ECoG, conforme ilustra a Figura 27.

A flexão dos dedos foi gravada utilizando luva de dados, uma interface que fornece sinais relativos ao movimento dos dedos do usuário. Os sinais da luva de dados foram amostrados em 25 Hz. O movimento de flexão simples para os dedos das mãos são os mais simples do ponto de vista da cinesiologia e exigem que poucos feixes nervosos sejam ativados o que, em tese, reduz a complexidade do problema e da aprendizagem. (NEWMANN, 2011)

Em cada experimento, o aviso no monitor permanece por 2 segundos, e em seguida, o monitor permanece em branco por mais dois segundos. Nesse período, o indivíduo move o dedo requisitado de 3 a 5 vezes.

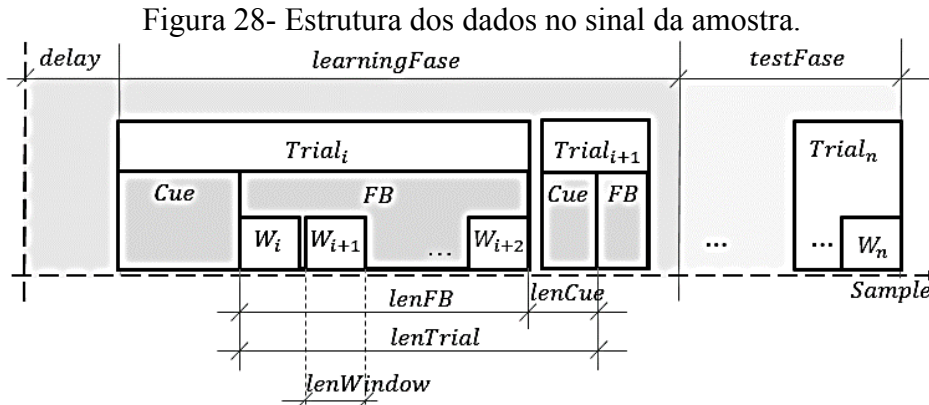
Figura 27- Esquema geral da realização do experimento.



Fonte: do próprio autor.

Ao todo, foram 30 experimentos para cada dedo, e a sequência de requisição de dedos foi aleatória. A seção de experimentos durou 10 min para cada indivíduo. Uma análise posterior mostrou que o movimento do dedo anelar estava correlacionado ao movimento dos dedos médio e mínimo, isso porque a biomecânica da mão faz com que o movimento dos demais dedos acabam induzindo um pequeno movimento no dedo anelar.

A estrutura dos dados do sinal para ser processada, foi organizada como está na Figura 28. O conjunto todo foi dividido para ser usado nas duas fases: a fase de treinamento (*learnigFase*) e a fase de teste (*testFase*). O intervalo para o início do experimento é o *delay*. Cada experimento (*Trial*) foi dividido em 2 etapas: a etapa de indicação na tela do dedo a ser movido (*Cue*) de tamanho *lenCue* e, a etapa do feedback (*FB*) de comprimento *lenFB*, onde ocorre o movimento do dedo indicado. A etapa do *FB* está dividida em janelas (*W*) de tamanho *lenWindow*.



Fonte: do próprio autor.

Os valores adotados foram:

$learningFase = 75\%$ dos dados	$testFase = 25\%$ dos dados
$lenCue = 2.000$ ms	$lenFB = 4.000$ ms
$lenTrial = 6.000$ ms	$lenWindow = 100$ ms

7.3 PRÉ-PROCESSAMENTO

O pré-processamento foi desenvolvido considerando as etapas e definições a seguir apresentadas.

7.3.1 Seleção de canais

O intervalo de confiança admitido foi entre $\pm 5\%$. Após a aplicação da hipótese do Teste t , eliminando eletrodos cujas leituras são similares, o número de eletrodos foi reduzido de 62 para apenas 19 eletrodos (canais).

7.3.2 Filtragem

As bandas de frequências consideradas seguem as recomendações da literatura pertinente. Este trabalho considerou as 3 primeiras faixas identificadas pela neurologia, excluindo-se a faixa de 35-70 Hz pois, de acordo com Miller, et al. (2008) reflete comprovadamente fenômenos espectrais conflitantes. Excluiu-se também a faixa de 200-300Hz pois a filtragem inicial já a eliminou.

Para esse trabalho, adotou-se filtros Elípticos passa-banda com atenuação na banda de passagem de 3 dB e na banda de corte de 50 dB.

7.4 EXTRAÇÃO DE CARACTERÍSTICAS

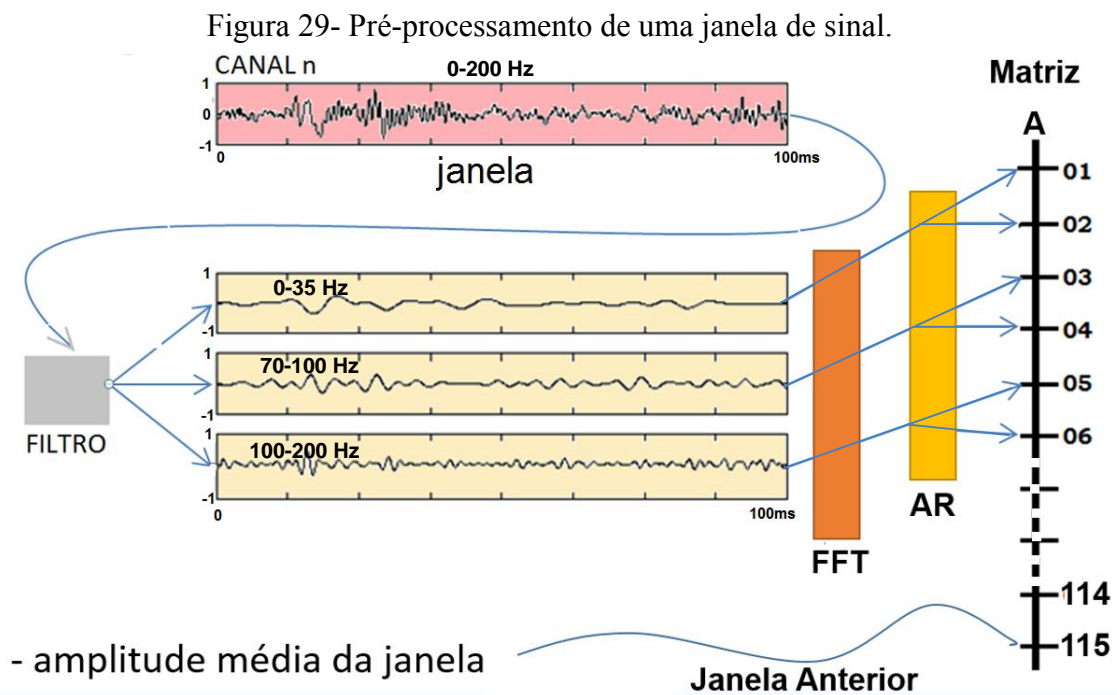
Para a extração de características, nesse caso, fez-se uso de janelamento sem superposição, adotando o comprimento de 100 ms. Para uma amostragem de 1 kHz isso implica em 4.000 valores por experimento de 4 s (*feedback*).

Os sinais da janela foram convertidos para o domínio da frequência, com o uso do algoritmo FFT (*Fast Fourier Transform*). Em seguida, aplicou-se o modelo autorregressivo sobre os sinais transformados, através do algoritmo de Burg, com grau 20, e aproveitando apenas os 2 primeiros coeficientes.

Para considerar o estado da janela anterior e evitar a sobreposição no janelamento, inseriu-se no vetor de características o valor medido da janela anterior.

Assim, no vetor de características, cada janela representa uma linha na matriz A, e tem comprimento 115. Essa dimensão pode ser considerada baixa se comparada aos demais trabalhos aqui citados.


A Figura 29 ilustra o processo de segmentação do sinal em 3 bandas para cada um dos 19 canais selecionados, através da filtragem, passando em seguida pela conversão de cada banda para o domínio da frequência (FFT) e obtenção dos dois coeficientes por autoregressão (AR), totalizando assim 115 elementos ($3 \times 19 \times 2 + 1 = 115$).



Fonte: do próprio autor.

Observando o gráfico da Figura 30, que apresenta os 10 primeiros experimentos, é possível constatar que não ocorre simultaneidade de picos nos sinais relativos ao movimento dos dedos.

Figura 30- Sinais da luva de dados para os 10 primeiros experimentos



Fonte: do próprio autor.

7.5 CLASSIFICAÇÃO DE PADRÕES

O diagrama apresentado na Figura 25 apresentou de forma sintética o modelo proposto para solução do problema e suas etapas de implementação. Observe que os dados relativos ao movimento dos dedos (sinais da luva) anterior também foram incluídos na composição da matriz de entrada (A), pois o conjunto físico dos dedos também atua como uma máquina de estados e deve então considerar o estado anterior do dedo em questão. Todos os dados dos sinais foram normalizados.

Considerando a montagem da matriz para a RNA ARTMAP-Nebulosa, a partir dos dados provenientes da extração de características, foi possível montar a matriz com os dados de entrada, com dimensões 2000x115 para o indivíduo *SI*.

Já o vetor B, para cada dedo, teve dimensão 2000x1. Seus dados foram obtidos a partir da média das amplitudes dos sinais lidos na janela correspondente.

Cada linha da matriz A e do vetor B corresponde à uma janela de tempo considerada.

Como já exposto anteriormente, por se considerar o sistema como também uma máquina de estados, os dados não podem ser utilizados randomicamente.

Os parâmetros de vigilância ρ_a , ρ_b e ρ_{ab} foram inicialmente ajustados respectivamente como 1,0; 0,95 e 0,95, afim de que o treinamento da rede se desse com grau elevado de aproximação com os valores obtidos. Já os parâmetros α e β respectivamente com 0,1 e 1, são

os valores adotados experimentalmente. Todos esses valores representam uma aproximação inicial, podendo ser alterados em caso de não convergência no treinamento. No reajuste de parâmetros não houve necessidade de alterá-los.

7.6 APLICAÇÃO E RESULTADOS

Como há uma relativa constância do sinal perturbado apenas no instante de movimento do dedo, ocorre redundância em certos trechos do vetor de saída.


Reduzir a redundância implica diretamente na redução do esforço computacional além do que, a RNA não se comporta muito bem com a presença delas, pois ocorre com frequência a necessidade de reajuste de parâmetros de vigilância.

Houve ocorrência de trechos redundantes, ou seja, para o mesmo valor lido na luva, ocorrem valores diferentes para os sinais cerebrais, em janelas adjacentes. Isso ocorre pela diferença de frequência de amostragem, a dos sinais corticais é de 1kHz e a da luva é de 25 Hz, isso obrigou aos construtores da matriz de dados a replicar o valores da luva de dados. Um algoritmo foi preparado para descartar janelas com tal ocorrência, desde que sejam adjacentes.

Os gráficos da Figura 31 apresentam parte dos dados de saída do sistema, relacionados com o dedo número 1 (polegar), sendo que o gráfico superior mostra os dados reais registrados a partir da luva de dados e, o inferior os dados gerados a partir da RNA treinada.

Nesse trabalho foi implementado um trecho de código que ignora os experimentos em que não houve alteração na leitura da luva de dados.

Figura 31- Gráficos de Sinais: (a) gravado e o (b) gerado pelo modelo.



Fonte: do próprio autor.

A baixa precisão nos trechos de estabilidade nos sinais (linhas horizontais no gráfico (b)) ocorreram devido à inexistência de padrões reconhecidos para a faixa de valores. A solução passa pelo ajuste nos parâmetros de vigilância ou a implementação de algoritmo de descarte desses trechos, já que não são de interesses.

A performance do modelo foi avaliada através do coeficiente de correlação linear que é o parâmetro estatístico adimensional que expressa a proximidade de uma amostra em relação ao valor esperado. No presente caso o usaremos como um indicador de proximidade entre os valores reais medidos no indivíduo *SI* e os valores gerados pelo modelo. Para este estudo, a Tabela 5 apresenta os índices obtidos para os cinco dedos do indivíduo *SI*.

Tabela 5- Coeficientes de correlação obtidos para os dedos da mão.

Dedos da mão	1 Polegar	2 Indicador	3 Médio	4 Anelar	5 Mínimo
r	0,880	0,876	0,918	0,776	0,953

Fonte: do próprio autor.

O coeficiente de correlação médio obtido pelo método proposto a partir de RNA ARTMAP-Nebulosa, descartando-se o dedo anelar para comparar com os demais trabalhos, foi de 0,91, índice bastante superior aos obtidos nos trabalhos apresentados durante a *BCI Competition IV*, conforme Miller e Schalk (2015), apresentados na Tabela 6.

Tabela 6- Tabela de resultados finais da BCI Competition IV .

#	Pesquisador	r	Laboratório de Pesquisas	Colaborador
1	Nanying Liang	0,46	Cortex Team, Research Centre INRIA, France	Laurent Bougrain
2	Remi Flamary	0,42	LITIS INSA de Rouen, France	Alain Rakotomamonjy
3	Mathew Salvaris	0,27	University of Essex, Colchester, UK	
4	Florin Popescu	0,10	Fraunhofer First, Germany	
5	Hyunjin Yoon	0,05	University of Southern California, LA, USA	Cyrus Shahabi

Fonte: Miller e Schalk (2015).

O melhor resultado dessa tabela, o trabalho de Nanying Liang, foi obtido separando o sinal em 3 bandas de frequência: 1-60Hz, 60-100Hz, e 100-200Hz; um delay de 25 registros, a classificação pelo método AR de Wiener.

Observa-se também que o tamanho da janela influencia significativamente na precisão dos resultados. A Tabela 7 apresenta o efeito da variação do tamanho da janela no coeficiente de correlação referente ao dedo 1 (polegar) do indivíduo *SI*. O melhor resultado se obtém com

janelas curtas, mas o aumento de número de janelas acaba também por interferir. O melhor resultado ficou mesmo em 100 ms.

Tabela 7- Efeitos da variação no tamanho da janela.

Tamanho da Janela (ms)	No. de Janelas	Coef. r
50	4000	0,78
100	2000	0,88
200	1000	0,72
400	500	0,60

Fonte: do próprio autor.

Outro fator importante constatado é que o dedo anelar, apesar de possuir um coeficiente inferior aos demais (0,776), tem um valor significativo. Os demais estudos comparados (MILLER; SCHALK, 2015), simplesmente desconsideraram esse dedo por apresentar resultado bastante conflitante. Esse fato denota a sensibilidade do modelo proposto, devido às características de flexibilidade e estabilidade próprias das RNA ARMAP-Nebulosas.

CAPÍTULO 8

CONCLUSÃO E TRABALHOS FUTUROS

Esta tese propôs um modelo para classificação de padrões de sinais de origem intracraniana para fins de utilização no comando de dispositivos externos, sejam eles para auxiliar indivíduos lesionados, idosos ou ainda para fins de entretenimento e de segurança.

O objetivo principal era comprovar que tal metodologia poderia ser desenvolvida por meio de uma RNA do tipo ARTMAP-Nebulosa com sinais do tipo ECoG.

O problema foi identificado como de reconhecimento de padrões, teve sua solução obtida por meio de abordagem neural, implementada por meio de uma plataforma BCI.

8.1 CONCLUSÕES

Os sinais ECoG e da luva de dados foram obtidos a partir do banco de dados público da *BCI Competition IV* (MILLER; SCHALK, 2015).

Os dados de sinais ECoG foram subdivididos em janelas de 100ms, filtrados em três bandas de frequência e submetidos à autocorrelação cujos dois primeiros coeficientes foram utilizados como padrão de entrada para a matriz **A** da RNA ARTMAP-Nebulosa.

Os dados da luva foram também subdivididos em janelas com a média das amplitudes registradas na janela e compuseram o padrão de saída para o vetor **B**. Treinada com 75% dos dados e testada com os outros 25% restantes, alcançou uma performance representada pelo coeficiente de correlação, com valor de 0,91.

Comparada com outros trabalhos, o índice obtido foi superior, o que aponta para a viabilidade do modelo proposto.

Os procedimentos de remoção de redundância aliados ao de seleção de canais cooperaram com a redução da dimensionalidade do problema e consequentemente na redução de recursos e tempo computacional exigidos para obtenção da solução.

A plasticidade e estabilidade da RNA ARTMAP Nebulosa empregada foram fundamentais para isolar a influência biomecânica entre os dedos, protegendo os padrões de uma classificação errônea, o que pode ser evidenciado pelos resultados do dedo anelar.

A RNA ARTMAP-Nebulosa demonstrou capacidade de generalização suficiente, o que pode ser evidenciado pelos resultados obtidos, com respostas positivas às variações paramétricas a que foi submetida.

8.2 PERSPECTIVAS FUTURAS

As evoluções nas técnicas de aquisição de sinais cerebrais certamente chegarão ao nível de captar sinais com baixo ruído por métodos não invasivos. Assim sendo, vão se aproximar cada vez mais, quantitativa e qualitativamente, do padrão de sinais ECoG.

O mercado de entretenimento já disponibiliza artefatos que comandam dispositivos através de BCI. Seu funcionamento é ainda precário, impreciso e sem muita confiabilidade.

O reconhecido envelhecimento de determinadas populações, devido à melhoria na qualidade de vida, criará novas demandas tecnológicas para sua manutenção. O uso de exoesqueletos é uma possível aplicação de BCIs para essa finalidade.

Segundo Sander et al. (2012), os magnetômetros ainda experimentais, baseados no elemento Rubídio, exibem uma sensibilidade de variação no campo magnético de 50 pT (picoteslas), valores suficientes para viabilizar a aquisição de sinais por vias não invasivas, com o mesmo padrão obtidos pelos métodos invasivos.

Outra possibilidade real é a aquisição de sinais de impulso nervoso através de implantes subcutâneo na coluna vertebral. Bem menos invasiva, a técnica já foi testada por Gad et al. (2015) em exoesqueleto com relativo sucesso.

Todo esse cenário aponta para possibilidades de aquisição de sinais cerebrais com superioridade em termos de qualidade, o que as credenciam como possíveis cenários para futura aplicação do modelo proposto neste trabalho.

8.3 SUGESTÕES PARA ESTUDOS FUTUROS

Para estudos futuros sugere-se também a aplicação desta metodologia em outros cenários (outros grupos culturais e outros membros do corpo), a fim de certificar sua abrangência e sua relação com o BCI-analfabetismo.

A redundância nos dados pode ser evidenciada na matriz de pesos, esse fato sugere a possibilidade de efetuar a seleção de canais relevantes, valendo-se apenas das matrizes de peso. Assim, um estudo no comportamento da matriz de pesos permitiria, em tese, identificar similaridades e redundâncias, fazendo-se uso apenas das matrizes de peso.

Outra possibilidade a ser explorada seria o uso dos sinais no domínio do tempo no treinamento da rede, ao menos para fins de comparação. Segundo sugere Suleiman (2007), não há ganho significativo no tratamento de biosinais no domínio da frequência.

Sugere-se ainda, com base nas afirmações de Schalk (2010), que traços comportamentais também podem ser evidenciados através de BCIs, que a BCI com RNA ARTMAP Nebulosa também seja avaliada para esse fim, detectar comportamentos ou a mudança deles nos seres humanos.

REFERÊNCIAS

- AMABIS, JOSÉ M.; MARTHO, GILBERTO R **Fundamentos da biologia moderna**. 4. ed. São Paulo: Moderna, 2006. 839 p.
- AMORIM, D. G. **Redes ART com categorias internas de geometria irregular**. 2006. 320 f. Tese (Doutorado em Física) – Departamento de Eletronica e Computação, Universidade de Santiago de Compostela – USC, Santiago de Compostela, 2006.
- ANDREWS, S.; KIONG, L. C.; KANNAN, R. **Fuzzy ARTMAP based feature classification for single trial brain-computer interface**. Zarga: ACIT, 2008. Disponível em: <https://uqu.edu.sa/files2/tiny_mce/plugins/filemanager/files/30/papers/f119.pdf>. Acesso em: 2 jan. 2015.
- ANUPAMA, H.; CAUVERY, N. K.; LINGARAJU, G. Brain-computer interface and its types: a study. **International Journal of Advances in Engineering and Technology**, New Delhi, v. 3, n. 2, p. 739-745, 2012.
- ARVANEH, M.; G. C.; ANG, K. K. Optimizing the channel selection and classification accuracy in EEG-based BCI. **IEEE Transactions on Biomedical Engineering**, Indiana, v. 58, n. 6, p. 1865-1873, 2011.
- AYDEMIR, O.; KAYIKCIOGLU, T. Comparative performance assessment of classifiers in low-dimensional feature space which are commonly used in bci applications. **Elektrorevue**, Brno, v. 2, n. 4, p. 58-63, 2011.
- BALABIN, R. M.; LOMAKINA, E. I. Support port vector machine for regression (LS-SVM): an alternative to artificial neural networks. **Analyst**, London, v. 13, n. 24, p. 1703–1712, 2011.
- BALL, T.; KERNA, M.; MUTSCHLERA, I.; AERTSENB, A.; SCHULZE-BONHAGEA, A. Signal quality of simultaneously recorded invasive and non-invasive EEG. **Journal Neuroimage**, Peachtree, v. 46, n. 3, p. 708–716, 2009.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neuroscience exploring the brain**. 4. ed. Philadelphia: Lippincott Williams & Wilkins, 2015. 857 p.
- BIRBAUMER, N. Breaking the silence: Brain–Computer interfaces (BCI). **Psychophysiology**, Baltimore, v. 43, n. 6, p. 517–532, 2006.

- BOKEHI, J.; SIMPSON, D.; INFANTOSI, A. Análise espectral de sinais eeg utilizando modelagem auto-regressiva. **Revista Brasileira de Engenharia Biomédica**, Rio de Janeiro, v. 9, n. 2, p. 5-22, 1993.
- BOUGRAIN, L.; LIANG, N. Band-specific features improve finger flexion prediction from ECoG. In: JORNADAS ARGENTINAS SOBRE INTERFACES CEREBRO COMPUTADORA - JAICC, 2, 2009, Argentina. **Memórias ...** Argentina: Entre-Rios, 2009. p. 45-48.
- BRUNNER, C.; ANDREONI, G.; BIANCHI, L.; BLANKERTZ, B.; BREITWIESER, C.; KANO, S.; KOTHE, C. A.; LECUYER, A.; MAKEIG, S.; MELLINGER, J.; PEREGO, P.; RENARD, Y.; SCHALK, G.; SUSILA, I. P.; VENTHUR, B.; MULLER-PUTZ, G. R. BCI software platforms. In: ALLISON, B. Z.; DUNNE, S.; LEEB, R.; MILLÁN, J. D.; NIJHOLT, A. **Towards practical brain-computer interfaces**. Berlin Heidelberg: Springer, 2013. p. 303-331.
- BYVATOV, E. F. Comparison of support vector machine and artificial neural network systems for drug/nondrug classification. **Journal Chemical Information Computation Sciences**, Washington, v. 6, n. 43, p. 1882-1889, 2003.
- CABOCLO, L. O. **Bases da eletroencefalografia**. Rio de Janeiro: SBHC, 2013. Disponível em: <<http://www.itarget.com.br/newclients/sbnc.org.br/arquivos/aulas/aula-5.pdf>>. Acesso em: 2 fev. 2015.
- CANUTO, A. M.; HOWELLS, G.; FAIRHURST, M. RePART: a modified fuzzy ARTMAP for pattern recognition, **Computational Intelligence**, Durtmund, v. 1625, n. 1, p. 159-168, 1999b.
- CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a selforganization. **Computer Vision, Graphics, and Image Processing**, San Diego, v. 37, p. 54-115, 1987.
- CARPENTER, G. A.; GROSSBERG, S. ART2: self-organization of stable category recognition codes for analog input patterns. **Applied optics**, Washington, v. 26, n. 23, p. 4919-4930, 1987a.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Networks**, Oxford, v. 4, n. 6, p. 759-771, 1991.
- CARPENTER, G.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, Piscataway, v. 3, n. 5, p. 698-713, 1992.
- CATON, R. The electric currents of the brain. **British Medical Journal**, London, v. 2, n. 765, 28 aug. 1875.
- CHANG, N. F.; CHEN, T. C.; CHIANG, C. Y.; CHEN, L. G. Channel selection for epilepsy seizure prediction method based on machine learning. **IEEE Engineering in Medicine and Biology Society**, Milan, v. 2012, p. 5162-5165, 2012.
- CHAO, Z. C.; NAGASAKA, Y.; FUJII, N. Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys. **Frontiers in Neuroengineering**, Lausanne, v. 3, n. 3, 2010.

- CHOI, J. S.; BANG, J. W.; PARK, K. R.; WHANG, M. Enhanced perception of user intention by combining EEG and gaze-tracking for brain-computer interfaces, **Sensors**, Basel, v. 13, n. 3, p. 3454-3472, 2013.
- DECANINI, J.; TONELLI-NETO, M.; MALANGE, F.; MINUSSI, C. R. Detection and classification of voltage disturbances using a Fuzzy-ARTMAP-wavelet network. **Electric Power Systems Research**, London, v. 81, n. 12, p. 20, 2011.
- DICKHAUS, T.; SANNELLI, C.; MÜLLER, K.; CURIO, G. Predicting BCI performance to study BCI illiteracy. **BMC Neuroscience**, London, v. 10, p. 84, 2009. Suppl. 1.
- DINIZ, P. S.; SILVA, E. A.; NETTO, S. L. **Processamento digital de sinais**. Porto Alegre: Bookman, 2014. 1000 p.
- DONCHIN, E.; SPENCER, K. M.; WIJESINGHE, R. The mental prosthesis: assessing the speed of a P300-based brain-computer interface. **IEEE Transactions on rehabilitation engineering**, San Diego, v. 8, n. 2, p. 174-179, 2000.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed. New York: Wiley-Interscience, 2001. 680 p.
- FLAMARY, R.; RAKOTOMAMONJY, A. Decoding finger movements from ECoG signals using switching linear models. **Frontiers in Neuroscience**, Lausanne, v. 6, n. 29, p. 1-9, 2012.
- FRED, A. L. **Reconhecimento de padrões - A3**. Lisboa: Instituto de Telecomunicações, 2001. Disponível em: <<http://www.lx.it.pt/~afred/docencia/Percepcao/acetatos/a3.pdf>>. Acesso em: 2 jan. 2015.
- FREEMAN, J. A.; SKAPURA, D. M. **Neural networks: algorithms, applications, and programming techniques**. Redwood: Addison-Wesley, 1991. 401 p.
- GAD, P.; GERASIMENKO, Y.; ZDUNOWSKI, S.; SAYENKO, D.; HAAKANA, P.; TURNER, A.; EDGERTON, V. R. Iron 'ElectriRx' man: overground stepping in an exoskeleton combined with noninvasive spinal cord stimulation after paralysis. **IEEE Engineering in Medicine and Biology Society**, Milan, v. 2015, p. 1124-1127, 2015.
- GARTNER, L. P.; HIATT, J. L. **Color textbook of histology**. 3. ed. Edinburgh: Elsevier Saunders, 2007. 483 p.
- GRAIMANN, B.; ALLISON, B. Z.; PFURTSCHELLER, G. **Brain-computer interface: revolutionizing human-computer interaction**. New York: Springer, 2010. 407 p.
- GUNDUZ, A.; SANCHEZ, J. C.; CARNEY, P. R.; PRINCIPE, J. C. Mapping broadband electrocorticographic recordings to two-dimensional hand trajectories in humans motor control features. **Neural Networking**, Oxford, v. 22, n. 9, p. 1257-1270, 2009.
- HAIDER, H. A.; ISHAK, A.; ADZNAN, J. Brain computer interface design and applications: challenges and future. **World Applied Sciences Journal**, Dubai, v. 7, n. 11, p. 819-825, 2010.
- HAYKIN, S. O. **Neural networks and learning machines**. 3. ed. Upper Saddle River: Prentice-Hall, 2008. 906 p.
- HAZRATI, M. K.; HOFMANN, U. G. Decoding finger movements from ECoG signals using empirical mode decomposition. **Biomedical Engineering/Biomedizinische Technik**, Berlin, v. 57, n. 1, p. 650-653, 2012. SI-1 Track-F.

HILL, N. J.; GUPTA, D.; BRUNNER, P.; GUNDUZ, A.; ADAMO, M. A.; RITACCIO, A.; SCHALK, G. Recording human electrocorticographic (ECoG) signals for neuroscientific research and real-time functional cortical mapping. **Journal of Visualized Experiments**, Bethesda, v. 2012, n. 64, p. 3993-3994, 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA-IBGE. **Censo demográfico**: 2010: características gerais da população, religião e pessoas com deficiência. Rio de Janeiro: IBGE, 2010. Disponível em: <[http://servicodados.ibge.gov.br/Download/Download.ashx? http =1& u= biblioteca.ibge.gov.br/visualizacao/periodicos/94/ cd_2010_religiao_deficiencia.pdf](http://servicodados.ibge.gov.br/Download/Download.ashx?http=1&u=biblioteca.ibge.gov.br/visualizacao/periodicos/94/cd_2010_religiao_deficiencia.pdf)>. Acesso em: 2 fev. 2010.

INGLE, V. K.; PROAKIS, J. G. **Digital signal processing using MATLAB**. Stanford: CENGAGE Learning, 2012. 420 p.

JAIN, A. K.; DUIN, R. P.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Washington, v. 22, n. 1, p. 4-37, 2000.

JUNQUEIRA, L. C.; CARNEIRO, J. **Histologia básica**: texto e atlas. 12. ed. Rio de Janeiro: Guanabara Koogan, 2006. 538 p.

KUBÁNEK, J.; MILLER, K.; OJEMANN, J.; WOLPAW, J.; SCHALK, G. Decoding flexion of individual fingers using electrocorticographic signals in humans. **Journal Neural Engineering**, Bristol, v. 6, n. 6, p. 1-14, 2009.

LABBÉ, B.; TIAN, X.; RAKOTOMAMONJY, A. MLSP competition, 2010: description of third place method. 2010, **IEEE International Workshop on Machine Learning for Signal Processing (MLSP)**, Kittila, v. 2010, p. 116–117, 2010.

LIN, W. C. **A case study on support vector machines versus artificial neural network**. 2004. 63 f. Thesis (Master of Science in Electrical Engineering)- University of Pittsburg. Pittsburg. 2004.

LOPES, M.; MINUSSI, C.; LOTUFO, A. Electric load forecasting using a fuzzy ART & ARTMAP neural network. **Applied Soft Computing**, Amsterdam, v. 5, n. 2, p. 235-244, 2005.

MADISETTI, V. K. **The digital signal processing handbook**. Boca Raton: CRC Press, 2010. 906 p.

MARQUES, D. M. **Análise espectral com wavelets do ECoG em crises epilépticas**. 2012. 66 f. Dissertação (Mestrado em Engenharia Biomédica) - Faculdade de Ciências e Tecnologia, Universidade Nova Lisboa, Lisboa, 2012.

MARTINEZ, J. A.; IZQUERDO, J. M.; IBARROLA, J. Feature selection applying statistical and neurofuzzy methods to EEG-based BCI. **Computational Intelligence and Neuroscience**, Pittsburg, v. 2015, n. 54, p. 1-17, 2015.

MENEZES, P. B. **Linguagens formais e autômatos**. Porto Alegre: Bookman, 2011. 165 p.

MILLER, K.; SCHALK, G. **Prediction of finger flexion**. Berlin: Berlin Brain Computer Interface, 2008. Disponível em: <[http://www. bbc.de/competition/iv/desc-4.pdf](http://www.bbc.de/competition/iv/desc-4.pdf)>. Acesso em: 30 jul. 2012.

MILLER, K.; SCHALK, G. **BCI competition**: final results. Berlin: Berlin Brain Computer Interface, 2008. Disponível em: <<http://www.bbc.de/competition/iv/results/>>. Acesso em: 2 fev. 2015.

- MILLER, K.; SHENOY, P.; DEN NIJS, M.; SORENSSEN, L. B.; RAO, R.; OJEMANN, J. Beyond the gamma band: the role of high-frequency features in movement classification. **IEEE Transaction on biomedical engineering**, Indiana, v. 55, n. 5, p. 1634-1637, 2008.
- MINUSSI, C. R.; LOTUFO, A. D. **Redes neurais: Introdução e principais conceitos**. Ilha Solteira: Notas, 2007. 107 p.
- MIRANDA, E. **Guide to brain-computer music interfacing**. London: Springer, 2014. 407 p.
- MONTENEGRO, M. A.; CENDES, F. G.; GUERREIRO, M. M.; GUERREIRO, C.A.M. **EEG na prática clínica**. 2 ed. São Paulo: Revinter, 2011. 344 p.
- NEWMANN, D. A. **Cinesiologia do aparelho musculoesquelético: fundamentos para reabilitação**. Rio de Janeiro: Guanabara Koogan, 2011. 593 p.
- NORANI, N.; MANSOR, W.; KHUAN, L. A review of signal processing in brain computer interface system. **Biomedical Engineering and Sciences**, Sarawak, v. 2010, p. 443-449, 2010.
- OCAZONEZ, S. A. **Processamento no domínio da frequência de sinais de eletroencefalografia**. 2009. 103 f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade de Brasília - UNB, Brasília, 2009.
- OPPENHEIM, A.; SCHAFER, R. **Digital signal processing**. Upper Saddle River: Prentice-Hall, 1975. 784 p.
- ORTIZ-ROSÁRIO, A. O. ADELI, H. Brain-computer interface technologies: from signal to action. **Reviews in the neuroscience**. Berlin. v. 24, n 25, p. 537-552, 2013.
- PALANIAPPAN, R.; PARAMESRAN, R. A new brain-computer interface design using. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, San Diego, v. 10, n. 3, p. 140-148, 2002.
- PIO, B. L. **Uma introdução às redes neurais artificiais para estudos em ecologia**. Brasília: Ebookdb, 2009. 43p.
- PISTOHL, T.; BALL, T.; SCHULZE-BONHAGE, A.; AERTSEN, A.; MEHRING, C. Prediction of arm movement trajectories from ECoG-recordings in humans. **Journal of Neuroscience Methods**, Washington, v. 167, n. 1, p. 105-114, 2007.
- RAUBER, T. W. **Redes neurais artificiais**. Vitória: UFES, 1997, Disponível em: <<http://www.inf.ufes.br/~thomas/pubs/eri98.pdf>>. Acesso em: 2 fev. 2015.
- RAVI, K.V.R.; PALANIAPPAN, R.; HENG, S. H. Simplified fuzzy ARTMAP classification of individuals using optimal VEP channels. **International Journal of Knowledge-Based and Intelligent Engineering Systems**, Amsterdam, v. 10, n. 6, p. 445-452, 2006.
- SANCHEZ, J.; GUNDUZ, A.; CARNEY, P.; PRINCIPE, J. Extraction and localization of mesoscopic motor control signals for human ECoG neuroprosthetics. **Journal of Neuroscience Methods**, Washington, v. 167, n. 1, p. 63-81, 2008.
- SANDER, T. H.; PREUSSER, J.; MHASKAR, R.; KITCHING, J.; TRAHMS, L. K. Magnetoencephalography with a chip-scale atomic magnetometer. **Biomedical Optics Express**, Washington, v. 3, n. 5, p. 981-990, 2012.
- SCHALK, G. Can electrocorticography (ECoG) support robust and powerful brain-computer interfaces? **Frontiers in Neuroengineering**, Lausanne, v.3, n. 9, p. 1-2, 2010.

- SCHALK, G.; MILLER, K. J.; ANDERSON, N. R.; WILSON, J. A.; SMYTH, M. D.; OJEMANN, J. G.; LEUTHARDT, E. C. Two-dimensional movement control using electrocorticographic signals in humans. **Journal Neural Engineering**, Bristol, v.5, n. 1, p. 75-84, 2008.
- SERRUYA, M. D.; HATSOPOULOS, N. G.; PANINSKI, L.; FELLOWS, M. R.; DONOGHUE, J. P. Brain-machine interface: instant neural control of a movement signal. **Nature**, London, v. 416, n. 1, p. 141–142, 2002.
- SOUZA, R. Modelos estruturais para previsão de séries temporais: abordagens clássica e bayesiana. In: 17o. **Colóquio ...** 17, 1989, Rio de Janeiro. Colóquio Brasileiro de Matemática. Rio de Janeiro: IMPA, 1989.
- SULEIMAN, A. B. R.; FATEHI, T. A. H. Features extraction techniques of EEG signal for BCI applications. **Computer and Information Engineering**, Mosul, v. 1, n. 1, p. 1-5, 2007.
- TANGERMANN, M.; MÜLLER, K. R.; AERTSEN, A.; BIRBAUMER, N.; BRAUN, C.; MÜLLER-PUTZ, G. R.; BLANKERTZ, B. et al. Review of the BCI competition IV. **Frontiers in Neuroscience**, Lausanne, v. 6, n. 55, 2012.
- THEODORIDIS, S. ; KOUTROUMBAS, K. **Pattern recognition**. San Diego: Academic Press. 2009. 961 p.
- TYAGI, S. A comparative study of svm classifiers and artificial neural networks application for rolling element bearing fault diagnosis using wavelet transform preprocessing. **World Academy of Science, Engineering and Technology**, Riverside, v. 2, n. 7, p. 309–317, 2008.
- VETTERLI, M.; KOVACEVIC, J. **Wavelets and subband coding**. Englewood Cliffs: Prentice Hall, 1995. 505 p.
- VIDAL, J. Toward direct brain-computer communication. **Annual Review of Biophysics and Bioengineering**, Los Angeles, v. 2, n. 1, p. 157-180, 1973.
- WALDERT, S.; PREISSEL, H.; DEMANDT, E.; BRAUN, C.; BIRBAUMER, N.; AERTSEN, A. M. Hand movement direction decoded from MEG and EEG. **The Journal of Neuroscience**, Washington, v. 28, n. 4, p. 1000-1008, 2008.
- WANG, Z.; SCHALK, G.; JI, Q. Anatomically constrained decoding of finger flexion from electrocorticographic signals. **Advances in Neural Information Processing Systems**, Vancouver, v. 24, n. 1, p. 2070–2078, 2011.
- WANGENHEIM, A. V.; WANGENHEIM, C. G. **Raciocínio baseado em casos**. São Paulo: Manole, 2003. 342 p.
- WOLPAW, J.; WOLPAW, E. **Brain-computer interfaces: principles and practice**. New York: Oxford University Press, 2012. 400 p.

APÊNDICE A

FUNDAMENTOS DE REDES NEURAIS ARTIFICIAIS

Para Haykin (2008), a concepção das RNA difere dos computadores digitais convencionais, apesar de serem igualmente motivados pela tentativa de reprodução da atividade cerebral. As RNA foram além da simples representação linear das unidades dos sistemas de informação (entrada-processamento-saída). O cérebro exibe um padrão de processamento não-linear e paralelo. Organiza seus componentes estruturais – os neurônios, para o desempenho de tarefas complexas, às vezes com velocidade superior aos computadores atuais, como por exemplo, o reconhecimento de um rosto familiar em cerca de 100 a 200 ms. Assim, uma RNA pode ser compreendida como um processador distribuído, maciçamente paralelo, formado por unidades simples de processamento, com capacidade de armazenar “conhecimento experimental” para uso futuro.

O Capítulo 2 deste trabalho apresentou aspectos fisiológicos ligados à dinâmica do aprendizado de um neurônio biológico. As RNA tratam-se em princípio de uma modelagem matemática do comportamento do neurônio biológico.

1 HISTÓRICO DAS RNA

Segundo Braga, Ludemir e Carvalho (2000), em 1943, o neurofisiologista Warren McCulloch, do MIT, e o matemático Walter Pitts, da Universidade de Illinois, apresentaram a primeira proposta de neurônio artificial, baseados no funcionamento do neurônio biológico. Em 1949, Hebb apresenta um trabalho postulando sobre a aprendizagem assimilada pelo neurônio biológico, baseada no reforço ou enfraquecimento das ligações sinápticas.

Em 1958, Rosenblatt propôs um modelo com sinapses ajustáveis através de pesos, o *Perceptron*, que tinha a capacidade de reconhecer alguns padrões através de um mecanismo de treinamento. Minsky e Papert, em 1969, demonstraram que a aplicação do *Perceptron* se restringia a solução de problemas linearmente separáveis. Nos anos 70 houve um lapso de pesquisas sobre o assunto. Hopfield, em 1982, apresenta resultados que confirmam as propriedades associativas das RNAs. Quatro anos depois, Rumelhart, Hinton e Williams sugerem o algoritmo de treinamento *backpropagation* multi-camadas, conferindo às RNA a capacidade de resolver problemas não linearmente separáveis. (ARIB, 2002)

2 VANTAGENS E DESVANTAGENS NO USO DE RNA

Segundo Suzuki (2011), são vantagens do emprego de RNA na solução de problemas diversos:

- **Qualidade superior** – fornece um nível superior de análise que as demais técnicas, conferindo, para as empresas, maior competitividade em tarefas relacionadas a extração de conhecimento;
- **Mapeamento Não-Linear**- é a capacidade de aprender a mapear não-linearidades dos conjuntos de entrada e saída diretamente do conjunto de treinamento;
- **Auto-aprendizado** - fortemente dependentes dos dados fornecidos, dispensam especialista e modelagem para o processo decisório;
- **Implementação mais rápida** – que outras técnicas de IA ou modelagem matemática;
- **Capacidade de generalização** - conjunto de dados incompletos ou imprecisos não impõem degradação, a RNA é capaz de absorver essas ocorrências;
- **Adaptabilidade** – capacidade de adaptar a estrutura para otimizar seu comportamento.


Entretanto, é possível também identificar algumas desvantagens, a saber:

- **Resultados discrepantes** – quando os dados não são representativos;
- **Tempo de Treinamento** – vinculado ao uso de um hardware de desempenho satisfatório e a escolha inicial dos dados mal-sucedida;
- **Caixa-preta** - critérios decisórios são encriptados e os pesos não aceitam interpretação;
- **Volume grande de dados** – um grande e consistente volume de dados é necessário para o aprendizado eficiente. A separação entre os dados de treinamento e os de teste depende de fatores empíricos como tentativa e erro ou a experiência do projetista.

3 O NEURÔNIO ARTIFICIAL E AS RNA

De acordo com Haykin (2008), o modelo proposto por McCulloch-Pitt, conforme ilustra a Figura 32, era constituído de um número de n entradas X ponderadas por pesos W .

Figura 32- Modelo do neurônio de McCulloch-Pitts.



Fonte: Haykin (2008).

Uma função não-linear $f(.)$ recebe o somatório s dessas entradas produzindo uma única saída Y , enviada como entrada para outros neurônios, conforme apresentado nas Equações (21) e (22). (HAYKIN, 2008)

$$s = \sum_{i=1}^n X_i \cdot W_i \quad (21)$$


$$Y = f(s + b) \quad (22)$$

O mecanismo de aferição dos pesos é chamado de aprendizagem, sendo que tais pesos uma vez aferidos constituem o conhecimento da rede. Nesse modelo, não-linearidades como relé, lógica *threshold* e sigmóide são as mais usuais, ilustradas na Figura 33.

O modelo admite ainda uma entrada “bias” b , para controle da saída, com peso W_0 de controle da saída, alimentado por uma constante $X_0 = +1$, conforme a Equação (22) (HAYKIN, 2008).

De acordo com Arib (2002), em termos de similaridade ao neurônio biológico, as entradas correspondem às sinapses dos dendritos e a saída corresponde ao sinal propagado pelo axônio até as suas terminações.

Figura 33- Funções de não linearidade.




Fonte: Haykin (2008) adaptado.

4 ARQUITETURAS DE RNA

Segundo Braga, Ludemir e Carvalho (2000), a arquitetura de uma RNA é definida pelos fatores: número de camadas da rede, número de nodos em cada camada, tipos de conexão entre os nodos e topologia da rede.

Haykin (2008) aponta 3 tipos básicos de arquiteturas, como ilustra a Figura 34: a RNA de camada única correspondente ao item (a) da figura; a arquitetura de múltiplas camadas, como é o caso dos itens (b) e (c); e as redes recorrentes (*backpropagation*), onde a saída realimenta entradas de camada anteriores ou da atual, que correspondem respectivamente aos itens (c) e (d). Observe que é possível combinar os dois últimos tipos. Rauber (1997) considera também os tipos (a) e (b) como sem realimentação ou *feedforward*, onde o sinal segue uma única direção.

Figura 34- Exemplos de RNAs com diferentes camada e topologias.

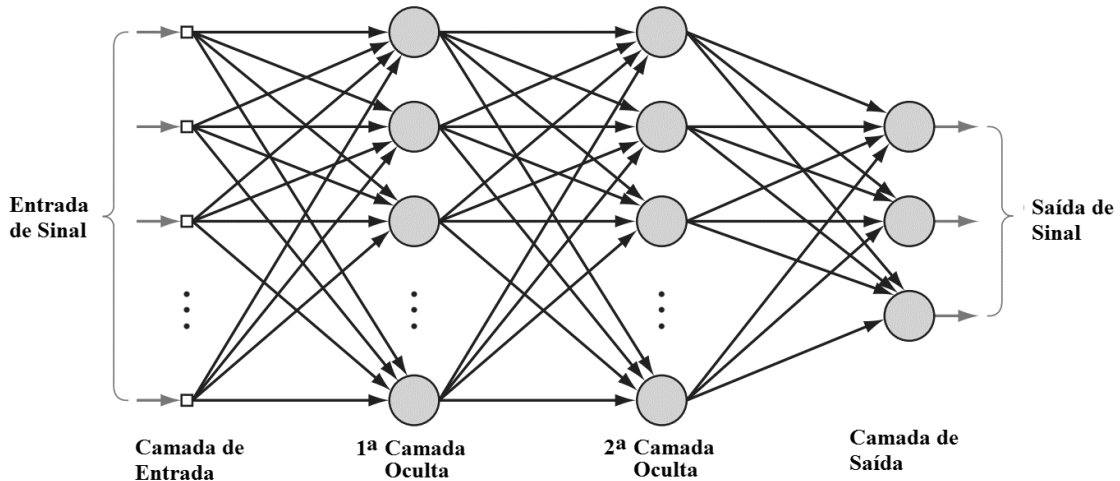


Fonte: Braga, Ludemir e Carvalho (2000).

As RNA são bastante singulares, e há diversidade de classificação na ótica dos principais autores estudados, isso sugere que haverá sempre um novo arranjo para redes bioinspiradas que não se enquadrarão na classificação até então definida.

Uma RNA é composta por um arranjo de neurônios de um ou mais níveis (camadas), cujas saídas podem compor a entrada de outros neurônios dispostos em outro nível. Admite-se também a disposição de camadas intermediárias, conforme ilustra a Figura 35.

Figura 35- Arquitetura de RNA Perceptron multicamadas com duas camadas ocultas.



Fonte: Haykin (2008).

Para Churchland e Sejnowski (1992), a inserção de camadas intermediárias permite extrair estatísticas de ordem elevada do conjunto de dados de entrada, provavelmente porque amplia o número de características a serem aferidas pelos pesos, que antes estava limitado ao número de entradas disponíveis na camada de entrada.

Para Haykin (2008), a realização é o ato de definir a estrutura da rede, definindo os fatores mencionados, com a finalidade de extrair o conhecimento do processo-alvo, especialmente útil em casos em que não existem formas consistentes de modelagem matemática. O uso de uma rede neural se dá em duas fases:

- **Treinamento** – fase *off-line* para adaptação dos pesos, executada sob uma amostra menor, específica para o treinamento. Nessa fase os pesos são inicializados. Sua escolha adequada pode reduzir o tempo de treinamento. O usual é escolher números aleatórios num determinado intervalo uniformemente distribuídos. Por se tratar de um processo iterativo, um critério de parada tem que ser definido que pode ser um número de ciclos ou erro máximo admissível por ciclo. A capacidade de generalização é outro fator a ser maximizado no treinamento;
- **Teste e análise** – fase em tempo-real, utiliza pesos adaptados para classificar a maior porção dos dados. Fase de baixo consumo de recursos computacionais. A

performance da rede é avaliada nessa fase. Na análise, valores muito discrepantes do conjunto que não conduzam a conexões associadas devem ser descartados.

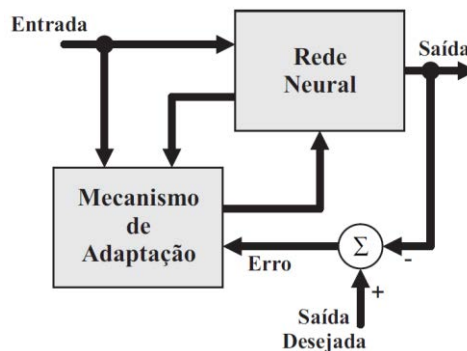
5 APRENDIZAGEM

Para Braga, Ludemir e Carvalho (2000), as RNA conseguem aprender através de exemplos, e permitem fazer interpolações e extrapolações a partir do conhecimento armazenado. A aprendizagem ocorre a partir de estímulos externos e do ajuste dos parâmetros da RNA.

Para Reuber (2011), durante o treinamento os graus de liberdade da rede têm que ser adaptados de maneira ótima, isso implica na modificação dos pesos dos neurônios de acordo com um algoritmo. De acordo com Braga, Ludemir e Carvalho (2000), quanto à adaptação o aprendizado se processa de duas formas:

Supervisionada – ativada por estímulos de saída, um supervisor externo controla entradas e saídas. O ajuste de parâmetros da rede, mapeando parede de padrões de entrada e saída reais e a saída gerada pela RNA, conforme ilustra a Figura 36.

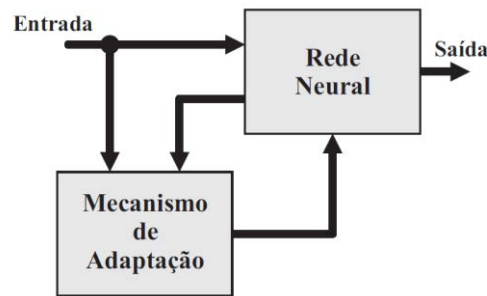
Figura 36- Aprendizagem supervisionada.



Fonte: Haykin (2008) adaptado.

Não-supervisionada – não existe supervisor controlando parâmetros da rede, o processo de aprendizagem se dá somente com os vetores de entrada. Os pesos são ajustados diretamente pela contínua entrada de padrões, conforme ilustra a Figura 37. São exemplos de rede não supervisionadas as redes ART-1 e Hopfield.

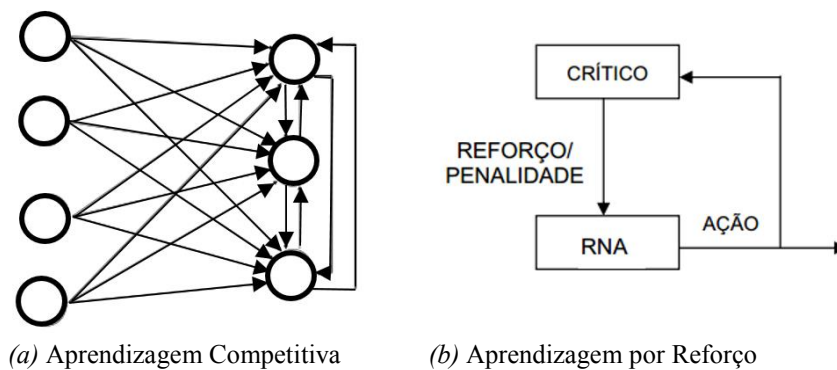
Figura 37- Aprendizagem não-supervisionada.



Fonte: Haykin (2008) adaptado.

A Figura 38 ilustra dois casos especiais de aprendizagem: o item (a) se refere a aprendizagem competitiva que é derivada da aprendizagem não-supervisionada, onde as unidades de saída disputam quem vai ser ativada; o item (b) se refere a aprendizagem por reforço, que é um caso especial de aprendizagem supervisionada, onde a informação é realimentada, comparando-se a saída gerada pela rede com a real, se está ou não correta.

Figura 38- Casos especiais de aprendizagem.



(a) Aprendizagem Competitiva

(b) Aprendizagem por Reforço


Fonte: Braga, Ludemir e Carvalho (2011).

6 PERCEPTRON, ADALINE e MADALINE

O *Perceptron* é um modelo de neurônio de aprendizado supervisionado, de camada única de pesos ajustáveis, trata-se de um classificador gerador de funções lógicas binárias. Sua limitação crítica é o fato de resolver apenas problemas linearmente separáveis por não admitir mais de uma camada de pesos ajustáveis.

A Figura 39 ilustra a arquitetura do modelo *Perceptron*. A taxa ΔW_i é a correção a ser aplicada aos pesos de entrada, esse é o mecanismo de aprendizagem *Perceptron* (WIDROW; LEHR, 1990).

Figura 39- Arquitetura do neurônio Perceptron




Fonte: do próprio autor

O modelo ADALINE (*ADaptive Linear Element*) consta de um combinador linear adaptativo atuando após a função de ativação, linear ou não-linear. É o *backpropagation* mais disseminado no meio acadêmico.

O ajuste de pesos é obtido através de incremento nos pesos baseado na regra Delta que é um ajuste realizado na direção contrária ao gradiente. Tem as mesmas limitações do Perceptron, porém o treinamento é mais suave, podendo até ser mais demorado. (WIDROW; LEHR, 1990) A Figura 40 ilustra esse modelo.


Figura 40- Modelo ADALINE.



Fonte: do próprio autor.

O modelo MADALINE (Many ADALINE) consta de uma rede de múltiplas camadas contendo neurônios ADALINE, conforme ilustra a Figura 41.

Figura 41- Modelo MADALINE.



Fonte: do próprio autor.

Os neurônios de saída têm peso constante e função definida, não são treinados e não se comunicam. O treinamento é feito verificando se a saída é igual ao valor desejado. Caso seja igual, os pesos permanecem inalterados, caso contrário ajustam-se os pesos de neurônios da primeira camada.

Cada neurônio ADALINE quebra o espaço de características em 2, diminuindo a complexidade do problema. Isso dá ao MADALINE a capacidade de tratar problemas não-linearmente separáveis. (BRAGA; LUDEMIR; CARVALHO, 2000)

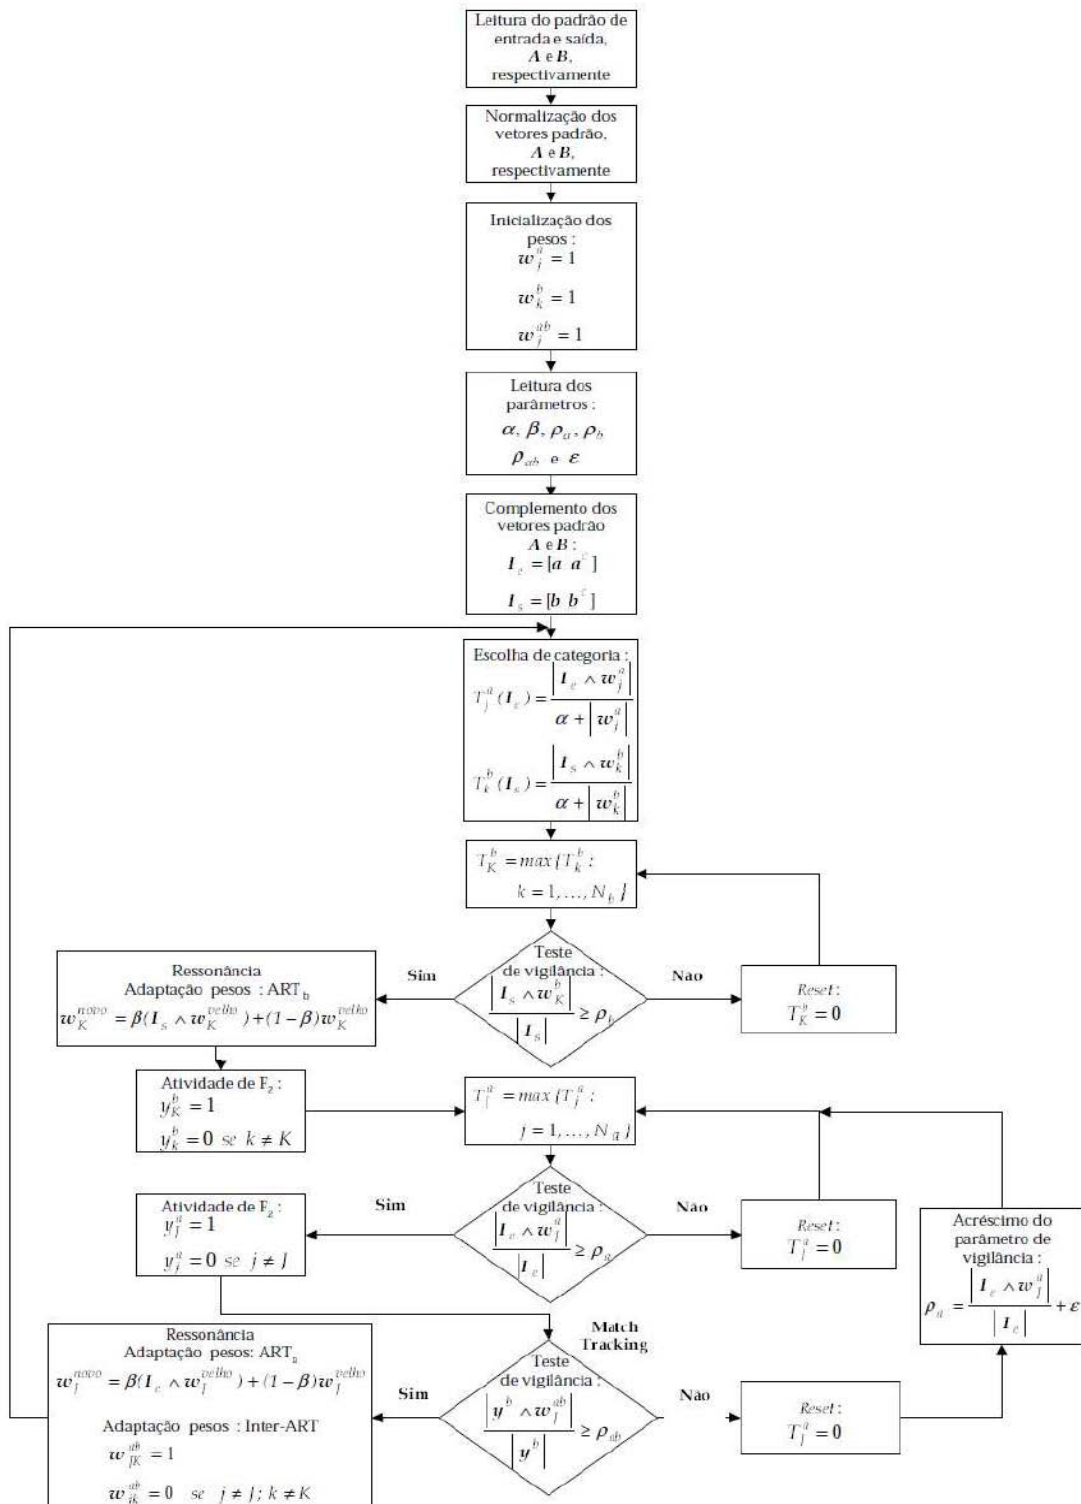
REFERÊNCIAS DO APÊNDICE

- ARIB, M. A. **Brain theory and neural network**. 2. ed. London: The MIT Press, 2002. 1290 p.
- BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. C. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262 p.
- CHURCHLAND, P. S.; SEJNOWSK, T. I. **The computational brain**. London: The MIT Press, 1993.
- HAYKIN, S. O. **Neural networks and learning machines**. 3. ed. Upper Saddle River: Prentice-Hall; 2008. 906 p.
- RAUBER, T. W. **Redes neurais artificiais**. Vitoria: UFES, 1997. Disponível em: <<http://www.inf.ufes.br/~thomas/pubs/eri98.pdf>>. Acesso em: 2 fev. 2015.
- SUZUKI, K. **Artificial neural network: methodological advances and biomedical applications**. Rijeka: InTech, 2011.
- WIDROW, B.; LEHR, M. A. **30 Years of adaptive neural networks: Perceptron, Madaline, and Backpropagation**. **Proceedings of IEEE**, Niagara, v. 78, n. 9, p. 1415-1442, 1990.

ANEXO A

Fluxograma de aprendizagem da rede ARTMAP-Nebulosa

Para uma compreensão mais facilitada é apresentado, a seguir, o fluxograma que estabelece os procedimentos do algoritmo de aprendizagem da rede ARTMAP-Nebulosa de acordo com (LOPES; MINUSSI; LOTUFO, 2005).



ANEXO B

Artigos Publicados relacionados com esta Pesquisa de Doutorado

Congressos Internacionais

MONTEIRO, RHYCARD L.; LOTUFO, ANNA D.; VIEIRA FILHO, JOZUÉ. Reconhecendo padrões relacionados com o movimento dos dedos das mãos em sinais ECoG com o uso de redes neurais ARTMAP-Fuzzy. In: BRICS COUNTRIES, 1.; BRAZILIAN CONGRESS ON COMPUTATIONAL INTELLIGENCE, 11., 2013, Porto de Galinhas. **Anais ...** Porto de Galinhas: SBCC, 2013. p.1-6.

Congressos Nacionais

MONTEIRO, RHYCARD L.; LOTUFO, ANNA D.; VIEIRA FILHO, JOZUÉ, Redes neurais ARTMAP-Fuzzy: Reconhecendo padrões de movimento de dedos em sinais ECOG. SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 12., 2015, Natal. **Anais ...** Natal: SBAI, 2015. p. 1-6.