

COERÊNCIA, MODELO OCULTO DE MARKOV E
PERCEPTRON DE MULTI- CAMADAS EM
IMAGÉTICA MOTORA

Ana Paula de Souza
BELO HORIZONTE, BRASIL.
FEVEREIRO DE 2010

Ana Paula de Souza

COERÊNCIA, MODELO OCULTO DE MARKOV E
PERCEPTRON DE MULTI- CAMADAS EM
IMAGÉTICA MOTORA

Dissertação submetida ao Curso de Pós-Graduação
em Engenharia Elétrica da Escola de Engenharia da
Universidade Federal de Minas Gerais como requisito parcial
para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Engenharia Elétrica

Orientador: Prof. Carlos Julio Tierra-Criollo

Co-orientador: Prof. Leonardo Bonato Felix

Universidade Federal de Viçosa

Belo Horizonte

Escola de Engenharia da UFMG

2010

Ana Paula de Souza

Coerência, Modelo Oculto de Markov e Perceptron de Multi-Camadas em Imagética Motora

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais,

Belo Horizonte, 2010.

Carlos Julio Tierra-Criollo (Orientador) - UFMG

Leonardo Bonato Felix (Co-Orientador) - UFV

Carlos Andrey Maia – UFMG

Gilberto Mastrocola Manzano – UNIFESP

*Se as coisas são inatingíveis... Ora!
Não é motivo para não querê-las...
Que tristes os caminhos se não fora
A mágica presença das estrelas!*

(Mário Quintana)

Agradecimentos

Agradeço ao professor Carlos Julio pelos ensinamentos transmitidos e pela orientação durante o desenvolvimento deste trabalho.

Ao professor Carlos Andrey pelas contribuições dadas durante o trabalho.

Ao professor Leonardo Bonato pela amizade, conselhos e orientações.

Aos amigos que fiz no NEPEB pelo apoio e colaboração durante a realização deste trabalho, principalmente durante as incansáveis coletas de EEG. Em especial, ao Sady pelos conselhos e pela prontidão em me ajudar com as muitas dúvidas que tive.

Aos velhos e bons amigos que não me deixaram sentir saudades de Viçosa: Douglas, Gleison, Colatina, Rosembergue e James.

Ao Gustavo pela paciência e dedicação que permitiram amenizar a caminhada até aqui.

Aos meus pais que torceram por mim, aceitando minha ausência sem reclamações.

À minha irmã pela amizade e pelas longas conversas e ao tio Moacir por acreditar em mim.

Agradeço, também, à CAPES, ao CNPq e à FAPEMIG pelo apoio financeiro.

Resumo

Sinais cerebrais e a interpretação de padrões nos mesmos propiciam uma nova modalidade de comunicação: a Interface Cérebro Máquina (ICM). A ICM pode utilizar a atividade elétrica advinda do córtex cerebral relacionada à imaginação motora para promover o acionamento de um dispositivo, sem que haja necessariamente a integridade das vias motoras. A Magnitude Quadrática da Coerência (MSC – *Magnitude Square Coherence*) tem sido utilizada para identificar o potencial relacionado a eventos no sinal de eletroencefalograma (EEG). Além disso, para a classificação desses eventos e aplicações em ICM técnicas como os Modelos Ocultos de Markov (*Hidden Markov Model* - HMM) e as Redes Neurais Artificiais (RNA) têm se mostrado promissoras. Dessa forma, esta dissertação visa investigar a classificação com HMM e RNA (na estrutura *Multilayer Peceptron* - MLP) utilizando como característica a MSC do sinal EEG, para os eventos: espontâneo; movimento do dedo indicador da mão esquerda; e imaginação deste movimento. Sinais EEG de três voluntários durante os eventos foram coletados com eletrodos dispostos segundo o Sistema Internacional 10-20 (1ª coleta) e Sistema 10-10 (2ª e 3ª coletas). O EEG foi dividido em trechos ($M = 14$ segundos cada) sincronizados com o evento. Cada trecho foi fragmentado em seis segmentos: EEG espontâneo; EEG do voluntário visualizando um LED (*Light Emitting Diode*) vermelho – *atenção*; EEG visualizando um LED amarelo – *preparação para realizar o evento*; EEG durante o evento; EEG espontâneo; EEG espontâneo. Em cada segmento avaliou-se a MSC da banda delta (0,1-2 Hz), banda alfa (8-13 Hz) e banda beta (14-30 Hz), com $M=12$ e $M=\text{máximo número de trechos}$. A faixa de frequência que apresentou maior MSC foi adotada como observação a ser utilizada no HMM e como entrada para a RNA. Os índices médios de acerto na classificação com o HMM para $M=12$ foram 68,5 %, 66,5 % e 67,5 %, para os sujeitos #1, #2 e #3, respectivamente. Para M máximo foram de 73,0 %, 70,0 % e 56,5 %. Quando utilizada a MLP para a classificação os índices para $M=12$ foram 64,0 %, 75,5 % e 82,0 % e, para M máximo 79,5 %, 85,5 % e 88,5 %. Esses achados mostram que é possível fazer modelos e classificações utilizando HMM e RNA de atividades cerebrais relacionadas a diferentes eventos, usando a MSC do sinal de EEG. A RNA mostrou melhor desempenho do que o HMM na classificação dos eventos.

Abstract

Brain signals and the interpretation of their patterns provide a new modality of communication: the Brain Computer Interface (BCI). BCI can use scalp potential related movement imagination to activate drive devices, not depending on the brain's normal output channels: peripheral nerves and muscles. Magnitude Squared Coherence has been used to identify the event related potential in Electroencephalogram (EEG) signals. Moreover, techniques such as Hidden Markov Model (HMM) and Artificial Neural Network (ANN with Multilayer Perceptron –MLP – structure) have shown promising results in classification for BCI systems. Thus, this work aims to investigate classification using HMM and ANN using features from MSC in EEG signals, for the following events: spontaneous EEG; actual index finger movement; and imaginary movement of that finger. EEGs were recorded from three normal subjects from electrodes placed according to the International 10-20 System (1st record) and 10-10 System (2nd and 3rd record). EEG was divided into trials (M - 14 seconds each) synchronized with the event. Each trial was divided into six segments: spontaneous EEG; EEG during visualization of red LED (Light Emitting Diode) – attention; EEG during visualization of yellow LED – preparation for the event; EEG during the event; spontaneous EEG; and spontaneous EEG. MSC was calculated for 12 trials and afterwards, for the maximum trials existent in each electrode. In each segment the MSC was calculated for delta band (0.1 – 2.0 Hz), alpha band (8.0 – 13 Hz) and beta band (14 – 30 Hz), with M=12 trials and M = maximum number of trials. The frequency band that presented the highest MSC was used as observation in HMM and as input for RNA. The average accuracy rates in the classification using HMM for M = 12 were 68.5 %, 66.5 % and 67.5 %, for subjects #1, #2 and #3, respectively. For maximum M, they were 73.0 %, 70.0 % and 56.5 %. When MLP was used for classification the results for 12 trials were 64.0 %, 75.5 % and 82.0 % and, using maximum M, the accuracy rates obtained were 79.5 %, 85.5 % and 88.5 %. These results showed that the MSC technique is an efficient tool for feature extraction in EEG recording during different events. With these features, it was possible to classify the EEG signals using HMM and RNA, the latter presenting the best performance in event classification.

Sumário

Agradecimentos	iv
Resumo	v
Abstract.....	vi
Sumário.....	vii
Lista de Figuras	x
Lista de Abreviaturas.....	xiii
CAPÍTULO 1: INTRODUÇÃO	2
1.1. Objetivos.....	3
1.2. Estrutura do trabalho	4
CAPÍTULO 2: POTENCIAL RELACIONADO À IMAGÉTICA MOTORA.....	5
2.1. Anatomia e fisiologia cerebral.....	5
2.1.1. Neurônios	7
2.2. Fisiologia de movimentos reais e imaginados	9
2.3. Sinais de Eletroencefalograma	13
2.3.1. Bandas de frequência no EEG	14
2.3.2. Potenciais relacionados a eventos.....	16
2.3.3. Aplicações em Interface Cérebro-Máquina (ICM).....	17
CAPÍTULO 3: EXTRAÇÃO DE CARACTERÍSTICAS, MODELAGEM E CLASSIFICAÇÃO DOS SINAIS EEG DURANTE MOVIMENTO E IMAGINAÇÃO MOTORA	
22	
3.1. Extração de características.....	22
3.1.1. Média Coerente.....	22
3.1.2. Magnitude Quadrática da Coerência (MSC – Magnitude Squared Coherence)	23
3.2. Modelagem e Classificação	25
3.2.1. Modelos Ocultos de Markov	25
3.2.1.1. Solução de problemas com HMM	27
Solução problema 1:	28
Solução problema 2:	29

Algoritmo de Viterbi	29
Solução problema 3:	30
Algoritmo de Baum-Welch	31
3.2.2. Redes Neurais Artificiais.....	32
CAPÍTULO 4: MATERIAIS E MÉTODOS.....	36
4.1. Sinais EEG: protocolo de aquisição	36
4.2. Pré-Processamento dos Sinais	38
4.2.1. Estimação do PRE através da Média Coerente.....	39
4.2.2. Divisão dos trechos de EEG em segmentos	40
4.3. Extração de características via MSC	41
4.4. Sinais Simulados	41
4.5. Processamento	42
4.5.1. Modelagem e validação com HMM	42
Treinamento.....	42
Validação e classificação.....	45
4.5.2. Treinamento e validação com RNA	46
Treinamento.....	46
Validação e classificação.....	47
CAPÍTULO 5: RESULTADOS	49
5.1. Sinais Simulados	49
5.2. Sinais EEG.....	52
5.2.1. HMM	52
Treinamento.....	52
Validação e Classificação	57
5.2.2. RNA.....	61
CAPÍTULO 6: DISCUSSÃO	67
CAPÍTULO 7: CONCLUSÃO.....	71
Publicações	71
Referências	73

Lista de Tabelas

Tabela 1 – Faixas de frequência das bandas do EEG.	15
Tabela 2 – Cada trecho foi dividido em seis segmentos com intervalos de duração distintos. * Os eventos podem ser: EEG espontâneo, EEG do movimento do dedo indicador da mão esquerda e EEG da imaginação do mesmo movimento.....	41
Tabela 3 – Matrizes iniciais das probabilidades de transição entre os estados para as sessões de IM, MR e EEG espontâneo.....	44
Tabela 4 – Matrizes iniciais das probabilidades de emissão das observações para as sessões de IM, MR e EEG espontâneo.....	45
Tabela 5 – Eletrodos utilizados no treinamento e na validação e o índice de acerto obtido por cada sinal simulado do MR.....	49
Tabela 6 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de MR misturado a um ruído branco gaussiano.	50
Tabela 7 – Eletrodos utilizados no treinamento e na validação e o índice de acerto obtido por cada sujeito no EEG do IM misturado com ruído branco gaussiano.	51
Tabela 8 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG da IM misturado a um ruído branco gaussiano.....	51
Tabela 9 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de movimento e todos os indivíduos.	53
Tabela 10 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de imaginação de movimento para todos os indivíduos.	55
Tabela 11 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG espontâneo para todos os indivíduos.	56
Tabela 12 – Média dos índices de acerto na classificação dos eletrodos para os três sujeitos com HMM.....	61
Tabela 13 – Média dos índices de acerto na classificação dos eletrodos para os três sujeitos para RNA.....	66

Lista de Figuras

Figura 2.1 – Visão anatômica do cérebro mostrando a identificação dos lobos frontal, parietal, temporal e occipital (Modificado de KANDEL <i>et al.</i> , 2000).....	6
Figura 2.2 – Mapeamento e distribuição de algumas funções cerebrais. Fonte: http://www.guia.heu.nom.br/fun%C3%A7oes_do_cerebro.htm	7
Figura 2.3 – Superfície cerebral com as divisões citoarquitetônicas enumeradas por Brodmann (1909). Figura da esquerda modificada de http://spot.colorado.edu/~dubin/talks/brodmann/brodmann.html e da direita modificada de GUYTON <i>et al.</i> , 2006.	7
Figura 2.4 – Constituição do neurônio:Dendritos; Corpo celular; Axônio; Terminações axônicas e Sinapses. Modificado de GUYTON <i>et al.</i> , 2006.	9
Figura 2.5 – O Planejamento motor tem início na área pré-frontal, propagando-se pelo córtex pré-motor e suplementar até atingir o córtex motor primário, culminando na execução da tarefa. Modificado de KANDEL <i>et al.</i> , 2000.	10
Figura 2.6 – Componentes da hierarquia motora. Modificado de MADER <i>et al.</i> , 2004.	11
Figura 2.7 – Hierarquia do controle motor. No topo da hierarquia (verde) existe o córtex motor e suas associações (córtex frontal; pré-motor), em rosa tem-se o nível intermediário que representa o caminho das informações responsáveis pela execução de tarefa. O nível inferior (azul) é representado pelos neurônios motores, interneurônios, receptores e fibras musculares. Modificado de VANDER <i>et al.</i> (2001).....	12
Figura 2.8 – Homúnculo em corte mostrando a área sensório-motora. Fonte: http://brainconnection.positscience.com/	13
Figura 2.9 – Disposição do Sistema Internacional 10-20 dos eletrodos para aquisição de EEG. Modificado de WEBSTER (2006).....	14
Figura 2.10 – (a) Exemplos dos diferentes ritmos do EEG. (b) Presença e ausência do ritmo alfa quando o indivíduo abre e fecha os olhos. Modificado de WEBSTER (2006).....	16
Figura 2.11 – PRE de Movimento e da imaginação do dedo indicador da mão esquerda, avaliado no eletrodo Cz.	17
Figura 2.12 – Diagrama esquemático dos processos envolvidos em Interface Cérebro Máquina. Modificado de PFURTSCHELLER <i>et al.</i> (2008).	19
Figura 3.1 – Modelo Oculto de Markov com 3 estados (i, j, k). Modificado de YNOGUTI, 1999.	27
Figura 3.2 – Rede neural MLP com uma camada oculta.	33
Figura 4.1 – Amplificador de sinais biológicos, BrainNet BNT – 36 da Lynux Tecnologia Eletrônica Ltda.	36

Figura 4.2 – Sistema 10-10 utilizado para a aquisição dos sinais da segunda e terceira etapas de EEG realizadas (Modificado de BRAGA, 2007).....	37
Figura 4.3 – Acelerômetro utilizado para registrar o movimento do dedo indicador da mão esquerda.....	37
Figura 4.4 – Protocolo do Evento. O LED vermelho indica atenção e o LED amarelo indica a preparação para o movimento ou imaginação de movimento. Os sujeitos foram instruídos a fazer as tarefas após o desligamento dos LEDs.....	38
Figura 4.5 – PRE do eletrodo Cz do sujeito #1 nas sessões de movimento, imaginação e EEG espontâneo, utilizando $M=12$	40
Figura 4.6 – Modelo Oculto de Markov com seis estados. As setas indicam a transição de um estado para o outro ou para si mesmo e as cores representam os estados que contêm características de cada segmento: azul – EEG espontâneo; vermelho – EEG da visualização do LED vermelho; amarelo – EEG da visualização do LED amarelo; verde – EEG durante a realização do evento.	43
Figura 4.7 – Processo de treinamento do HMM.....	44
Figura 4.8 – Sistema de classificação para os sinais EEG a partir dos modelos HMM construídos para cada sujeito.....	46
Figura 4.9 – Processo de treinamento da RNA.....	47
Figura 4.10 – Sistema de validação e classificação para os sinais EEG a partir dos redes treinadas de cada sujeito.....	48
Figura 5.1 – Modelos para o EEG do MR misturado a ruído branco gaussiano dos três sujeitos analisados.	50
Figura 5.2 – Modelos para o EEG da IM misturado a ruído branco gaussiano dos três sujeitos analisados.	52
Figura 5.3 – Modelos para o EEG de movimento dos três sujeitos analisados. As probabilidades de transições que não são mostradas são nulas.	54
Figura 5.4 – Modelo do EEG da imaginação de movimento dos três sujeitos. As probabilidades de transição dos estados que não são mostradas na figura são nulas.	55
Figura 5.5 – Modelo do EEG espontâneo dos três sujeitos. As probabilidades de transição dos estados que não são mostradas na figura são nulas.....	56
Figura 5.6 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 1, utilizando os modelos feitos no treinamento para as etapas 2 e 3. As observações são obtidas através da coerência de 12 trechos.	57
Figura 5.7 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 1 para as 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo para obter as observações.	58

Figura 5.8 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 2 da 2ª e 3ª etapas de EEG, utilizando os modelos construídos no treinamento e $M=12$	59
Figura 5.9 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 2 para as 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo.	59
Figura 5.10 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 3 para a 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e $M=12$	60
Figura 5.11 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 3 para a 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo.	60
Figura 5.12 – Classificação do EEG do MR, IM e espontâneo do sujeito # 1, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.	62
Figura 5.13 – Classificação do EEG do MR, IM e espontâneo do sujeito # 1, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.	62
Figura 5.14 – Classificação do EEG do MR, IM e espontâneo do sujeito # 2, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.	63
Figura 5.15 – Classificação do EEG do MR, IM e espontâneo do sujeito # 2, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.	64
Figura 5.16 – Classificação do EEG do MR, IM e espontâneo do sujeito # 3, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.	65
Figura 5.17 – Classificação do EEG do MR, IM e espontâneo do sujeito # 3, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.	65

Lista de Abreviaturas

ANN	Artificial Neural Network
BCI	<i>Brain Computer Machine</i>
CT	Tomografia Computadorizada
DRE	Desincronização Relacionada ao Evento
ECG	Eletrocardiograma
EEG	Eletroencefalograma
ELA	Esclerose Lateral Amiotrófica
EM	<i>Expectation Maximization</i>
HMM	Modelos Ocultos de Markov – <i>Hidden Markov Model</i>
IA	Inteligência Artificial
ICA	Análise de Componentes Independentes – <i>Independent</i>
<i>Components Analysis</i>	
ICM	Interface Cérebro Máquina
IM	Imaginação de movimento
IRMF	Imagem Funcional por Ressonância Magnética
LEDs	<i>Light Emitter Diodes</i>
MGE	Magnetoencefalografia
MLP	<i>Multilayer Perceptron</i>
MR	Movimento Real
MSC	Magnitude Quadrática da Coerência – <i>Magnitude Squared</i>
<i>Coherence</i>	
ORD	Detecção Objetiva de Respostas – <i>Objective Response Detection</i>
PE	Potencial Evocado
PEA	Potenciais Evocados Auditivos
PEV	Potenciais Evocados Visuais
PCL	Potenciais Corticais Lentos
PSD	Densidade Espectral de Potência – <i>Power Spectral Density</i>

PRE	Potenciais Relacionados a Eventos
RNA	Redes Neurais Artificiais
RSR	Relação Sinal Ruído
SRE	Sincronização Relacionada ao Evento
SVM	Máquina de vetor de suporte – <i>Support Vector Machine</i>

CAPÍTULO 1: INTRODUÇÃO

A capacidade de comunicação dos seres humanos envolve dinamismo e complexidade na forma de transmissão da informação (BAYLISS, 2001; AZEVEDO, 2005; LOTTE *et al.*, 2007). O processo de comunicação consiste na codificação e decodificação dessas informações. A codificação envolve a ação de transmissão através de algum ato enquanto a decodificação envolve o acionamento de sensores para interpretar a informação recebida (BAYLISS, 2001; AZEVEDO, 2005; BIRBAUMER *et al.*, 2007).

Com o avanço tecnológico a necessidade de comunicação entre homens e máquinas promoveu o aparecimento das Interfaces Cérebro Máquina (ICM). O objetivo da ICM é fornecer uma forma de comunicação entre usuários e o ambiente ao seu redor, por meio do controle de dispositivos (LOTTE *et al.*, 2007; HOFFMANN *et al.*, 2007).

O alvo desta técnica são as pessoas que possuem algum tipo de deficiência motora, seja essa total (por exemplo, a esclerose lateral amiotrófica - ELA) ou parcial (amputações). Essas limitações motoras impossibilitam as pessoas de se comunicarem através de atividades musculares, mantendo somente a integridade cognitiva. Dessa forma, a ICM pode utilizar o potencial advindo da atividade cerebral para promover o acionamento de um dispositivo eletromecânico (EBRAHIMI *et al.*, 2003; GAO *et al.*, 2003).

Um dos desafios da ciência é a busca por uma forma de utilizar essas atividades cerebrais na comunicação. O modo mais viável economicamente é o eletroencefalograma (EEG) captado no couro cabeludo. Como as pessoas com algum tipo de deficiência motora não conseguem fazer movimentos, é necessário que as mesmas mandem o comando para a execução de tarefas, o que está relacionado com a imaginação de movimentos ou outra tarefa cognitiva.

Embora o sinal de EEG contenha as informações para o acionamento de dispositivos (tarefas cognitivas, por exemplo), o mesmo também contém outras informações, conhecidas como EEG espontâneo, que podem promover falsas detecções de comandos para as ICMs. Isso se torna um desafio para as técnicas de processamento de sinais.

Assim, a investigação do potencial relacionado a eventos para a comunicação em ICM exige processamento de sinais que aumentem a confiabilidade da sua detecção para reconhecimentos de padrões da atividade cerebral (MIDDENDORF *et al.*, 1999; PFURTSCHELLER *et al.*, 2001; BAZTARRICA, 2002; PFURTSCHELLER *et al.*, 2008), ou seja, esse processamento será responsável pela interpretação e tradução das atividades cerebrais em comandos (LOTTE *et al.*, 2007; EBRAHIMI *et al.*, 2003; HOFFMANN *et al.*, 2007). Para tanto, várias características podem ser extraídas do EEG, dentre as quais podem ser citadas: bandas de energia (PFURTSCHELLER *et al.*, 1997; PALANIAPPAN *et al.*, 2005); densidade espectral de potência (CHIAPPA *et al.*, 2004; BARRETO *et al.*, 2004); características em tempo frequência (WANG *et al.*, 2004; BANG-HUA *et al.*, 2007); modelos auto-regressivos (ANDERSON *et al.*, 1996; PENNY *et al.*, 2000; GARRETT *et al.*, 2003); coerência (SANTOS FILHO *et al.*, 2009). A Magnitude Quadrática da Coerência (MSC ou coerência) tem se mostrado uma técnica robusta reduzindo o número de épocas necessárias para a detecção do PRE, sendo eficiente na identificação do potencial relacionado à imagética motora (SANTOS FILHO *et al.*, 2009).

Após a escolha das características, a próxima etapa consiste em avaliar técnicas para a interpretação e classificação dos sinais EEG. Vários algoritmos estão sendo aplicados em ICM tais como classificadores lineares (discriminante de Fisher, K Vizinhos mais próximos, distância de Mahalanobis), redes neurais, classificadores bayesianos não lineares (Modelos de Markov), dentre outros (LOTTE *et al.*, 2007; YUGE *et al.*, 2008). O modelo oculto de Markov – HMM – é muito utilizado em reconhecimento de fala (RABINER, 1989), e sua aplicação em ICM tem sido investigada (BENGIO *et al.*, 1996; LOTTE *et al.*, 2007). Por outro lado, a aplicação da RNA em ICM tem bastante popularidade (CHIAPPA *et al.*, 2004; HELMY *et al.*, 2008). Assim, justifica-se a investigação da MSC junto com o HMM e RNA em reconhecimento de padrões em imagética motora.

1.1. Objetivos

O presente trabalho visa utilizar a Magnitude Quadrática da Coerência para extração das características durante: EEG espontâneo; EEG do movimento do dedo indicador da mão esquerda; e EEG devido à imaginação deste movimento. Para a modelagem e classificação emprega-se o HMM e a RNA.

1.2. Estrutura do trabalho

No capítulo 2 aborda-se a neurofisiologia do movimento real e imaginário, as técnicas de registro da atividade elétrica cerebral (EEG), o potencial relacionado a eventos (PRE), e aplicações do PRE em ICMs.

No capítulo 3 são apresentadas as técnicas de processamento de sinais utilizadas para o desenvolvimento do projeto: Média coerente, MSC, HMM e RNA. Neste são apresentados os cálculos envolvidos em cada técnica e sua aplicação em sinais EEG.

O quarto capítulo aborda a metodologia, apresentando um tópico com sinais simulados. Já os resultados obtidos são relatados no capítulo 5 e discutidos no capítulo 6. E, finalmente, a conclusão e propostas para trabalhos são apresentadas no capítulo 7.

CAPÍTULO 2: POTENCIAL RELACIONADO À IMAGÉTICA MOTORA

Inicialmente, este capítulo apresenta a neurofisiologia cerebral do movimento real e imaginário. As técnicas de registro da atividade cerebral, bem como as características do EEG são consideradas, enfatizando o potencial relacionado a eventos (PRE), que é o foco deste estudo. Adicionalmente, são apresentadas aplicações do PRE em ICMs.

2.1. Anatomia e fisiologia cerebral

O sistema nervoso é um dos sistemas de comunicação do corpo humano e está dividido em sistema nervoso central e periférico. O primeiro é constituído pelo cérebro e pela medula espinhal e o periférico é composto por pares de nervos (12 cranianos e 31 raquidianos), gânglios e terminações nervosas (KANDEL *et al.*, 2000; GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; DANGELO *et al.*, 2002). O sistema nervoso central é responsável pela percepção dos estímulos, comando e resposta (DANGELO *et al.*, 2002).

O funcionamento do cérebro e a codificação das informações que chegam a ele estão relacionados com a percepção advinda do meio externo. O cérebro é constituído, em sua maior parte, por água e gordura e seus tecidos são formados basicamente por dois tipos de células: os neurônios e as células gliais, estruturas que serão discutidas no tópico seguinte (GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; KANDEL *et al.*, 2000).

Esse órgão é dividido longitudinalmente, por uma fissura, em hemisfério esquerdo e direito. Os mapeamentos científicos da estrutura cerebral mostram que o hemisfério direito recebe informações do lado esquerdo e controla o movimento deste lado, enquanto que o hemisfério esquerdo recebe as sensações e controla o lado direito do corpo (KANDEL *et al.*, 2000; WILKINSON *et al.*, 2005).

Cada hemisfério cerebral é dividido anatomicamente em quatro lobos: frontal, parietal, temporal e occipital (Fig.2.1). Cada lobo possui uma importância específica para determinadas funções, como, por exemplo, o lobo frontal está relacionado com o planejamento de ações futuras, movimentos voluntários e elaboração de pensamento, o lobo occipital é responsável pela recepção e processamento visual, o lobo temporal está relacionado com a recepção e o processamento do som e o lobo parietal é responsável pela recepção e processamento de estímulos sensoriais e percepção da posição do corpo –

propriocepção (KANDEL *et al.*, 2000; GUYTON *et al.*, 2006; BEAR *et al.*, 2002). Algumas funções podem ser observadas na Fig. 2.2. Nessa pode-se avaliar a associação de funções, como por exemplo, a associação visual (região onde a informação visual é processada) e a visão, que estão totalmente localizadas no lobo occipital, ao passo que a coordenação de movimentos e a execução dos mesmos estão distribuídas entre os lobos frontal e parietal (GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; KANDEL *et al.*, 2000).

A parte mais externa do cérebro, formada por uma camada de substância cinzenta, é denominada córtex cerebral. Essa estrutura tem sido objeto de investigações que permitiram a divisão da mesma em áreas citoarquitetônicas. A divisão mais aceita atualmente, utilizada tanto para fins clínicos como pesquisa, é a de Brodmann que identificou 52 áreas – Fig. 2.3 – (GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; KANDEL *et al.*, 2000; BEAR *et al.*, 2002; CARVALHO, 2006).

Neste trabalho foram avaliadas as tarefas de imaginação e execução motora, sendo o foco o córtex motor primário (área 4), suplementar e pré-motor (área 6), como pode ser observado na Fig. 2.3. Para maiores detalhes sobre a fisiologia e anatomia cerebral verificar KANDEL *et al.* (2000), GUYTON *et al.* (2006), GREENSTEIN *et al.* (2000) e DANGELO *et al.* (2002).

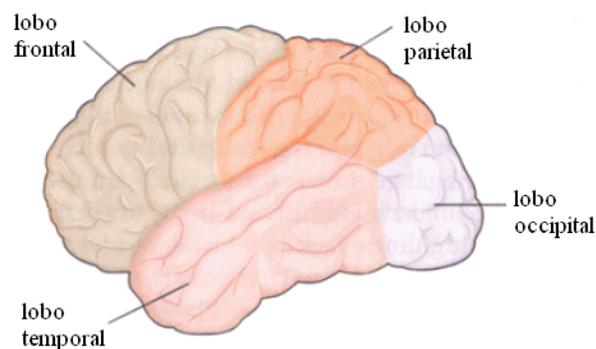


Figura 2.1 – Visão anatômica do cérebro mostrando a identificação dos lobos frontal, parietal, temporal e occipital (Modificado de KANDEL *et al.*, 2000).

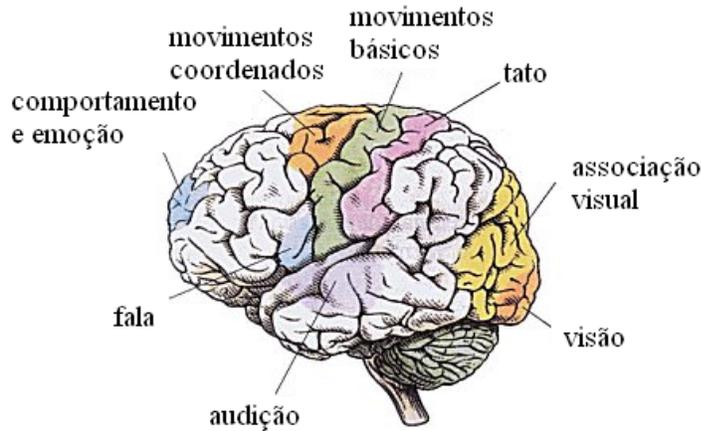


Figura 2.2 – Mapeamento e distribuição de algumas funções cerebrais. Fonte: http://www.guia.heu.nom.br/fun%C3%A7oes_do_cerebro.htm

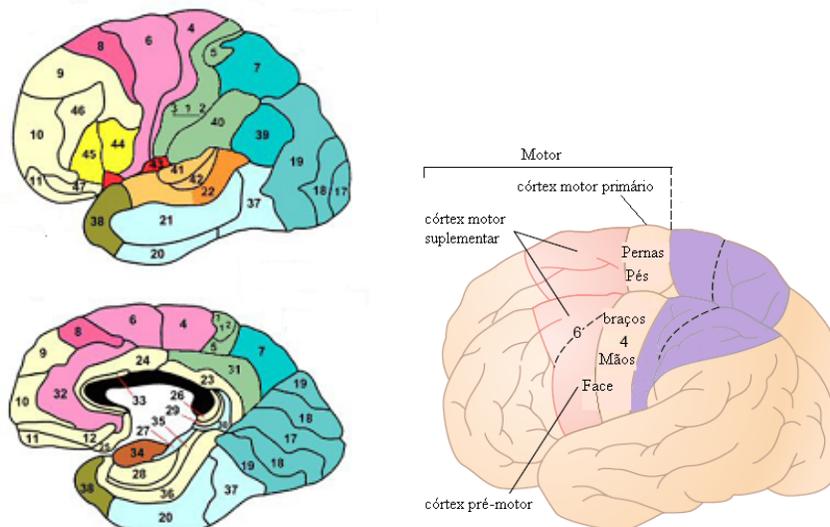


Figura 2.3 – Superfície cerebral com as divisões citoarquitetônicas enumeradas por Brodmann (1909). Figura da esquerda modificada de <http://spot.colorado.edu/~dubin/talks/brodmann/brodmann.html> e da direita modificada de GUYTON *et al.*, 2006.

2.1.1. Neurônios

De acordo com KANDEL *et al.* (2000), toda a base da percepção e das várias funções desempenhadas pelos seres humanos ocorrem por intermédio das células neurais e por suas conexões. Os neurônios têm como função o processamento das informações cerebrais, responsáveis pela recepção, armazenamento e transmissão dessas informações. Os mesmos existem em bilhões na estrutura cerebral e em diversas formas e tamanhos,

sendo classificados como neurônios aferentes, eferentes e interneurônios. Essas células conduzem as informações através dos potenciais de ação e a transmissão de uma célula para outra é dada através das sinapses (KANDEL *et al.*, 2000; GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; e DANGELO *et al.*, 2002).

O neurônio é constituído por: dendritos, corpo celular, axônio e terminações axônicas (Fig. 2.4). Os dendritos são responsáveis pelo recebimento das informações sinápticas e o corpo celular é o centro metabólico, onde ocorre todo o processo de nutrição da célula. Os axônios são responsáveis pela condução de informação do corpo celular até os terminais sinápticos, bem como a propagação de impulsos nervosos (KANDEL *et al.*, 2000; GUYTON *et al.*, 2006; GREENSTEIN *et al.*, 2000; e DANGELO *et al.*, 2002). E, para a sustentação, regulação do meio extra-celular e conexão dos neurônios existem as células gliais que estão em maior número no sistema nervoso. (DANGELO *et al.*, 2002; GREENSTEIN *et al.*, 2000). As formas características dos neurônios são caracterizadas pelos citoesqueletos, estruturas responsáveis pela sustentação da membrana neuronal. Obstruções nas mesmas podem causar doenças como o Alzheimer, caracterizada pela desestruturação do citoesqueleto de neurônios localizados na região responsável por funções cognitivas (BEAR *et al.*, 2002).

Quanto à classificação os neurônios podem ser divididos em sensoriais, que conduzem informação para o sistema nervoso central (vias aferentes); motores, que enviam comandos para os músculos e glândulas (vias eferentes); e interneurônios, que são referentes às demais células neurais que não se classificam nem como motoras e nem como sensoriais (KANDEL *et al.*, 2000).

Experimentos mantendo animais em ambientes com intensas tarefas motoras e cognitivas demonstraram que os neurônios das áreas cerebrais responsáveis pelas funções desempenhadas apresentaram maior número de sinapses e ramificações dendríticas (CARVALHO *et al.*, 2006). Essa repetitividade, por exemplo, em uma tarefa motora, gera a plasticidade uso-dependente, ou seja, mudanças funcionais do córtex cerebral devido à contínua atividade desempenhada. Através desse aprendizado, as sinapses dos grupos de neurônios, codificam novas informações, sejam elas tarefas motoras ou fatos e eventos (CARVALHO, 2006).

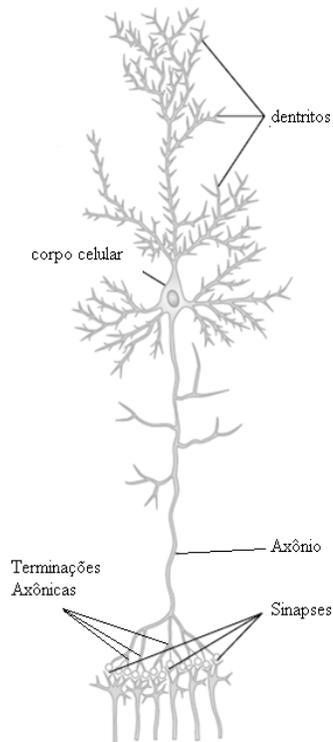


Figura 2.4 – Constituição do neurônio: Dendritos; Corpo celular; Axônio; Terminações axônicas e Sinapses. Modificado de GUYTON *et al.*, 2006.

Alterações neurais no córtex motor foram avaliadas durante treinamento de ratos, sendo observadas novas sinapses e reorganização dos mapas motores. Essa reorganização foi obtida através de treinamento intenso, revelando uma aprendizagem lenta (CARVALHO, 2006).

Dessa forma, os neurônios são responsáveis por toda a comunicação existente e transmissão das informações, seja de percepção ou não. Maiores detalhes sobre fisiologia neuronal pode ser avaliada em KANDEL *et al.* (2000), GUYTON *et al.* (2006), GREENSTEIN *et al.* (2000) e DANGELO *et al.* (2002).

2.2. Fisiologia de movimentos reais e imaginados

A área cerebral destinada à execução motora é chamada de córtex motor, envolvendo parte dos lobos frontal e parietal (VANDER *et al.*, 2001). Essa região está dividida em três áreas interligadas: córtex motor primário; córtex pré-motor; e córtex motor suplementar (Fig. 2.3) que correspondem às áreas 4 (córtex motor primário) e 6 (córtex pré-motor e motor suplementar) do mapa citoarquitetônico de Brodmann. Nessa região existe uma hierarquia funcional para a realização das tarefas, iniciando-se com o

planejamento, propagação da informação pelas vias motoras até a realização do movimento propriamente dito (VANDER *et al.*, 2001; KANDEL *et al.*, 2000). Estudos realizados em animais mostraram que o córtex motor primário é responsável pela aprendizagem das habilidades manuais finas, sendo relevante na aprendizagem motora e cognitiva (CARVALHO, 2006).

O planejamento das tarefas motoras tem início no córtex pré-frontal (Fig. 2.5 – área 8 na Fig. 2.3), que, juntamente com o córtex parietal posterior (áreas 5 e 7 – Fig. 2.3), definem quais ações serão realizadas. As informações dessas áreas são enviadas através dos neurônios ou redes neuronais para as áreas do córtex pré-motor e motor suplementar e, posteriormente, para o córtex motor primário. O córtex pré-motor recebe informações de três fontes, que podem ser observadas na Fig. 2.6: núcleo motor no tálamo; tronco encefálico; e cerebelo (VANDER *et al.*, 2001; KANDEL *et al.*, 2000).

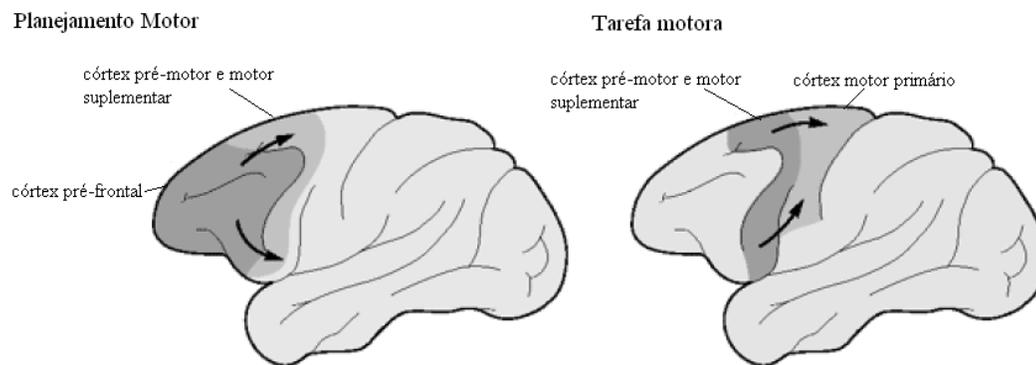


Figura 2.5 – O Planejamento motor tem início na área pré-frontal, propagando-se pelo córtex pré-motor e suplementar até atingir o córtex motor primário, culminando na execução da tarefa.

Modificado de KANDEL *et al.*, 2000.

Hierarquicamente, o desenvolvimento das tarefas motoras pode ser dividido em nível inferior, nível intermediário e nível superior (Fig. 2.7). Na base do nível inferior estão os receptores (recebem estímulos externos) e as fibras musculares que executam o movimento. Logo acima se encontra o nível local que é constituído pelos neurônios motores e interneurônios que recebem e enviam informações para o tronco encefálico.

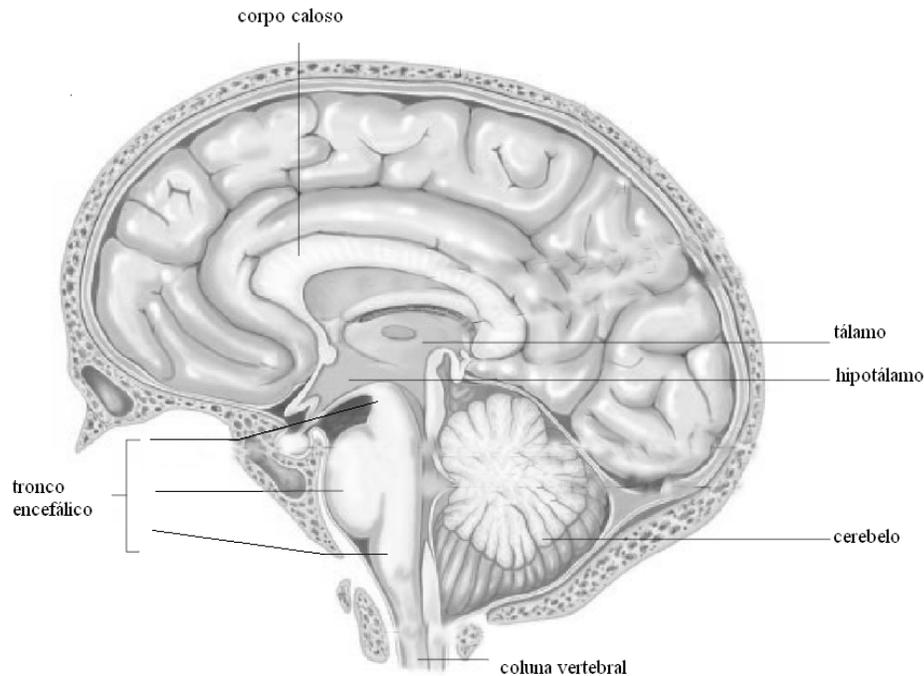


Figura 2.6 – Componentes da hierarquia motora. Modificado de MADER *et al.*, 2004.

No nível intermediário tem-se o tronco encefálico, cerebelo, tálamo, gânglio basal e o córtex sensorial motor (Figs 2.6 e 2.7). O primeiro é responsável por várias funções tais como respiração, pensamento, julgamento, percepção e movimento voluntário (VANDER *et al.*, 2001). Já o cerebelo tem como função principal o equilíbrio postural na condução da ação e, assim como o gânglio basal, é responsável pela coordenação de movimentos (uma disfunção nessa região pode causar o tremor nas pessoas com mal de Parkinson – WILKINSON *et al.*, 2005; VANDER *et al.*, 2001). O tálamo participa do controle e coordenação dos músculos esqueléticos, recebe informação de algumas vias aferentes (visual, auditiva e somatossensorial), além de participar da integração sensorial e motora. Já o córtex sensorial-motor envolve as partes do córtex cerebral que atuam em conjunto para controlar a atividade dos músculos esqueléticos. No topo da hierarquia está o córtex motor e suas associações (GREENSTEIN *et al.*, 2000; VANDER *et al.*, 2001; MADER *et al.*, 2004).

Estudos realizados através da estimulação elétrica em várias regiões do córtex motor primário geraram um mapeamento das áreas musculares nessa parte cerebral (Fig. 2.8). No homúnculo representado na Fig. 2.8 percebe-se a grande área cerebral designada para o movimento da mão, o que justifica o uso da mesma na imaginação de movimento de muitos estudos (VANDER *et al.*, 2001; KANDEL *et al.*, 2000; GUYTON *et*

al., 2006). Através de técnicas de neuroimagem funcional verificou-se que esses mapas são dinâmicos, sofrendo alterações de acordo com as experiências, o ambiente e até mesmo em resposta a lesões cerebrais (CARVALHO, 2006).

Os movimentos gerados no córtex motor primário têm suporte no córtex pré-motor, ou seja, o córtex pré-motor auxilia no desenvolvimento de tarefas que envolvem vários músculos e órgãos. Por exemplo, o movimento dos braços e ombros para que as mãos sejam orientadas a realizar uma tarefa específica. Para que esse objetivo seja atingido, a parte anterior do córtex pré-motor elabora uma “imagem motora” da tarefa (VANDER *et al.*, 2001; KANDEL *et al.*, 2000; GUYTON *et al.*, 2006). Maiores detalhes sobre anatomia e fisiologia do processo motor pode ser encontrado em KANDEL *et al.* (2000), VANDER *et al.* (2001) e MADER *et al.* (2004).

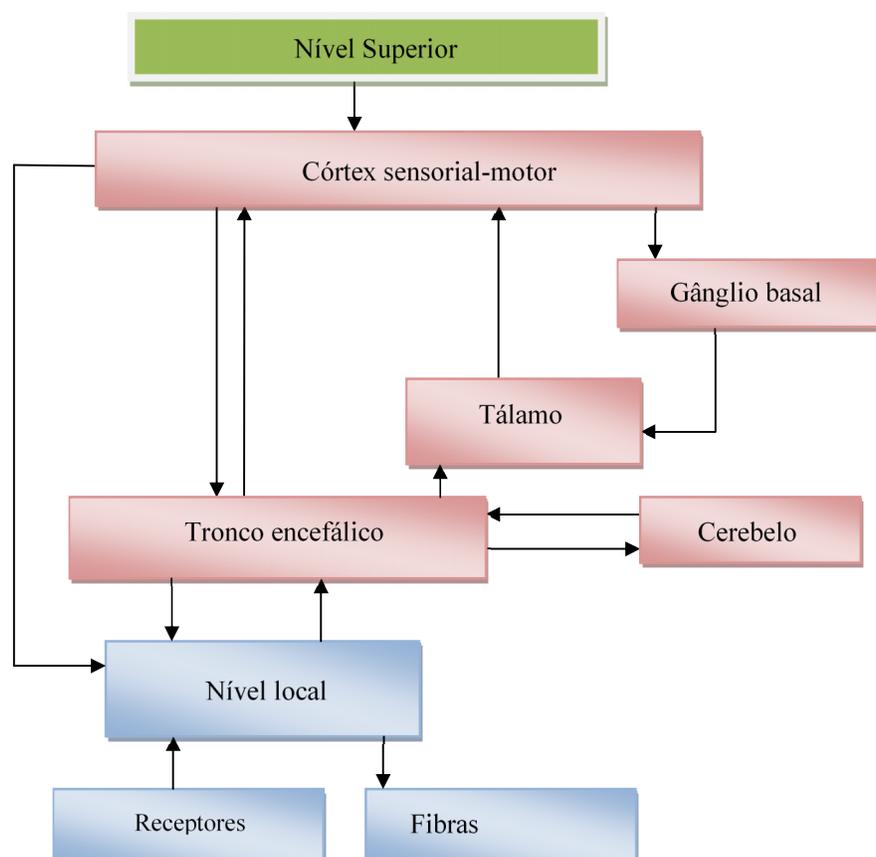


Figura 2.7 – Hierarquia do controle motor. No topo da hierarquia (verde) existe o córtex motor e suas associações (córtex frontal; pré-motor), em rosa tem-se o nível intermediário que representa o caminho das informações responsáveis pela execução de tarefa. O nível inferior (azul) é representado pelos neurônios motores, interneurônios, receptores e fibras musculares. Modificado de VANDER *et al.* (2001).

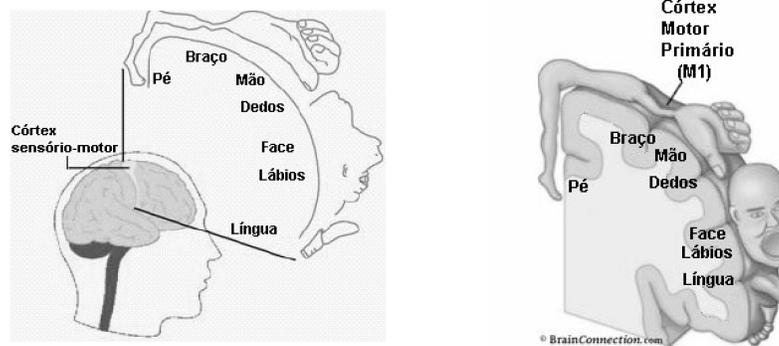


Figura 2.8 – Homúnculo em corte mostrando a área sensório-motora. Fonte: <http://brainconnection.positscience.com/>

2.3. Sinais de Eletroencefalograma

Uma técnica clássica de medição dos sinais cerebrais é o eletroencefalograma (EEG). Comparado com outras técnicas tais como Magnetoencefalografia (MGE), Imagem Funcional por Ressonância Magnética (IRMF) e Tomografia Computadorizada (TC), o EEG é o que pode ser adquirido e processado com um menor custo, sendo amplamente utilizados em aplicações de ICM (WOLPAW *et al.*, 2000; AZEVEDO, 2005).

O registro dos sinais cerebrais através da eletroencefalografia é feito por meio de eletrodos fixados na superfície do escalpo. Esses eletrodos são pequenos discos de metal, confeccionados de prata/cloreto de prata ou ouro, cuja disposição no escalpo mais utilizada, para a aquisição de EEG, é o Sistema Internacional 10-20 – Fig. 2.9 (TATUM *et al.*, 2007; AZEVEDO, 2005; BAZTARRICA, 2002). Neste sistema, os números pares indicam eletrodos do lado direito da cabeça e os ímpares do esquerdo. As letras F, C, P, T e O são utilizadas para identificar as diferentes regiões do córtex, sendo frontal, central, parietal, temporal e occipital, respectivamente (TATUM *et al.*, 2007; WEBSTER, 2006; BAZTARRICA, 2002).

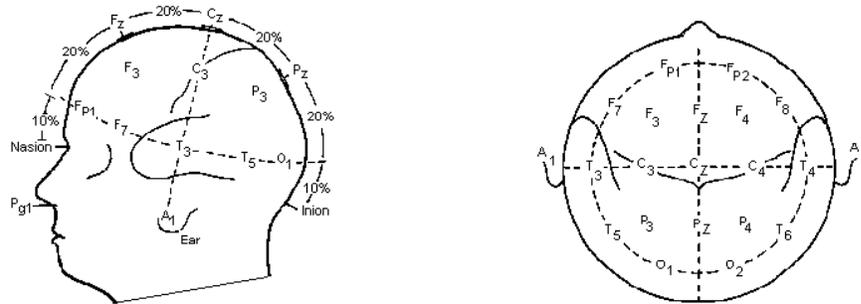


Figura 2.9 – Disposição do Sistema Internacional 10-20 dos eletrodos para aquisição de EEG.

Modificado de WEBSTER (2006).

A amplitude dos sinais EEG coletados no escalpo variam em torno de 10 a 150 μV e a faixa de frequência para análises clínicas é de 0,1 a 50 Hz. Essa baixa amplitude é promovida, principalmente, pelas camadas existentes entre o cérebro e o escalpo (WEBSTER, 2006).

Para aplicações em ICM algumas características do EEG devem ser analisadas. Nos tópicos seguintes serão apresentadas as bandas de frequências existentes no EEG e os potenciais relacionados a eventos.

2.3.1. Bandas de frequência no EEG

O registro de EEG sem a existência de estímulos, denominado EEG espontâneo, caracteriza-se por bandas específicas de frequência (Tabela 1 e Fig. 2.10). Essas bandas são classificadas de acordo com o estado de consciência do indivíduo, sofrendo variações de acordo com a atividade desenvolvida. Existem diferenças na literatura quanto à faixa de frequência destas bandas, mas comumente, são nomeadas e diferenciadas da seguinte forma (TATUM *et al.*, 2007; WEBSTER, 2006; BAZTARRICA, 2002; AZEVEDO, 2005):

- Banda Delta (δ): A banda δ é caracterizada por frequências inferiores a 4 Hz (comumente entre 0,1 e 4 Hz) e possuem amplitude inferior a 100 μV . Associado ao estado de sono profundo, esse ritmo é registrado de forma predominante, na região frontal do córtex cerebral.
- Banda Teta (θ): A banda θ possui faixa de frequência entre 4 e 8 Hz e amplitude em torno de 100 μV . Em crianças esse ritmo é mais dominante e,

em adultos, é observado durante sonolência ou sono leve. Estas ondas podem ser registradas nas regiões parietais e temporais estando os indivíduos em estado de profunda meditação, estresse emocional e outras atividades mentais, tais como a solução de problemas.

- Banda Alfa (α): Esse ritmo é definido em uma faixa de frequência de 8 a 13 Hz e é registrado em maior amplitude na região occipital. Essa amplitude varia em torno de 30 a 50 μV e sua observação se dá quando o indivíduo encontra-se em estado de vigília. O mesmo sofre atenuação quando ocorre atenção, principalmente visual, e esforço mental.
- Banda Mu (μ): O ritmo μ possui a faixa de frequência de 10 a 12 Hz e amplitude inferior a 50 μV . Embora possua características de frequência e amplitude semelhantes às do ritmo alfa, a banda μ é registrada em uma região distinta do córtex cerebral: o córtex motor. Sua intensidade pode ser afetada durante movimento ou pela intenção de movimento.
- Banda Beta (β): A banda β apresenta predominância nas regiões frontais e parietais do córtex cerebral e sua faixa de frequência é definida de 14 a 30 Hz. Esse ritmo é normalmente associado à atividade mental, atenção, sendo sua amplitude inferior a 30 μV .

Tabela 1 – Faixas de frequência das bandas do EEG.

Ritmo	Faixa de frequência (Hz)
Delta	0,1 a 4
Teta	4 a 8
Alfa	8 a 13
Um	10 a 12
Beta	14 a 30

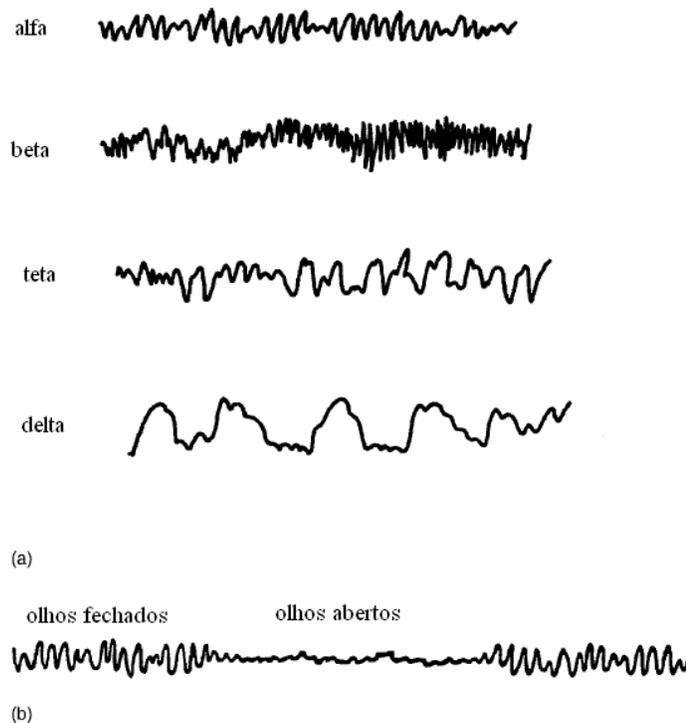


Figura 2.10 – (a) Exemplos dos diferentes ritmos do EEG. (b) Presença e ausência do ritmo alfa quando o indivíduo abre e fecha os olhos. Modificado de WEBSTER (2006).

2.3.2. Potenciais relacionados a eventos

A atividade elétrica cerebral registrada no EEG sofre alteração em resposta a um estímulo externo. Quando essa alteração é sincronizada em tempo e em fase com o evento tem-se o potencial evocado (PE) ou potencial relacionado ao evento (PRE) – neste trabalho adotaremos o termo PRE. Se a alteração for sincronizada com o evento apenas no tempo, têm-se os processos de sincronização relacionada ao evento (SRE) e dessincronização relacionada ao evento (DRE) (KALCHER *et al.*, 1995; PFURTSCHELLER *et al.*, 1999; PFURTSCHELLER *et al.*, 2006; TAKAHASHI *et al.*, 2009). A análise realizada neste trabalho avaliou apenas o PRE, portanto, maiores detalhes dos demais processos podem ser encontrados em KALCHER *et al.* (1995) e PFURTSCHELLER *et al.* (2006).

Estimulações de naturezas variadas estão incluídas nos PRE's dentre as quais se podem citar: potencial evocado por estimulação sensorial - visual (PEV) (CHENG *et al.*, 2002; MIRANDA DE SÁ *et al.*, 2004; PICCIONE *et al.*, 2006), potencial evocado auditivo (PEA) (DOBIE *et al.*, 1989; NIJBOER *et al.*, 2007), potencial evocado somatosensitivo (TIERRA-CRIOLLO, 2001) e potencial cortical lento (PCL), decorrentes

de movimentos ou tarefa mental (BIRBAUMER *et al.*, 2000; KREPKIA *et al.*, 2007; MELLONI *et al.*, 2007).

Esses potenciais possuem amplitudes inferiores as do EEG espontâneo (baixa relação sinal ruído – RSR), dificultando a detecção com um único trecho de sinal (AZEVEDO, 2005). Dessa forma, a fim de melhorar a relação sinal ruído, comumente utiliza-se a média coerente dos trechos (TIERRA-CRIOLLO, 2001; PFURTSCHELLER *et al.*, 1999), enfatizando o PRE (melhor RSR). Um exemplo do PRE no eletrodo Cz do movimento e da imaginação do dedo indicador da mão esquerda está ilustrado na Fig. 2.11.

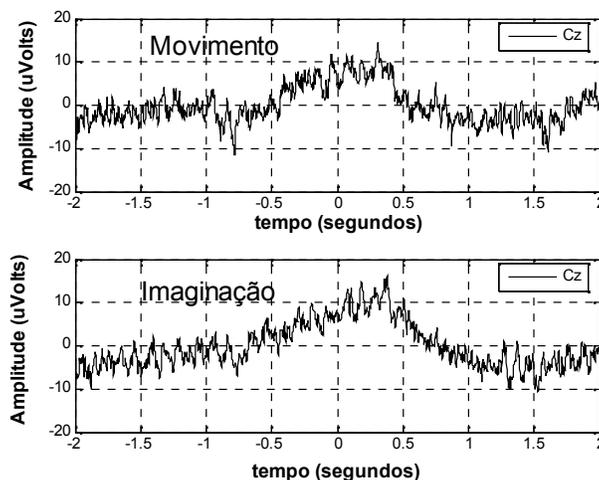


Figura 2.11 – PRE de Movimento e da imaginação do dedo indicador da mão esquerda, avaliado no eletrodo Cz.

O PRE referente ao movimento possui amplitude em torno de $10 \mu\text{V}$ e é registrado no córtex motor (RUGG *et al.*, 1996). Por outro lado, o PRE da imaginação motora pode apresentar amplitude inferior a esse valor, sendo melhorado com sessões de treinamento (NEUMANN *et al.*, 2003). Além disso, na realização ou imaginação de tarefas motores ocorrem variações das bandas alfa e beta, que estão relacionadas com a SRE e a DRE (PFURTSCHELLER *et al.*, 1999; GYSELS *et al.*, 2004; PFURTSCHELLER *et al.*, 2006).

2.3.3. Aplicações em Interface Cérebro-Máquina (ICM)

O objetivo principal da ICM é controlar dispositivos através dos padrões de atividades cerebrais do usuário (BAYLISS, 2001; GYSELS *et al.*, 2004; AZEVEDO, 2005; NIJHOLT *et al.*, 2008; PFURTSCHELLER *et al.*, 2008). Essa forma de comunicação proporciona aplicações tais como a interação de pessoas com pequeno ou

nenhum controle motor (perdas de membros ou Esclerose Lateral Amiotrófica – ELA) ou controle de jogos de computadores (KAMOUSHI *et al.*, 2005; PFURTSCHELLER *et al.*, 2008).

Os sinais de EEG são os mais utilizados para aplicações em ICM por apresentarem alta resolução temporal, baixo custo, portabilidade e terem possibilidade de implementação em tempo real (AZEVEDO, 2005; POPESCU *et al.*, 2008). Após a aquisição dos sinais de EEG é necessário a identificação de padrões dos mesmos para o funcionamento da ICM (BAYLISS, 2001; PFURTSCHELLER *et al.*, 2008; HELMY *et al.*, 2008).

As ICM's podem ser classificadas de acordo com a atividade utilizada para sua implementação. Dessa forma tem-se as ICM's dependentes que necessitam da atividade muscular e as independentes que são implementadas com os PRE's, sem a necessidade da atividade motora (PFURTSCHELLER *et al.*, 1997; WOLPAW *et al.*, 2000; GYSELS *et al.*, 2004; BIRBAUMER *et al.*, 2007; LIN *et al.*, 2009).

Como exemplo das ICM's tem-se a utilização dos padrões de PEV (LEISTRITZ *et al.*, 1999; MIDDENDORF *et al.*, 1999; CHENG *et al.*, 2002; GAO *et al.*, 2003), o P300 (LEVINE *et al.*, 2000; KAPER *et al.*, 2004; PICCIONE *et al.*, 2006; HELMY *et al.*, 2008), os potenciais relacionados a imaginação de movimento (BIRBAUMER *et al.*, 2000; PFURTSCHELLER *et al.*, 2001; QIN *et al.*, 2004; WANG *et al.*, 2004; KAMOUSHI *et al.*, 2005; BIRBAUMER *et al.*, 2007) e a SRE e DRE de diferentes bandas (PFURTSCHELLER *et al.*, 1997; NEUPER *et al.*, 1999; WANG *et al.*, 2004; TAKAHASHI *et al.*, 2009).

Na Fig. 2.12 tem-se o diagrama esquemático dos processos envolvidos em ICM. Cada etapa possui suas peculiaridades sendo abaixo apresentadas as características de aquisição, pré-processamento, extração de características, classificação e aplicação em interface:

1. Aquisição dos Sinais Cerebrais: Essa etapa consiste no registro da atividade elétrica cerebral, com boa relação sinal-ruído. Para o registro do EEG, por exemplo, utilizam-se eletrodos de prata/cloreto de prata ou de ouro. Para que a qualidade do sinal registrado seja adequada, é necessário que haja um bom contato entre a pele e o eletrodo, caracterizando uma baixa impedância (limpeza do local e utilização de gel condutor). Os sinais captados pelos

eletrodos são direcionados a um estágio de amplificação, composto por amplificadores de instrumentação. Esses amplificadores possuem alta impedância de entrada (ordem de $G\Omega$), elevada razão de rejeição de modo comum (maior que 90 dB) e ganho da ordem de 10000 (PRUTCH *et al.*, 2005; WEBSTER, 2006). Os sinais EEG amplificados são filtrados por filtros passa-faixas, cujas freqüências variam de acordo com o potencial analisado (potenciais relacionados ao movimento e à imaginação de movimento são filtrados em uma faixa de 0,5 a 42 Hz) (NEUPER *et al.*, 1997; PRUTCH *et al.*, 2005). Além disso, existe um filtro *notch* para remover os 60 Hz e seus harmônicos. Finalmente, a conversão analógico-digital deve ser realizada.

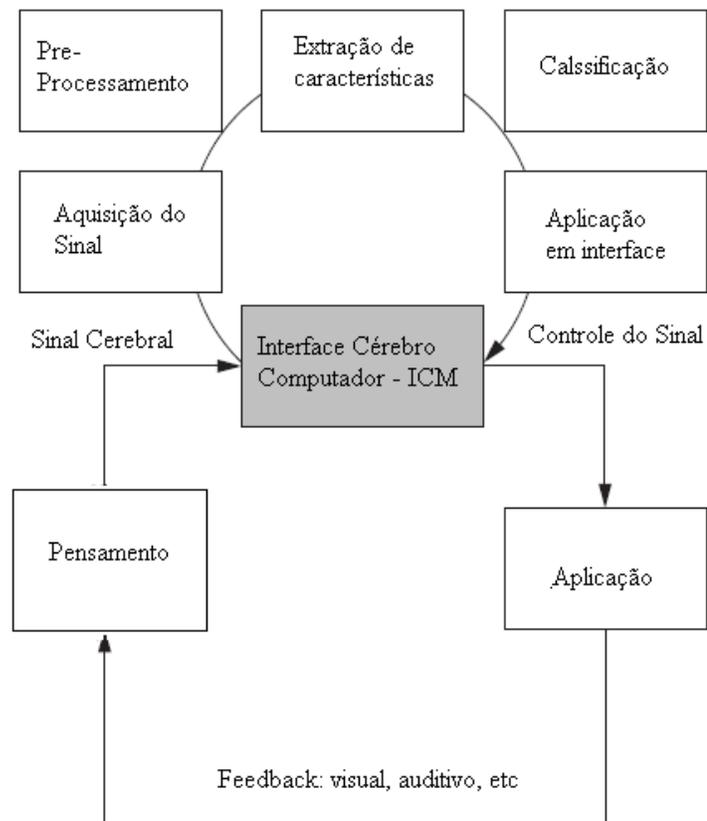


Figura 2.12 – Diagrama esquemático dos processos envolvidos em Interface Cérebro Máquina.

Modificado de PFURTSCHELLER *et al.* (2008).

2. Pré-processamento: Essa etapa é caracterizada pela remoção de ruídos existentes nos sinais evitando falsas interpretações. Esses ruídos podem ter origem elétrica ou fisiológica. Nos de origem técnica tem-se os artefatos de

linha (60 Hz e seus harmônicos) e flutuações na impedância dos eletrodos (eletrodos mal fixados ou danificados). Já os de origem fisiológica podem ser artefatos oculares, musculares e eletrocardiográficos (AZEVEDO, 2005). A remoção desses ruídos pode ser feita, por exemplo, através de técnicas de filtragem ou análise de componentes independentes – ICA (OMIDVARNIA *et al.*, 2005; HUANG *et al.*, 2009), ou técnicas de remoção automática de artefatos (TIERRA-CRIOLLO, 2001).

3. Extração de características: Várias formas de extração de características tem sido propostas em ICM's (LOTTE *et al.*, 2007; YUGE *et al.*, 2008). Dentre essas podem ser citadas a promediação de trechos dos sinais de EEG sincronizados com o evento (TIERRA-CRIOLLO, 2001; BRAGA, 2007), análise por componentes independentes (HAN *et al.*, 1999; LEE *et al.*, 1999), análise de densidade espectral de potência – PSD (PALANIAPPAN *et al.*, 2002; BARRETO *et al.*, 2004), transformada wavelet (BANG-HUA *et al.*, 2007; TING *et al.*, 2008; YUGE *et al.*, 2008) e modelos auto-regressivos (ANDERSON *et al.*, 1996; PFURTSCHELLER *et al.*, 2001; GARRETT *et al.*, 2003).
4. Classificação: Esta etapa do processo consiste na modelagem e interpretação dos padrões dos sinais EEG analisados. Os métodos comumente utilizados em ICM's para a classificação são: redes neurais e neurofuzzy (PALANIAPPAN *et al.*, 2002; PICCIONE *et al.*, 2006), classificadores bayesianos (GARRET *et al.*, 2003), máquina de suporte vetorial (GYSELS *et al.*, 2004; DORNHEGE, 2006), modelos lineares e não lineares (PFURTSCHELLER *et al.*, 2001; ZHONG *et al.*, 2002; HINTERBERGER *et al.*, 2003; CHIAPPA *et al.*, 2004), componentes principais (CHIAPPA *et al.*, 2006), dentre outros. Aplicações recentes em ICM, utilizando combinações de vários classificadores, mostraram bons resultados quanto à precisão dos mesmos (HAMMON *et al.*, 2007; LOTTE *et al.*, 2007).
5. Aplicação em interface: Nessa etapa o sinal processado deve ser capaz de acionar algum dispositivo, de acordo com a aplicação esperada. Algumas implementações são direcionadas para movimentação de cursores em uma tela (BIRBAUMER *et al.*, 2000; OBERMAIER *et al.*, 2001;

PFURTSCHELLER *et al.*, 2003) ou o acionamento de dispositivos eletromecânicos tais como próteses e órteses (TAYLOR *et al.*, 2000; YU *et al.*, 2004).

CAPÍTULO 3: EXTRAÇÃO DE CARACTERÍSTICAS, MODELAGEM E CLASSIFICAÇÃO DOS SINAIS EEG DURANTE MOVIMENTO E IMAGINAÇÃO MOTORA

A literatura apresenta várias técnicas de extração de características, modelagem e classificação dos sinais EEG para aplicação em ICM, como discutido no Capítulo 2. Dessa forma, este capítulo descreve os métodos utilizados no presente trabalho. Primeiramente faz-se uma análise sobre os métodos clássicos da média coerente e Magnitude Quadrática da Coerência para detecção do PRE e extração de características. Posteriormente, é apresentada a modelagem e classificação utilizando modelos Ocultos de Markov (especificamente os modelos ocultos discretos) seguidos de uma análise com redes neurais artificiais em sua estrutura perceptron de multi-camadas. Em todos os tópicos são avaliadas as aplicações das técnicas junto aos sinais de EEG e para aplicações em ICM.

3.1. Extração de características

3.1.1. Média Coerente

A média coerente é uma técnica clássica para a detecção de PRE a partir de vários trechos do sinal EEG sincronizados com o estímulo (NIEDMEYER *et al.*, 1988; TIERRA-CRIOLLO, 2001; BRAGA, 2007).

Assumindo que a resposta evocada ($s(t)$) é determinística e o ruído $e(t)$ é aleatório de média zero, o EEG registrado no escalpo ($x(t)$) é dado por (NIEDMEYER *et al.*, 1988; TIERRA-CRIOLLO, 2001; BRAGA, 2007):

$$X(t) = s(t) + e(t) \tag{Eq. 1}$$

Como se supõe que o ruído não sincronizado com o estímulo ($e(t)$ na Eq.1) é um sinal aleatório estacionário - características estatísticas invariantes no tempo – sua esperança é nula. Dessa forma, a esperança matemática de $x(t)$ resulta no PRE:

$$E[x(t)] = E[s(t) + e(t)] = E[s(t)] + E[e(t)] = s(t) \tag{Eq. 2}$$

Assim o PRE pode ser estimado através da média de M trechos do sinal EEG durante estimulação ($x_i(t)$), sincronizados com o estímulo:

$$\hat{s}(t) = \frac{1}{M} \sum_{i=1}^M x_i(t) \quad \text{Eq. 3}$$

Considerando os trechos estatisticamente independentes e $s(t)$ determinístico, a variância da média coerente será função da variância do ruído:

$$\text{var}[\hat{s}(t)] = \text{var}\left[\frac{1}{M} \sum_{i=1}^M x_i(t)\right] = \frac{1}{M^2} \sum_{i=1}^M \text{var}[x_i(t)] = \frac{1}{M} \text{var}[e(t)] \quad \text{Eq. 4}$$

Dessa forma, a RSR em dB aumenta em um fator de M e é dada por:

$$10 \log_{10}(M) \quad \text{Eq. 5}$$

3.1.2. Magnitude Quadrática da Coerência (MSC – Magnitude Squared Coherence)

A MSC ou coerência é uma técnica de detecção objetiva de respostas (ORD – *Objective Response Detection*) que se baseia em critérios estatísticos e quantitativos (CARTER, 1987; RAMOS *et al.*, 2000). Esta técnica tem sido apontada como uma das mais robustas, pois reduz o número de épocas necessárias para a detecção de PRE, sendo seu limiar independente da forma de resposta (CARTER, 1987). Dentro do contingente de aplicações pode-se citar as detecções dos potenciais relacionados à estimulação somato-sensitiva (SIMPSON *et al.*, 2000; TIERRA-CRIOLLO, 2001; INFANTOSI *et al.*, 2006), do potencial evocado auditivo (DOBIE *et al.*, 1989; RAMOS *et al.*, 2000; FELIX *et al.*, 2002), do potencial evocado visual (MIRANDA DE SÁ *et al.*, 2002; MIRANDA DE SÁ *et al.*, 2005; MIRANDA DE SÁ *et al.*, 2007) e do potencial relacionado a imaginação de movimento (SANTOS FILHO *et al.*, 2009). No presente trabalho a coerência foi aplicada na detecção do PRE relacionado tanto ao movimento como à imaginação motora.

Segundo DOBIE *et al.* (1989), a MSC é baseada na função de coerência entre dois sinais $y[n]$ e $x[n]$

$$\gamma_{yx}(f) = \frac{P_{yx}(f)}{\sqrt{P_{yy}(f)} \sqrt{P_{xx}(f)}} \quad \text{Eq. 6}$$

onde $P_{yx}(f)$ é a densidade espectral de potência cruzada (*Cross PSD – Cross Power Spectral Density*), e $P_{yy}(f)$ e $P_{xx}(f)$ são as PSD's individuais. A função coerência indica a dependência linear dos harmônicos dos sinais avaliados. Elevando ao quadrado o valor absoluto da Eq. 6 tem-se:

$$\kappa(f) = |\gamma_{yx}(f)|^2 = \frac{|P_{yx}(f)|^2}{P_{yy}(f)P_{xx}(f)} \quad \text{Eq. 7}$$

Esse valor é um número real e o $\hat{\kappa}(f)$ para sinais ergódicos é dado por (DOBIE *et al.*, 1989; SIMPSON *et al.*, 2000; MIRANDA DE SÁ *et al.*, 2002; MIRANDA DE SÁ *et al.*, 2007):

$$\hat{\kappa}(f) = \frac{\left| \sum_{i=1}^M Y_i(f) X_i^*(f) \right|^2}{\sum_{i=1}^M |Y_i(f)|^2 \sum_{i=1}^M |X_i(f)|^2} \quad \text{Eq. 8}$$

onde * indica o complexo conjugado, $Y_i(f)$ e $X_i(f)$ são as transformadas de Fourier da i -ésima janela, e M é o número de trechos usadas para a estimação.

Considerando o sinal $y[n]$ idêntico em todos os trechos, por exemplo, um estímulo sensorial em uma tarefa cognitiva relacionada a um evento, e $x[n]$ o sinal de EEG do escalpo, o valor de $\hat{\kappa}(f)$ pode ser simplificado e representado por (DOBIE *et al.*, 1989; SIMPSON *et al.*, 2000; MIRANDA DE SÁ *et al.*, 2002; MIRANDA DE SÁ *et al.*, 2007):

$$MSC(f) = \frac{\left| \sum_{i=1}^M X_i(f) \right|^2}{M \sum_{i=1}^M |X_i(f)|^2} \quad \text{Eq. 9}$$

Para o nível de significância desejado (α) pode-se obter um valor crítico que constitui um limiar estatístico para o detector. Esse limiar, para a hipótese nula de ausência de resposta é dado por (MIRANDA DE SÁ *et al.*, 2007)

$$MSC_{crit} = 1 - \alpha^{\frac{1}{M-1}} \quad \text{Eq. 10}$$

Na presença de resposta relacionada ao evento, na frequência f , é esperada uma detecção positiva ($MSC(f) > MSC_{crit}$). Na ausência de resposta ou na condição de não

realização do evento (EEG espontâneo) uma taxa de falso positivo de α é esperada em todas as frequências.

3.2. Modelagem e Classificação

3.2.1. Modelos Ocultos de Markov

O Modelo Oculto de Markov (*Hidden Markov Model – HMM*) foi descrito pela primeira vez no final dos anos 60 e ganhou popularidade em aplicações de fala na década de 70 (RABINER, 1989).

Esse modelo é um tipo de autômato probabilístico no qual cada estado modela a probabilidade de se observar um dado vetor de observações (RABINER, 1989). Dessa forma, o mesmo consiste de um processo duplamente estocástico, contendo um processo oculto – estados conectados por transições probabilísticas – e outro observável – conjunto de observações atribuído a cada estado (RABINER, 1989; KÜNSCH *et al.*, 1995; BENGIO *et al.*, 1996; YNOGUTI, 1999).

O HMM tem sido largamente aplicado em áreas variadas tais como: análise de séries de eletrocardiograma (ECG) (ANDREÃO *et al.*, 2006; MÜLLER *et al.*, 2006); reconstituição de fala (RABINER, 1989; JUANG *et al.*, 1991; OSTENDORF, 1996; YNOGUTI, 1999); aplicações em ICM com sinal de EEG (OBERMAIER *et al.*, 2001; ZHONG *et al.*, 2002; OBERMAIER *et al.*, 2003; CHIAPPA *et al.*, 2003; NOVÁK *et al.*, 2004; LI *et al.*, 2005; HELMY *et al.*, 2008; YAN *et al.*, 2008) que é o objetivo deste trabalho.

Esses modelos podem ser classificados como discretos, contínuos e semicontínuos (RABINER, 1989; YNOGUTI, 1999), sendo apresentado nesta sessão apenas o HMM discreto, que foi utilizado no desenvolvimento do trabalho. Segundo RABINER (1989), os elementos que caracterizam o HMM são (Fig. 3.1):

- $S = \{S_1, S_2, \dots, S_N\}$ é o conjunto de estados, sendo N o número de estados do modelo. Os estados individuais são, na Fig. 3.1, $S = \{i, j, k\}$.
- $V = \{v_1, v_2, \dots, v_O\}$ é o conjunto de observações, sendo O o número de observações distintas. As observações individuais são denotadas como $v_i (1 \leq i \leq O)$. O índice t representa o tempo. No HMM discreto v_t é o valor

quantizado, ou seja, $\dim(v_t) = \{1, 1\}$ e $v_t \in N = \{1, 2, 3, \dots, TC\}$, onde TC é o tamanho do *codebook*.

- $A^t = \{a_{ij}\}^t$ é a matriz de transição dos estados e a_{ij} é a probabilidade de transição do estado i para o estado j . A Eq. 11 significa que a seqüência no tempo $t+1$ estava no estado j e no tempo t está no estado i , e a probabilidade dessa transição foi de a_{ij} . Na Fig. 3.1, a matriz A é definida por $A = [a_{ii} \ a_{ij} \ a_{ik}; 0 \ a_{jj} \ a_{jk}; a_{ki} \ 0 \ a_{kk}]$.

$$a_{ij} = P[q_{t+1}=j | q_t=i] \quad \text{Eq. 11}$$

E a_{ij} deve obedecer às seguintes regras:

$$a_{ij} \geq 0 \quad 1 \leq i, j \leq N \quad \text{Eq. 12}$$

$$\sum_{j=1}^N a_{ij} = 1, \quad 1 \leq i \leq N \quad \text{Eq. 13}$$

- B^t é a matriz de probabilidade das observações. Para o HMM discreto o número de observações é finito e a matriz de probabilidade das mesmas é dada por $B^t = \{b_j(k)\}$, onde $b_j(k)$ (Eq. 14) define a probabilidade de emissão de cada observação k no estado j . Na Fig. 3.1, as probabilidades de emissões dos símbolos de cada estado são dadas por $b_i[], b_j[]$ e $b_k[]$, para os estados i, j e k , respectivamente.

$$b_j(k) = P[v = k | q_t = S_j] \quad \text{Eq. 14}$$

E $b_j(k)$ deve obedecer às seguintes regras:

$$b_j(k) \geq 0, \quad 1 \leq j \leq N \quad e \quad 1 \leq k \leq M \quad \text{Eq. 15}$$

$$\sum_{k=1}^M b_j(k) = 1 \quad \text{Eq. 16}$$

- $\pi = \{ \pi_i \}$, onde $\sum_i \pi_i = 1$, é a probabilidade *à priori* dos HMMs.

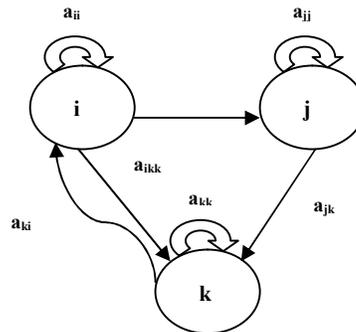


Figura 3.1 – Modelo Oculto de Markov com 3 estados (i, j, k). Modificado de YNOGUTI, 1999.

O modelo HMM pode ser escrito na sua forma compacta:

$$\lambda = (A, B, \pi) \quad \text{Eq. 17}$$

Solução de problemas com HMM

Existem três problemas básicos que o HMM é capaz de resolver (RABINER, 1989; KÜNSCH *et al.*, 1995; YNOGUTI, 1999):

1. Dado um modelo $\lambda = (A, B, \pi)$ e uma seqüência de observações $V = \{v_1, v_2, \dots, v_O\}$ é possível obter a probabilidade de ocorrência dessas observações, ou seja, $P(V|\lambda)$.
2. Dado uma seqüência de observações $V = \{v_1, v_2, \dots, v_O\}$ e um modelo $\lambda = (A, B, \pi)$ é possível obter a seqüência de estados que melhor representa essas observações.
3. Dado uma seqüência de observações $V = \{v_1, v_2, \dots, v_O\}$ é possível ajustar o parâmetro dos modelos $\lambda = (A, B, \pi)$, que maximiza $P(V|\lambda)$.

Solução problema 1:

Dado um modelo $\lambda = (A, B, \pi)$ com N estados e uma seqüência de observação $V = \{v_1, v_2, \dots, v_O\}$ de duração O , a probabilidade de $P(V|\lambda)$ pode ser calculada pelo procedimento *forward-backward*.

A variável *forward* ($\alpha_t(i)$) é a probabilidade da seqüência de observações v_1, v_2, \dots, v_O até o tempo O , ou seja:

$$\alpha_t(i) = P(v_1, v_2, \dots, v_O, q_t | \lambda) \quad \text{Eq. 18}$$

E $\alpha_t(i)$ pode ser resolvido pelo algoritmo *forward* (RABINER, 1989), descrito pelas seguintes etapas:

a. Inicialização:

$$\alpha_1(i) = \pi_i b_i(v_1), \quad 1 \leq i \leq N \quad \text{Eq. 19}$$

b. Indução

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] \cdot b_j(v_{t+1}) \quad \text{Eq. 20}$$

onde $1 \leq t \leq O$, $1 \leq j \leq N$, j é o estado e t é o tempo (número de observações no HMM discreto).

c. Terminação

$$P(V | \lambda) = \sum_{i=1}^N \alpha_O(i) \quad \text{Eq. 21}$$

A variável *backward* ($\beta_t(i)$) é a probabilidade da seqüência de observações v_1, v_2, \dots, v_O , dessa forma:

$$\beta_t(i) = P(v_{t+1}, v_{t+2}, \dots, v_O | \lambda) \quad \text{Eq. 22}$$

E $\beta_t(i)$ pode ser resolvido pelo algoritmo *backward* (RABINER, 1989), descrito pelas seguintes etapas:

a. Inicialização:

$$\beta_t(i) = 1 \quad 1 \leq i \leq N \quad \text{Eq. 23}$$

b. Indução:

$$\beta_t(j) = \sum_{i=1}^N a_{ij} \cdot b_j(v_{t+1}) \beta_{t+1}(j) \quad \text{Eq. 24}$$

onde $t = O-1, O-2, \dots, 1$, $1 \leq i \leq N$, j é o estado e t é o tempo (número de observações no HMM discreto).

c. Terminação:

$$P(V | \lambda) = \sum_{i=1}^N \pi_i b_i(v_1) \beta_1(i) \quad \text{Eq. 25}$$

Solução problema 2:

O problema 2 procura obter a seqüência de estados que melhor representa as observações de um determinado modelo. Uma das alternativas para a solução deste problema é o algoritmo de Viterbi, descrito abaixo.

Algoritmo de Viterbi

Para se obter uma seqüência de estados $S = \{S_1, S_2, \dots, S_N\}$ dada uma seqüência de observações $V = \{v_1, v_2, \dots, v_O\}$, tem-se uma quantidade:

$$\delta_t(i) = \max_{S_1, S_2, \dots, S_{t-1}} P(S_1 S_2 \dots S_t = i, v_1, v_2, \dots, v_O | \lambda) \quad \text{Eq. 26}$$

onde $\delta_t(i)$ é o resultado que apresenta a maior probabilidade ao longo de um simples caminho no tempo t . Para esse cálculo, considera-se as t primeiras observações, terminando no estado i . Por indução tem-se:

$$\delta_{t+1}(i) = \max_i \delta_t(i) \cdot b_j(v_{t+1}) \quad \text{Eq. 27}$$

Para recuperar a seqüência de estados mantêm-se os argumentos que maximizam a Eq.27, para cada t e j . O procedimento para encontrar essa seqüência é possível através do vetor $\psi_t(j)$ e consiste das seguintes etapas:

1. Inicialização

$$\delta_1(i) = \pi_i \cdot b_i(v_1) \quad 1 \leq i \leq N \quad \text{Eq. 28}$$

$$\psi_1(i) = 0 \quad \text{Eq. 29}$$

2. Recursão

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(v_t), \quad 2 \leq t \leq O \text{ e } 1 \leq i \leq N \quad \text{Eq. 30}$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad 2 \leq t \leq O \text{ e } 1 \leq i \leq N \quad \text{Eq. 31}$$

3. Terminação

$$P^* = \max_{1 \leq i \leq N} [\delta_O(i)] \quad \text{Eq. 32}$$

$$S_O^* = \arg \max_{1 \leq i \leq N} [\delta_O(i)] \quad \text{Eq. 33}$$

4. Caminho (seqüência de estados) *backtracking*:

$$S_t^* = \psi_{t+1} S_{t+1}^*, \quad t = O-1, O-2, \dots, 1 \quad \text{Eq. 34}$$

Segundo RABINER (1989), o algoritmo de Viterbi tem processo semelhante ao processo de *forward*, exceto na parte de *backtracking*.

Solução problema 3:

O terceiro e mais complexo dos problemas existentes é determinar um método para ajustar os parâmetros do modelo $\lambda = (A, B, \pi)$ que maximize $P(V|\lambda)$. Segundo RABINER (1989) não existe um método analítico para a solução deste problema, sendo comum a

utilização do procedimento iterativo de *Baum-Welch* (também conhecido como método EM, *expectation-maximization*), ou técnicas de gradiente.

Algoritmo de Baum-Welch

Esse método é supervisionado, fazendo-se necessário um conjunto de treinamento. O processo consiste em ajustar os parâmetros de λ , maximizando $P(V|\lambda)$ para um máximo local. As etapas desse algoritmo podem ser descritas por:

1. Inicialização: Inicializa um conjunto inicial de parâmetros $\lambda = (A, B, \pi)$. E o número de iteração (it) = 1, máximo de iteração (M_{it}) = L.
2. Estimação: Calcule \bar{A} e \bar{B} de acordo com as fórmulas:

- Probabilidade de Transição \bar{a}_{ij} :

$$\bar{a}_{ij} = \frac{NE_{ij}}{NE_i} \quad \text{Eq. 35}$$

onde NE_{ij} é o número esperado de transição do estado i para o estado j e NE_i é o número esperado de transição do estado i . Dessa forma:

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{M-1} \alpha_t(i) a_{ij} b_j(v_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^{M-1} \alpha_t(i) \beta_t(i)} \quad \text{Eq. 36}$$

- Probabilidade de emissão das observações:

$$\bar{b}_i(k) = \frac{NO_{ki}}{NO_i} \quad \text{Eq. 37}$$

onde NO_{ki} é o número esperado de ocorrer a observação k no estado i e NO_i é o número esperado de transição do estado i . Dessa forma:

$$\bar{b}_i(k) = \frac{\sum_{t=1}^M \alpha_t(i) \beta_t(i)}{\sum_{t=1}^M \alpha_t(i) \beta_t(i)} \quad \text{Eq. 38}$$

$$P(V | \lambda) = \sum_{i=1}^N \alpha_t(i) \cdot \beta_t(i) \quad \text{Eq. 39}$$

3.2.2. Redes Neurais Artificiais

Redes Neurais Artificiais (RNA's) consistem em ferramentas com ampla aplicabilidade para análise de sinais biológicos (PAPKI, *et al.*, 1998), principalmente na classificação e processamento do EEG (LIU *et al.*, 2002; ROBERT *et al.*, 2002) e identificação do PRE (LEISTRITZ *et al.*, 1999; HOFFMAN *et al.*, 2001). Além disso, tem sido aplicado na etapa de classificação das ICM's (HIRAIWA *et al.*, 1989; ANDERSON *et al.*, 1996; ANDERSON *et al.*, 1998; GARCIA *et al.*, 2002; GARRETT *et al.*, 2003; CHIAPPA *et al.*, 2004; TAVAKOLIAN *et al.*, 2004; BARRETO *et al.*, 2004; PALANIAPPAN *et al.*, 2005; TAVAKOLIAN *et al.*, 2006; AHMADI *et al.*, 2009).

De acordo com BRAGA *et al.* (2000), as RNA's são sistemas paralelos, constituídos por nodos, que são unidades simples de processamento. Esses calculam determinadas funções matemáticas que, em sua maioria são não-lineares e têm sua ativação promovida por um valor limiar ao qual o mesmo está associado.

Entre esses nodos existem conexões também associadas a um número o qual chamamos de peso (ZEIDENBERG, 1990). Essa ligação presente nas redes é uma das grandes linhas de pesquisa da Inteligência Artificial (IA) que objetiva modelar e investigar comportamentos inteligentes baseando-se no funcionamento do cérebro humano (BITTENCOURT, 2001).

Dessa forma, a estrutura neural extrai seu poder computacional através de sua estrutura paralela distribuída e também da habilidade que a mesma possui de aprender e generalizar. A generalização, por sua vez, se refere ao fato de a rede produzir saídas adequadas para entradas diferentes das apresentadas durante o treinamento (HAYKIN, 2001).

As características, segundo BITTENCOURT (2001), que tornam interessante a metodologia das RNA's, do ponto de vista da solução de problemas são as seguintes:

- Capacidade de aprender através de exemplos e de generalizar este aprendizado de forma que seja capaz de reproduzir um resultado a uma entrada diferente da apresentada.

- Bom desempenho em situações onde não há conhecimento necessário sobre como encontrar uma solução.
- Não necessita de conhecimento sobre os eventos matemáticos dos domínios de aplicação.
- Elevada imunidade ao ruído, ou seja, a rede admite a presença de informações ausentes ou falsas.

No presente trabalho, utilizamos a rede com camadas intermediárias (Fig. 3.2) que permite a solução de problemas não linearmente separáveis. Esta é nomeada na literatura como *Multi Layer Perceptron* (MLP).

Essas redes apresentam um poder computacional elevado quando comparado com o apresentado pelas redes sem camadas intermediárias. Nela as funções precisam ser diferenciáveis para que o gradiente possa ser calculado, direcionando o ajuste de pesos (BRAGA *et al.*, 2000).

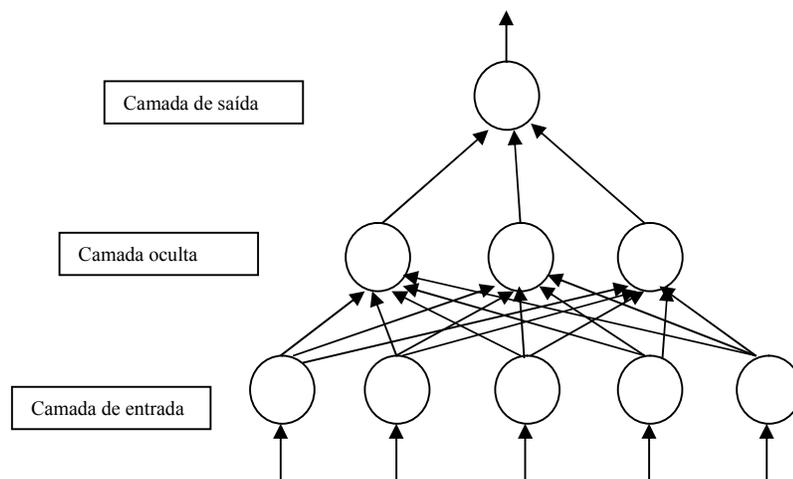


Figura 3.2 – Rede neural MLP com uma camada oculta.

O algoritmo utilizado foi o de retropropagação ou *backpropagation* que, segundo Haykin (2001), possui a seguinte seqüência:

1. *Inicialização*: retira os pesos sinápticos e limiares de uma distribuição uniforme (média zero). A variância é escolhida de modo que o desvio padrão

dos campos locais induzidos dos neurônios se encontre na transição entre as partes linear e saturada da função de ativação sigmóide.

2. *Apresentação dos exemplos de treinamento*: apresentar à rede os exemplos para o treinamento, de acordo com os processos definidos.

3. *Computação para frente (Propagação)*: sendo a entrada e a saída, o campo local induzido $v_j^{(l)}(n)$ para o neurônio j na camada l é:

$$v_j^{(l)}(n) = \sum_{i=0}^m \omega_{ji}^{(l)}(n) y_i^{(l-1)}(n) \quad \text{Eq. 40}$$

onde $y_i^{(l-1)}(n)$ é o sinal de saída do neurônio i na camada anterior $l-1$, na iteração n , e $\omega_{ji}^{(l)}(n)$ é o peso sináptico do neurônio j da camada l , que é alimentado pelo neurônio i da camada $l-1$.

4. *Computação para trás (Retropropagação)*: cálculo dos gradientes locais (δ) da rede definidos por

para o neurônio j da camada L :

$$\delta_j^{(l)}(n) = \{e_j^L(n) \phi_j'\} \{v_j^{(L)}(n)\} \quad \text{Eq. 41}$$

e, para o neurônio j da camada oculta l :

$$\delta_j^{(l)} = \phi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) \omega_{kj}^{(l+1)}(n) \quad \text{Eq. 42}$$

onde o apóstrofo em $\phi_j'(\cdot)$ representa a diferenciação em relação ao argumento.

O ajuste dos pesos pode ser generalizado da seguinte forma:

$$\omega_{ji}^{(l)}(n+1) = \omega_{ji}^{(l)}(n) + \alpha [\omega_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad \text{Eq. 43}$$

onde η é o parâmetro da taxa de aprendizagem e α é a constante de momento.

5. *Iteração*: iterar as computações para frente e para trás até que o critério de parada seja satisfeito.

A função de ativação utilizada em todas as estruturas foi a logsigmóide (Eq. 44) que retorna valores positivos compreendidos entre zero e um. Já o algoritmo de treinamento foi o *Trainidx*, que usa o método *backpropagation* e tenta manter o aprendizado o mais rápido possível, porém com estabilidade. Isso é feito com a variação tanto do gradiente descendente quanto da taxa de aprendizado.

$$f(n) = \frac{1}{1 + e^{-n}} \quad \text{Eq. 44}$$

CAPÍTULO 4: MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais e métodos utilizados no desenvolvimento da dissertação. Primeiramente, são descritos os procedimentos para o registro do EEG, detalhando os testes realizados. Posteriormente são relatadas as etapas de remoção de artefatos e extração de características via MSC. O tópico subsequente apresenta uma análise com sinais simulados seguida da modelagem e classificação feitas com HMM e RNA.

4.1. Sinais EEG: protocolo de aquisição

O EEG de três sujeitos, saudáveis, que não fazem uso de qualquer medicamento que possa interferir nos sinais, foi coletado no laboratório do NEPEB (Núcleo de Estudos e Pesquisas em Engenharia Biomédica da UFMG) de acordo com protocolo aprovado pelo comitê de ética local. A coleta foi realizada com o amplificador de sinais biológicos (Fig. 4.1), com filtro passa-alta e passa-baixa de 0,1 Hz e 100 Hz, respectivamente, filtro notch de 60 Hz e frequência de amostragem de 600 Hz.

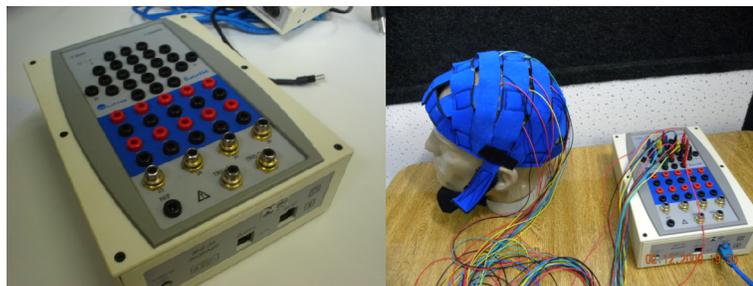


Figura 4.1 – Amplificador de sinais biológicos, BrainNet BNT – 36 da Lynux Tecnologia Eletrônica Ltda.

Durante a coleta, os indivíduos permaneceram sentados confortavelmente em uma poltrona e isolados em uma cabine acústica, onde a iluminação foi ajustada para que não interferisse nos sinais. As coletas foram realizadas em três etapas: a primeira utilizando o sistema 10-20 (Fig. 2.9) e as duas subsequentes utilizando 17 eletrodos posicionados conforme o sistema 10-10 (marcação em azul da Fig. 4.2). Em todos os processos de registro os eletrodos foram referenciados aos eletrodos auriculares (A1 e A2).

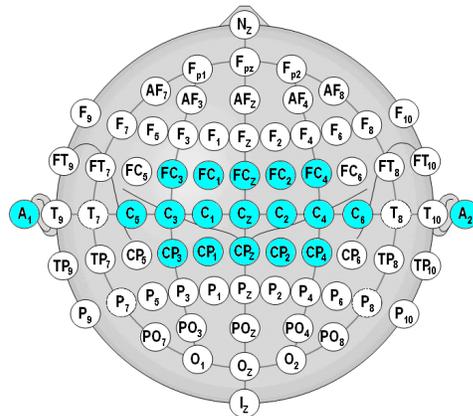


Figura 4.2 – Sistema 10-10 utilizado para a aquisição dos sinais da segunda e terceira etapas de EEG realizadas (Modificado de BRAGA, 2007).



Figura 4.3 – Acelerômetro utilizado para registrar o movimento do dedo indicador da mão esquerda.

Para registro do movimento do dedo simultaneamente ao EEG foi utilizado um acelerômetro MEMS (micro electronics mechanical system) da Analog Devices, ADXL 213 com faixa de medição típica de ± 1.2 g, afixado no dedo indicador da mão esquerda (Fig. 4.3).

Durante o registro do EEG, dois LEDs (*Light Emitter Diodes*) foram utilizados como comando para os eventos relacionados ao movimento e a imaginação (Fig. 4.4). Ambos os LEDs foram fixados em um painel retangular preto (30x20 cm) situado no ângulo de visão do sujeito, a 80 cm de seus olhos. O comando para a realização da tarefa foi feito da seguinte forma: o LED vermelho acendia para indicar atenção; três segundos depois o LED amarelo foi aceso para indicar preparação; um segundo após o LED amarelo estar aceso, os dois foram desligados e o sujeito foi orientado a fazer a tarefa (movimento ou imaginação). No EEG espontâneo, no desligamento dos LEDs, os sujeitos foram orientados a permanecerem quietos e não realizar nenhuma tarefa.

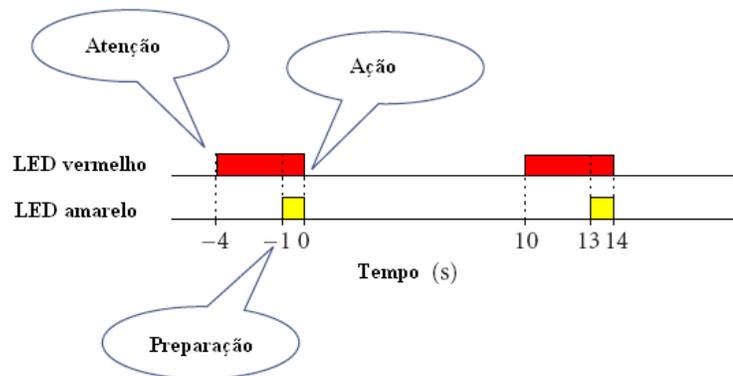


Figura 4.4 – Protocolo do Evento. O LED vermelho indica atenção e o LED amarelo indica a preparação para o movimento ou imaginação de movimento. Os sujeitos foram instruídos a fazer as tarefas após o desligamento dos LEDs.

As coletas dos sinais EEG, na primeira etapa, foram realizadas para a atividade espontânea com 15 minutos de duração, durante o movimento e durante a imaginação de movimento com duração de 20 minutos. Na segunda e terceira etapas foi de 15 minutos tanto para o EEG espontâneo como durante a tarefa cognitiva.

Durante a coleta do EEG espontâneo, o sujeito era orientado a não fazer nenhum tipo de movimento (real ou imaginário). Esta coleta foi realizada para que a resposta obtida do EEG espontâneo pudesse ser comparada com os PRE's do movimento real (MR) e da imaginação de movimento (IM).

Durante o movimento ou imaginação do movimento o sujeito era orientado a executar a tarefa após o desligamento dos LEDs. O tempo entre as tarefas foi de 14 segundos. A coleta se iniciava com 60 segundos de registro de EEG espontâneo que servia como referência para a rejeição de artefatos.

4.2. Pré-Processamento dos Sinais

Para a análise do PRE foram utilizados apenas os eletrodos das regiões central (C3, Cz e C4), parietal (P3, Pz e P4) e frontal (F3, Fz e F4). Esta disposição foi utilizada por estar abrangendo as áreas para obtenção do PRE do MR e IM do dedo (WOLPAW *et al.*, 2000; PFURTSCHELLER *et al.*, 2003; PFURTSCHELLER *et al.*, 2006; SANTOS FILHO *et al.*, 2009). Todas as etapas de pré-processamento foram realizadas *off-line* utilizando o software MatLab (Mathworks).

Inicialmente, os sinais EEG foram divididos em trechos, sincronizados com os eventos (movimento, imaginação de movimento e espontâneo com a observação dos LEDs) por meio de um sinal de sincronismo enviado no apagamento dos LEDs ($t=0$ s, Fig. 4.4). Para a rejeição de artefatos foi utilizado um algoritmo descrito em TIERRA-CRIOLLO (2001). Este algoritmo consiste em, primeiramente, determinar o desvio padrão (σ) do EEG de fundo em um trecho livre de artefatos com duração de 15 a 20 segundos. A partir desse cálculo é estabelecido um limiar definido por três vezes o desvio padrão (3σ). Os trechos que apresentarem 5 % de amostras consecutivas ou 10 % das suas amostras com valor superior ao limiar calculado serão rejeitados. Além disso, rejeitaram-se também os trechos de imaginação em que o sujeito realizou o movimento detectado pelo acelerômetro.

4.2.1. Estimação do PRE através da Média Coerente

Após a rejeição dos artefatos, avaliou-se o PRE dos indivíduos utilizando a técnica de média coerente apresentada no capítulo 3. Para cada um dos eventos analisados foi calculado o PRE de todos os sujeitos e eletrodos utilizados, com o objetivo de identificar se havia ou não resposta. Na Fig. 4.5, tem-se o PRE do eletrodo Cz do sujeito #1, para as sessões de movimento, imaginação de movimento e EEG espontâneo, utilizando 12 trechos ($M = 12$). Através da ilustração percebe-se a presença do PRE nos dois gráficos superiores (Movimento e Imaginação) e também a semelhança na morfologia desses potenciais (PFURTSCHELLER *et al.*, 1997; SANTOS FILHO *et al.*, 2009). Por outro lado, o PRE do EEG espontâneo apresenta pequenas variações em torno de $0 \mu\text{V}$, não caracterizando componentes significativas. Comportamento similar foi observado nos demais indivíduos.

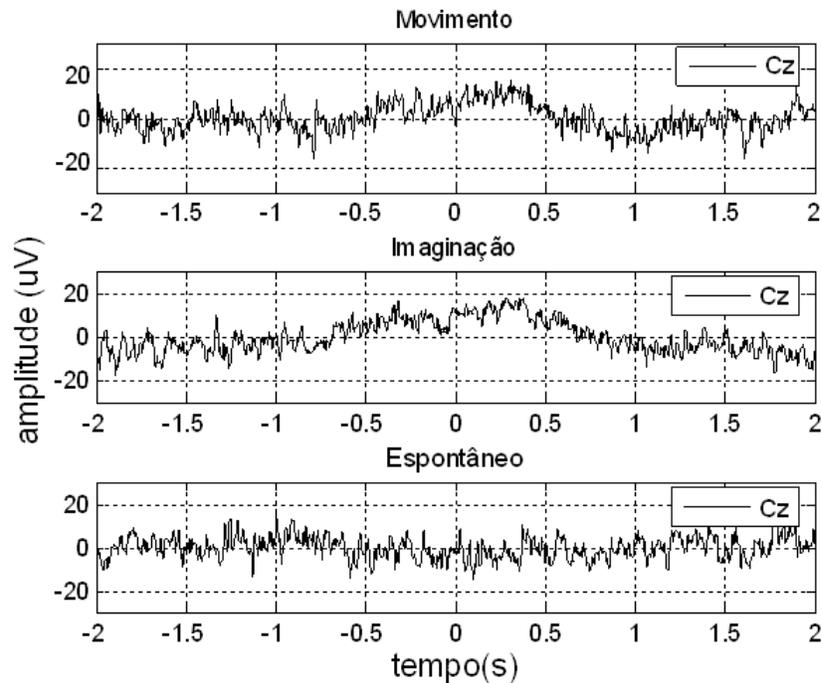


Figura 4.5 – PRE do eletrodo Cz do sujeito #1 nas sessões de movimento, imaginação e EEG espontâneo, utilizando $M=12$.

4.2.2. Divisão dos trechos de EEG em segmentos

Após a rejeição de trechos com artefatos, cada trecho restante foi dividido em seis segmentos que representavam diferentes características do EEG, como indicado na tabela 2.

O primeiro segmento é caracterizado pelo EEG espontâneo, pois os LEDs estão apagados e o indivíduo está completamente relaxado. Esse segmento tem duração de três segundos sendo que, após esse intervalo, tem-se o acendimento do LED vermelho e o início do segundo segmento. O EEG referente à visualização do LED vermelho tem duração de dois segundos, sendo interrompido pelo início do EEG com a visualização do LED amarelo (terceiro segmento). O intervalo referente ao EEG do LED amarelo, por sua vez, tem duração de 1,3 segundos, após o qual se inicia o quarto segmento relativo ao evento (EEG espontâneo, movimento ou imaginação de movimento). Este segmento possui duração de 2,7 segundos, sendo que, 0,7 segundos após seu início, os LEDs são desligados ($t=0$ s, Fig. 4.4). Os segmentos seguintes (cinco e seis) são caracterizados, novamente, pelo EEG espontâneo e têm duração de 2,5 segundos cada. Dessa forma, a soma dos segmentos tem duração de 14 segundos que é o intervalo de um trecho do EEG.

Tabela 2 – Cada trecho foi dividido em seis segmentos com intervalos de duração distintos. * Os eventos podem ser: EEG espontâneo, EEG do movimento do dedo indicador da mão esquerda e EEG da imaginação do mesmo movimento.

Segmentos	Intervalo	Evento
1	-7,0 a -4,0 s	EEG Espontâneo
2	-4,0 a -2,0 s	EEG durante a visualização do LED vermelho
3	-2,0 a -0,7 s	EEG durante a visualização do LED amarelo
4	- 0,7 a 2,0 s	EEG durante o evento*
5	2,0 a 4,5 s	EEG Espontâneo
6	4,5 a 7,0 s	EEG Espontâneo

4.3. Extração de características via MSC

Após a divisão dos trechos em segmentos, foi feito o levantamento de características por meio da MSC para aplicação nos modelos HMM e na RNA. Para os cálculos da coerência foram utilizados $M=12$. Quando o número de trechos fosse superior a esse valor, por exemplo, $M=45$, adotava-se o seguinte critério:

1. Como 45 não é múltiplo de 12, eliminava-se os últimos trechos até atingir-se o múltiplo mais próximo: 36.
2. A coerência de cada conjunto de 12 trechos foi calculada e tomada como um conjunto de observações. Com $M=36$, teve-se três conjuntos de observações, consecutivos.

A MSC foi aplicada aos sinais EEG dos eletrodos C3, Cz, C4, F3, Fz, F4, P3, Pz e P4, para a coleta utilizando o sistema 10-20. Nas coletas utilizando o sistema 10-10 a MSC foi calculada para os eletrodos FC3, FC1, FCz, FC2, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2 e CP4. Em todos os casos a técnica foi avaliada para as bandas delta (0,1-2 Hz), alfa (8-13 Hz) e beta (14-30 Hz) e a resolução espectral foi de 0,1 Hz. Para cada segmento foi calculada a coerência e verificada a banda que possuísse o maior valor, esta seria a observação do HMM e a entrada da RNA para o segmento analisado.

4.4. Sinais Simulados

Para o entendimento dos modelos de Markov foi feito inicialmente algumas análises com sinais simulados. O processo consistiu em somar a um ruído branco gaussiano os segmentos referentes ao EEG da IM e do MR. Os intervalos de cada

segmento definido na simulação são idênticos aos intervalos apresentados na tabela 2, porém, os mesmos não contêm o EEG relacionado à visualização dos LEDs vermelho e amarelo. As informações referentes aos eventos retiradas dos eletrodos Cz, C3 e C4 foram utilizadas para treinamento e validação. Sendo as combinações distintas entre os indivíduos.

Após a geração dos sinais simulados, foram extraídas as observações referentes às bandas alfa, beta e delta. Posteriormente foi feita a modelagem com HMM por meio das observações obtidas. O resultado foi tomado como satisfatório quando a seqüência de estados obtida na validação era a esperada, sendo a taxa de acerto calculada através da Eq. 45 (TA é a taxa de acerto; NA é o número de estados coincidentes com o estado esperado; NO é o número de observações). Cada indivíduo obteve uma combinação distinta de eletrodos para treinamento e validação e um índice de acerto variável.

$$TA = \frac{NA}{NO} \quad \text{Eq. 45}$$

4.5. Processamento

Após a extração de características foi feito treinamento e validação dos sinais através das técnicas descritas no capítulo 3.

4.5.1. Modelagem e validação com HMM

A análise com modelos de Markov foi feita em duas etapas (Fig. 4.7 e 4.8):

1. Treinamento utilizando 80 % do conjunto formado pelos sinais da primeira etapa e segunda etapa de coletas de EEG;
2. Classificação utilizando a segunda (20 % do conjunto anterior) e a terceira etapas de EEG com os modelos encontrados no treinamento.

Treinamento

Os seis segmentos definidos nas sessões anteriores foram utilizados para extrair as observações dos estados do HMM (Fig. 4.6), conforme a tabela 2. As observações para cada estado (banda com maior coerência) foram obtidas com $M=12$ trechos. Por exemplo, considerando o eletrodo Cz do sujeito # 1 com $M=45$ tem-se três seqüências de observações para os seis estados: {alfa, beta, beta, delta, alfa, alfa}; {alfa, alfa, beta, delta,

alfa, beta}; {alfa, alfa, beta, delta, alfa, alfa}. Assim, as observações do modelo são $V=\{alfa, beta, beta, delta, alfa, alfa, alfa, alfa, beta, delta, alfa, beta, alfa, alfa, beta, delta, alfa, alfa\}$.

Para cada sujeito e cada sessão (EEG espontâneo, EEG do MR e da IM) foram utilizados diferentes eletrodos. O modelo julgado como adequado no treinamento foi o que, durante a validação, apresentou maior índice de acerto. No final, cada indivíduo teve um modelo específico para EEG espontâneo, EEG da IM e EEG do MR. O treinamento foi realizado com o algoritmo de *Baum-Welch* descrito no capítulo 3. O índice de acerto foi calculado verificando o número de eletrodos (etapas dois e três) classificados corretamente.

As matrizes iniciais da probabilidade de transição dos estados, para as três sessões, foram semelhantes (tabela 3). Os valores diferentes de zero e um foram adotados para que houvesse convergência dos modelos, sendo outros valores testados anteriormente. Por outro lado, analisando-se as matrizes de emissão das observações (tabela 4), percebe-se que as probabilidades do EEG espontâneo são distintas do EEG da IM e do MR, pois se espera uma maior resposta referente à banda delta no estado quatro para a IM e o MR (SANTOS FILHO *et al.*, 2009). O número de estado do HMM foi mantido fixo em 6 durante todas as análises.

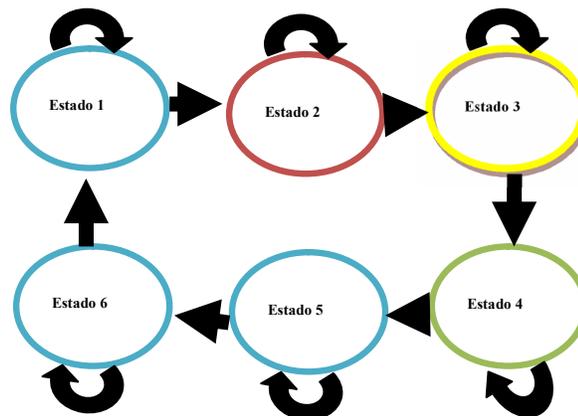


Figura 4.6 – Modelo Oculto de Markov com seis estados. As setas indicam a transição de um estado para o outro ou para si mesmo e as cores representam os estados que contêm características de cada segmento: azul – EEG espontâneo; vermelho – EEG da visualização do LED vermelho; amarelo – EEG da visualização do LED amarelo; verde – EEG durante a realização do evento.

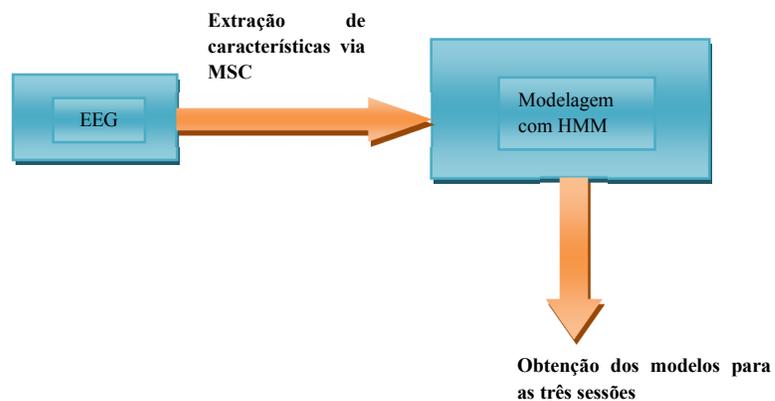


Figura 4.7 – Processo de treinamento do HMM.

Tabela 3 – Matrizes iniciais das probabilidades de transição entre os estados para as sessões de IM, MR e EEG espontâneo.

Sessões	Origem: Estado	Destino: Estado 1	Destino: Estado 2	Destino: Estado 3	Destino: Estado 4	Destino: Estado 5	Destino: Estado 6
IM	1	0,005	0,995	0	0	0	0
	2	0	0	1	0	0	0
	3	0	0	0	1	0	0
	4	0	0	0	0	1	0
	5	0	0	0	0	0	1
	6	1	0	0	0	0	0
MR	1	0,005	0,995	0	0	0	0
	2	0	0	1	0	0	0
	3	0	0	0	1	0	0
	4	0	0	0	0	1	0
	5	0	0	0	0	0	1
	6	1	0	0	0	0	0
Espontâneo	1	0,005	0,995	0	0	0	0
	2	0	0	1	0	0	0
	3	0	0	0	1	0	0
	4	0	0	0	0	1	0
	5	0	0	0	0	0	1
	6	1	0	0	0	0	0

Tabela 4 – Matrizes iniciais das probabilidades de emissão das observações para as sessões de IM, MR e EEG espontâneo.

Sessões	Observação	delta	alfa	beta
IM	Estado 1	0,34	0,33	0,33
	Estado 2	0,34	0,33	0,33
	Estado 3	0,34	0,33	0,33
	Estado 4	1,00	0,00	0,00
	Estado 5	0,34	0,33	0,33
	Estado 6	0,34	0,33	0,33
MR	Estado 1	0,34	0,33	0,33
	Estado 2	0,34	0,33	0,33
	Estado 3	0,34	0,33	0,33
	Estado 4	1,00	0,00	0,00
	Estado 5	0,34	0,33	0,33
	Estado 6	0,34	0,33	0,33
Espontâneo	Estado 1	0,34	0,33	0,33
	Estado 2	0,34	0,33	0,33
	Estado 3	0,34	0,33	0,33
	Estado 4	0,34	0,33	0,33
	Estado 5	0,34	0,33	0,33
	Estado 6	0,34	0,33	0,33

Validação e classificação

A validação foi realizada utilizando as coletas com o sistema 10-10 com 12 trechos e o número máximo de trechos apresentados em cada eletrodo.

A mesma foi feita através do algoritmo de *Baum-Welch* descrito no capítulo 3. Esta etapa do processo foi feita utilizando os sinais EEG coletados com a configuração da Fig. 4.2. As observações dos novos sinais EEG foram obtidas e passadas como entrada para cada modelo de cada sujeito. Dessa forma, as observações de cada eletrodo foram analisadas pelos modelos e através de $P(V/\lambda)$, decidia-se qual era o evento apresentado.

A medida de probabilidade ($P(V/\lambda)$) obtida pelos modelos foi a log-probabilidade que varia entre 0 e $-\inf$. Essa medida relata que, quanto maior o valor da probabilidade, mais próximo de zero será seu logaritmo ao passo que, quanto menor a probabilidade, o logaritmo se aproxima de $-\inf$.

Cada um dos sujeitos analisados possuía um sistema de classificação que foi composto pelos três modelos: λ_{IMi} , λ_{MRi} , λ_{ESPi} ($i=1,2$ e 3 , representando o sujeito). Dado um vetor de observações foi calculada a probabilidade ($\log(P(V/\lambda))$) de cada modelo emitir a seqüência apresentada. Essas probabilidades foram passadas para a função *Max* que

verificava a maior probabilidade ($\log(P(V/\lambda))$) e classificava a seqüência como IM, MR ou Espontâneo. Na Fig. 4.8 tem-se o diagrama esquemático do processo de classificação descrito acima.

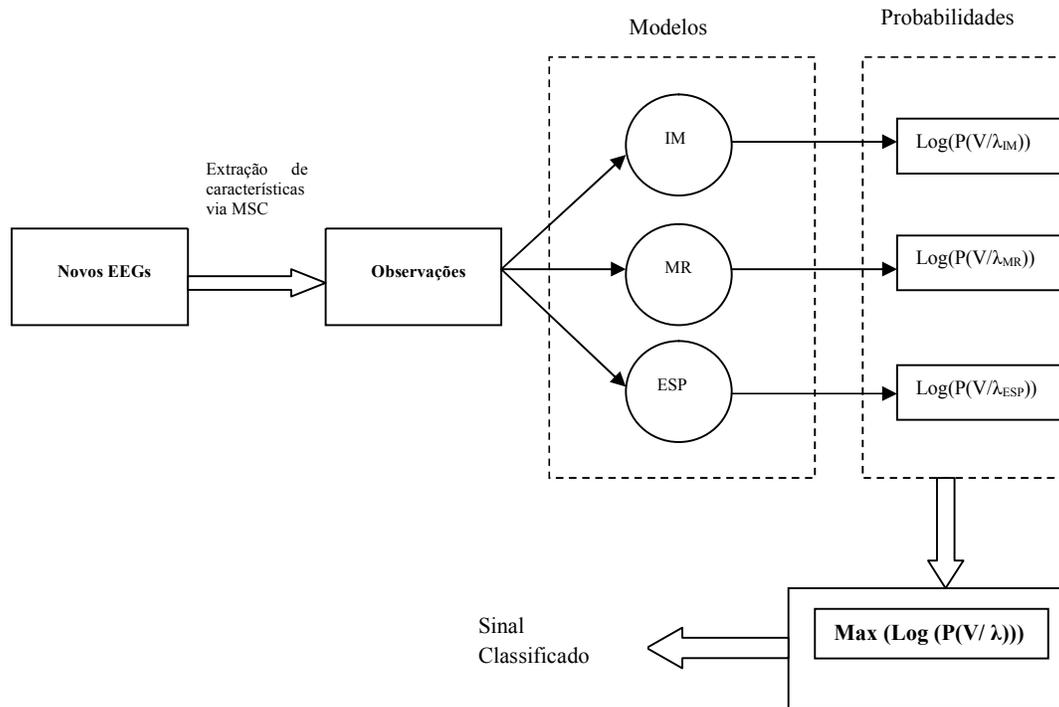


Figura 4.8 – Sistema de classificação para os sinais EEG a partir dos modelos HMM construídos para cada sujeito.

4.5.2. Treinamento e validação com RNA

A análise com RNA foi feita através de uma etapa de treinamento (Fig. 4.9) e outra de validação e classificação (Fig. 4.10) que estão descritas nos tópicos abaixo.

Treinamento

Da mesma forma que no HMM os seis segmentos definidos nas sessões anteriores foram utilizados para extrair as entradas para as redes neurais. Depois de extraídas as características do EEG, por meio da MSC, obteve-se o conjunto de entradas em cada segmento.

Para montar o conjunto de treinamento empregaram-se os eletrodos da primeira etapa (sistema 10-20) e da segunda etapa (sistema 10-10). O número de observações utilizadas foi de 80% do conjunto total de observações. Os 20% restantes foram utilizados

para a validação. No treinamento foi utilizado o algoritmo *traingdx* e a função de ativação *log-sigmoide* descritos no capítulo 3. O número de camadas ocultas foi variado de 1 a 3 e o número de neurônios em cada camada foi variado de 1 a 20. Como saída da rede, foi adotado o seguinte critério:

- EEG espontâneo – saída representada pelo valor 0;
- EEG de movimento – saída representada pelo valor 1/2;
- EEG de imaginação – saída representada pelo valor 1.

O processo de treinamento foi realizado variando o algoritmo de treinamento, as funções de ativação, o número de camadas ocultas e o número de neurônios em cada camada, até que o menor erro fosse obtido no conjunto de validação. Esse procedimento foi realizado para evitar o *overfitting*.

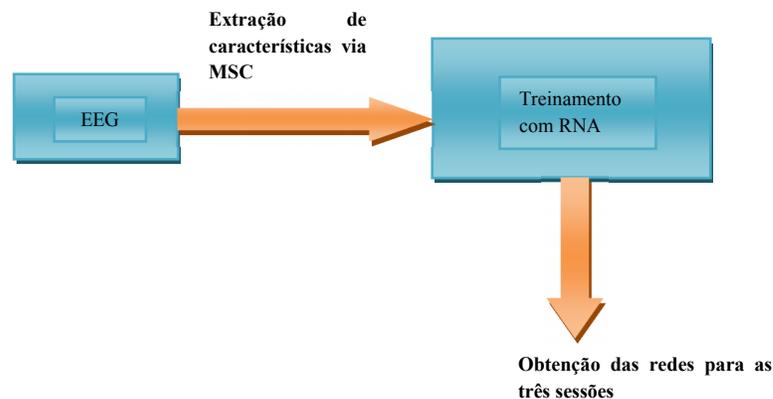


Figura 4.9 – Processo de treinamento da RNA.

Validação e classificação

A validação foi realizada juntamente com o processo de treinamento como foi descrito no tópico anterior. As informações de validação e treinamento foram passadas para as redes e, durante o treinamento, o algoritmo armazenava a estrutura que obtivesse o menor erro para o conjunto de validação, o que é conhecido como *earlystopping*. As redes que obtiveram melhor desempenho (menor erro) foram utilizadas também para testar a classificação dos sinais EEG da terceira etapa de coletas.

Para a classificação foi adotado a menor diferença absoluta entre o valor da saída obtida e os valores padrões para o EEG espontâneo (0), movimento (1/2) e imaginação (1).

Por exemplo, o eletrodo seria caracterizado como de EEG espontâneo se a saída retornada pela MLP estivesse mais próxima de zero.

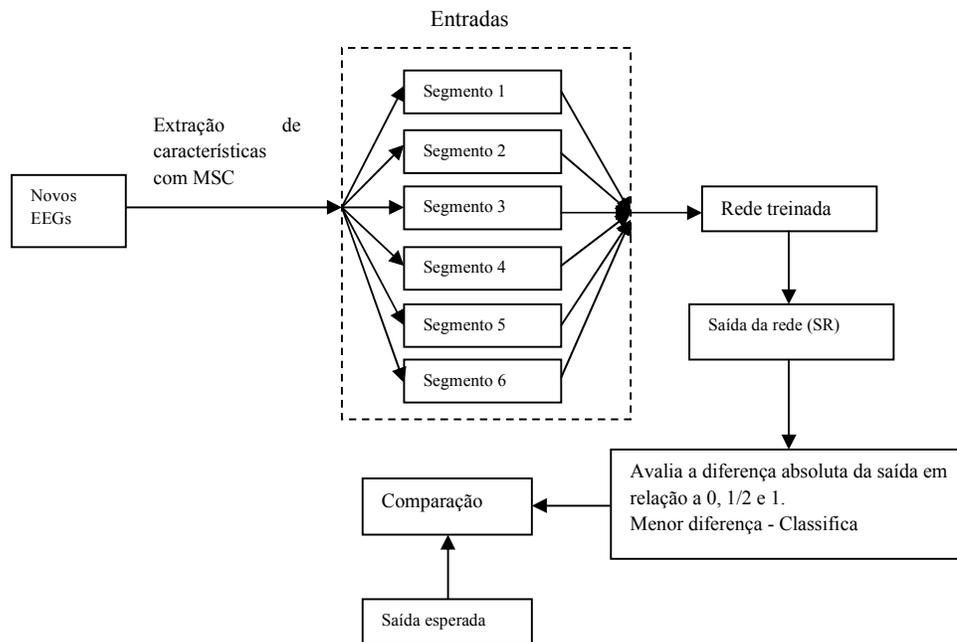


Figura 4.10 – Sistema de validação e classificação para os sinais EEG a partir dos redes treinadas de cada sujeito.

CAPÍTULO 5: RESULTADOS

Este capítulo está dividido em três tópicos. O primeiro destinado à apresentação dos resultados obtidos com sinais simulados. O segundo explora os resultados apresentados pelo HMM durante o treinamento e validação, e finalmente relatam-se os resultados obtidos pela MLP.

5.1. Sinais Simulados

Nesse tópico, utilizaram-se os sinais simulados para a análise, como explicado no capítulo 4. A matriz inicial para as probabilidades de transição dos estados e as probabilidades de emissão das observações são idênticas às das tabelas 3 e 4, respectivamente.

Os modelos para o EEG do MR foram construídos com os eletrodos apresentados na tabela 5, onde os índices de acerto foram 79,20 %, 83,33 % e 100,00 %, para os sinais simulados dos sujeitos # 1, # 2 e # 3, respectivamente. A probabilidade de emissão das observações é apresentada na tabela 6, onde se percebe que no estado quatro a banda delta tem 100% de probabilidade de ocorrer em todos os sujeitos, concordando com o esperado (SANTOS FILHO *et al.*, 2009). Os demais estados e bandas apresentam caráter aleatório, uma vez que tem a MSC de um ruído branco.

A probabilidade de transição do estado 1 para o estado 2, para o sujeito #1 (Fig. 5.1), foi de 0,57, enquanto que a probabilidade de ficar no mesmo estado foi de 0,43. As demais probabilidades foram unitárias, ou seja, uma vez atingido o segundo estado, o modelo sempre irá para o seguinte. Comportamento similar pode ser observado para os sujeitos # 2 e # 3.

Tabela 5 – Eletrodos utilizados no treinamento e na validação e o índice de acerto obtido por cada sinal simulado do MR.

EEG	Sujeito	Eletrodos		Acerto
		Treinamento	Validação	
MR com ruído	Sujeito #1	C4 e Cz	C3	79,20%
	Sujeito #2	C3 e C4	Cz	83,33%
	Sujeito #3	C3 e C4	Cz	100,00%

Tabela 6 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de MR misturado a um ruído branco gaussiano.

Sujeito	Estados	Banda Delta	Banda Alfa	Banda Beta
#1	1	0,09	0,75	0,16
	2	1,00	0,00	0,00
	3	0,00	0,00	1,00
	4	1,00	0,00	0,00
	5	0,00	1,00	0,00
	6	1,00	0,00	0,00
#2	1	0,08	0,27	0,65
	2	0,81	0,00	0,19
	3	0,00	1,00	0,00
	4	1,00	0,00	0,00
	5	0,00	0,76	0,24
	6	1,00	0,00	0,00
#3	1	0,72	0,07	0,21
	2	0,00	0,83	0,17
	3	0,00	0,00	1,00
	4	1,00	0,00	0,00
	5	0,18	0,00	0,82
	6	0,82	0,18	0,00

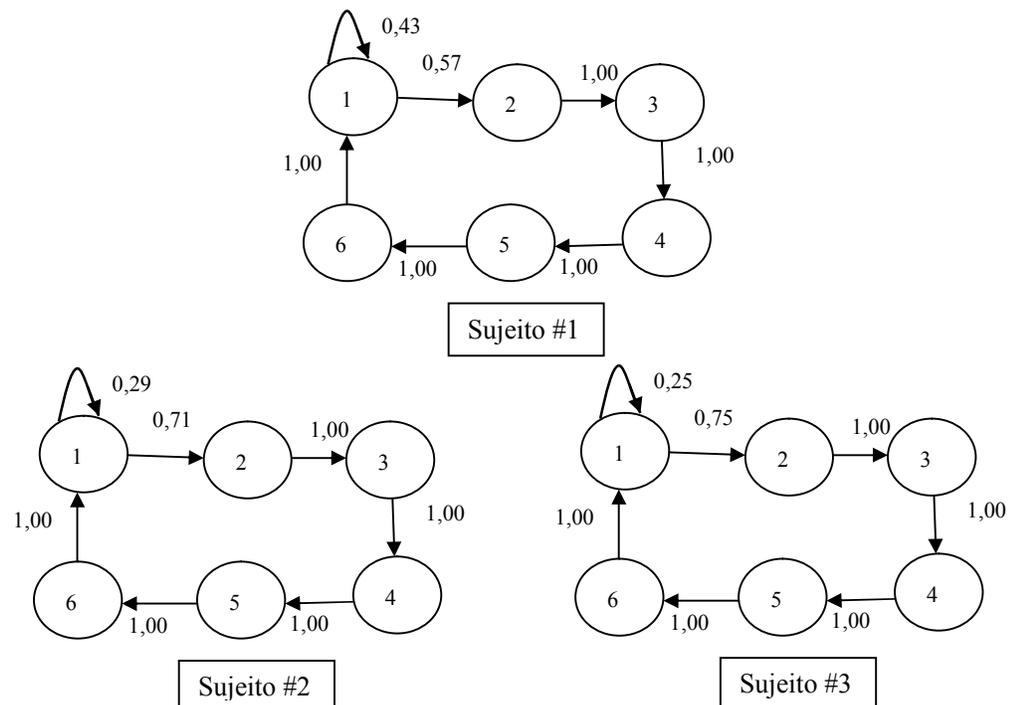


Figura 5.1 – Modelos para o EEG do MR misturado a ruído branco gaussiano dos três sujeitos analisados.

Analisando-se o EEG da IM misturada ao ruído branco, obtiveram-se os modelos apresentados na tabela 7. Esses modelos apresentaram índice de acerto entre 72,22 e 100 %, sendo o maior obtido pelo sujeito # 2.

As probabilidades de emissão das observações (tabela 8) apresentaram distribuição semelhante à do EEG do MR (tabela 6). No estado quatro também se obteve 100% de chance de ocorrer a banda delta, ao passo que, nos demais estados, não se teve um comportamento semelhante entre os indivíduos devido a presença do ruído branco somente.

Por outro lado, as probabilidades de transição dos estados possuíam maior chance de ficar no primeiro estado do que ir para o próximo. Além disso, da mesma forma que no MR, ao atingirem o segundo estado, os demais estados serão atingidos, pois, a probabilidade de transição era 100 %.

Tabela 7 – Eletrodos utilizados no treinamento e na validação e o índice de acerto obtido por cada sujeito no EEG do IM misturado com ruído branco gaussiano.

EEG	Sujeito	Eletrodos		Acerto
		Treinamento	Validação	
IM com ruído	Sujeito #1	C4 e C3	Cz	79,17%
	Sujeito #2	C4 e Cz	C3	100,00%
	Sujeito #3	C4 e C3	Cz	72,22%

Tabela 8 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG da IM misturado a um ruído branco gaussiano.

Sujeito	Estados	Banda Delta	Banda Alfa	Banda Beta
#1	1	0,00	0,15	0,85
	2	0,00	0,00	1,00
	3	0,00	0,00	1,00
	4	1,00	0,00	0,00
	5	0,00	1,00	0,00
	6	0,00	1,00	0,00
#2	1	0,26	0,74	0,00
	2	1,00	0,00	0,00
	3	0,00	1,00	0,00
	4	1,00	0,00	0,00
	5	0,00	1,00	0,00
	6	1,00	0,00	0,00
#3	1	0,21	0,00	0,79
	2	0,00	1,00	0,00
	3	0,00	0,00	1,00
	4	1,00	0,00	0,00
	5	0,00	0,00	1,00
	6	0,00	0,25	0,75

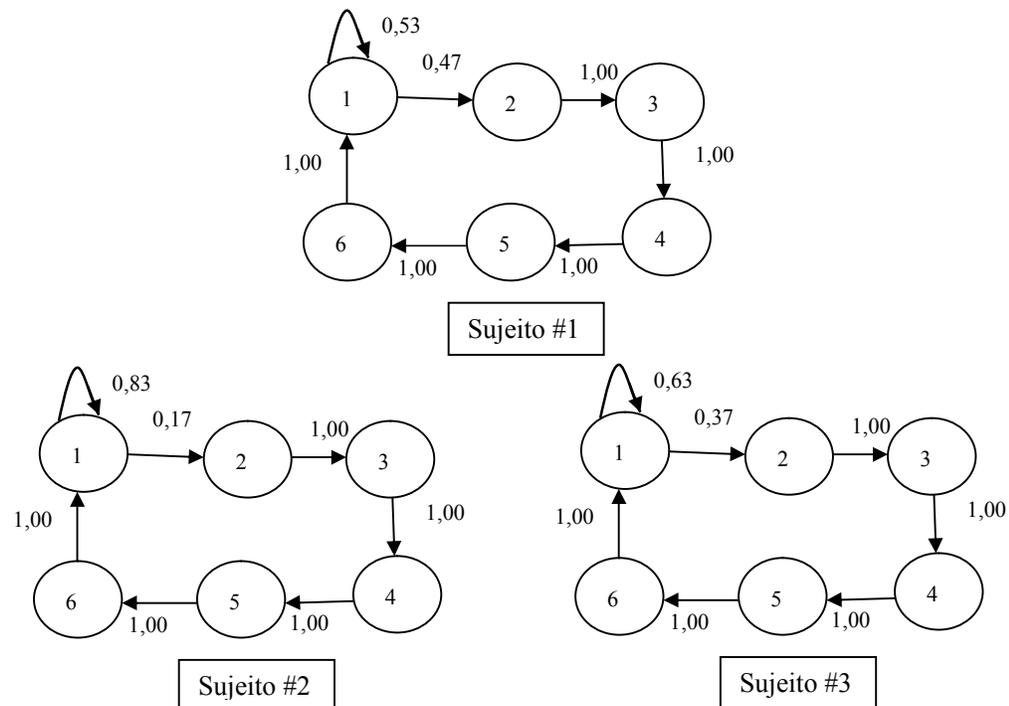


Figura 5.2 – Modelos para o EEG da IM misturado a ruído branco gaussiano dos três sujeitos analisados.

5.2. Sinais EEG

5.2.1. HMM

Esse tópico será dividido em duas etapas:

- Treinamento;
- Validação e Classificação.

Treinamento

Diferentes combinações de canais foram avaliadas para a construção dos modelos, até que se obtivesse a melhor resposta na validação. As probabilidades de emissão das observações para os três sujeitos estão apresentados na tabela 9. Para os três sujeitos observou-se que a probabilidade de se obter a banda delta no estado quatro (durante o movimento) foi de 100%, como esperado (SANTOS FILHO *et al.*, 2009), uma vez que a banda delta aparece durante a realização desta tarefa. Por outro lado, a probabilidade mais alta nos sujeitos #2 e #3 de se ter a banda alfa foi 61 % e 33%, no estado cinco, que caracteriza um estado de relaxamento, após o movimento. Para a banda beta, teve-se uma média de 62 % no estado pré-movimento (estado três) e, no estado pós-movimento (estado

5) essa banda teve média de, aproximadamente, 37 %. Além disso, analisando a passagem do estado dois para o três, observa-se um incremento da banda beta em todos os indivíduos.

A probabilidade de transição dos estados mostrou que somente o primeiro estado possui probabilidade de ir para o estado seguinte ou de ficar no mesmo processo, caracterizando uma média de 76 % de ficar e 24 % de ocorrer a transição. Os demais estados apresentaram 100% de probabilidade de ocorrer a transição para o estado seguinte (Fig. 5.3), essa seqüência mostra que uma vez atingido o estado dois, todo o processo irá se completar, atingindo novamente o estado 1.

Tabela 9 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de movimento e todos os indivíduos.

Sujeitos	Estados	Banda Delta	Banda Alfa	Banda Beta
#1	1	0,11	0,23	0,67
	2	0,37	0,21	0,42
	3	0,05	0,29	0,66
	4	1,00	0,00	0,00
	5	0,02	0,18	0,80
	6	0,09	0,16	0,75
#2	1	0,06	0,20	0,74
	2	0,08	0,16	0,76
	3	0,09	0,42	0,49
	4	1,00	0,00	0,00
	5	0,00	0,61	0,39
	6	0,00	0,15	0,85
#3	1	0,13	0,33	0,54
	2	0,17	0,36	0,47
	3	0,15	0,15	0,70
	4	1,00	0,00	0,00
	5	0,09	0,33	0,58
	6	0,00	0,22	0,78

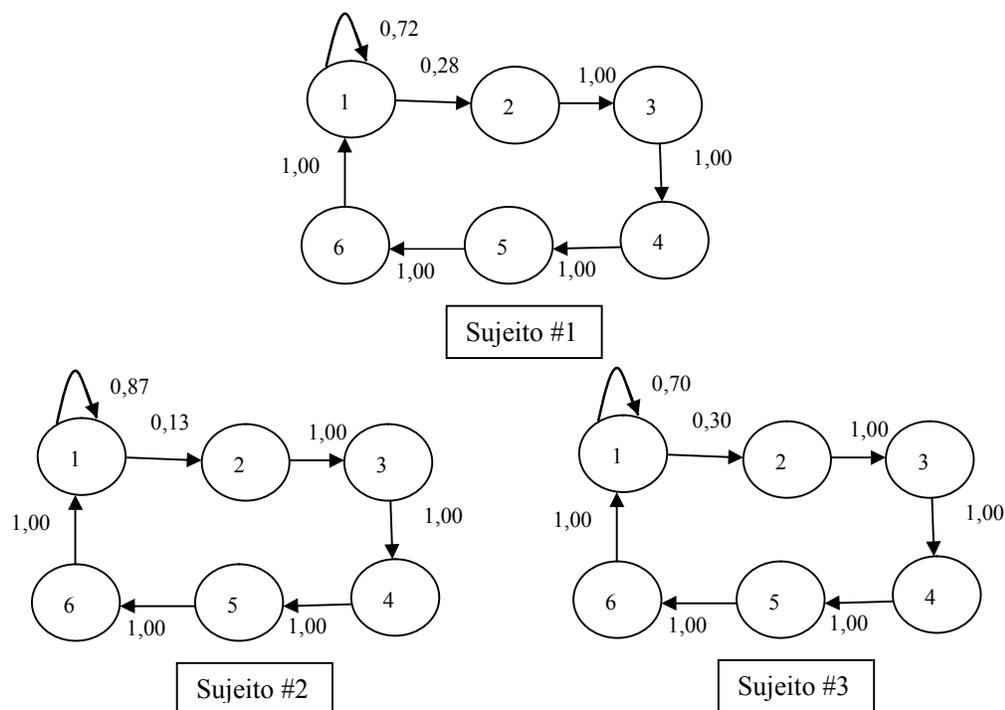


Figura 5.3 – Modelos para o EEG de movimento dos três sujeitos analisados. As probabilidades de transições que não são mostradas são nulas.

Para o EEG de imaginação de movimento, os modelos obtidos tiveram matrizes similares às apresentadas pelo EEG de MR. Analisando as probabilidades de emissão das observações (tabela 10), observou-se que, assim como no EEG do MR, a banda delta mostra maior probabilidade durante o quarto estado (100 %), indicando a realização da IM (SANTOS FILHO *et al.*, 2009). Diferente do EEG do MR, as bandas beta e alfa sofreram alteração em cada indivíduo. O sujeito # 1, apresentou padrão de concentração no estado 3 (38 % - banda beta) antes da imaginação de movimento. O sujeito # 2 apresenta predomínio da banda beta nos estados um (43 %), dois (61 %) e seis (100 %). Analisando o sujeito # 3, observou-se que em todos os estados, com exceção do segundo e quarto, teve-se o predomínio da banda beta (1 – 65 %; 3 – 100 %; 5 – 100 %; 6 – 100 %).

A probabilidade de transição dos estados foi de 100%, exceto no primeiro estado, que apresenta média de 79 % de chance de ficar no estado atual e 21 % de progredir para o estado que o sucede (Fig. 5.4).

Tabela 10 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG de imaginação de movimento para todos os indivíduos.

Sujeitos	Estados	Banda Delta	Banda Alfa	Banda Beta
#1	1	0,00	0,27	0,73
	2	0,00	0,62	0,38
	3	0,00	0,11	0,89
	4	1,00	0,00	0,00
	5	0,06	0,50	0,44
	6	0,11	0,11	0,78
#2	1	0,17	0,40	0,43
	2	0,14	0,25	0,61
	3	0,00	0,77	0,23
	4	1,00	0,00	0,00
	5	0,00	0,00	1,00
	6	0,00	0,00	1,00
#3	1	0,10	0,25	0,65
	2	0,00	0,86	0,14
	3	0,00	0,08	0,92
	4	1,00	0,00	0,00
	5	0,00	0,00	1,00
	6	0,00	0,00	1,00

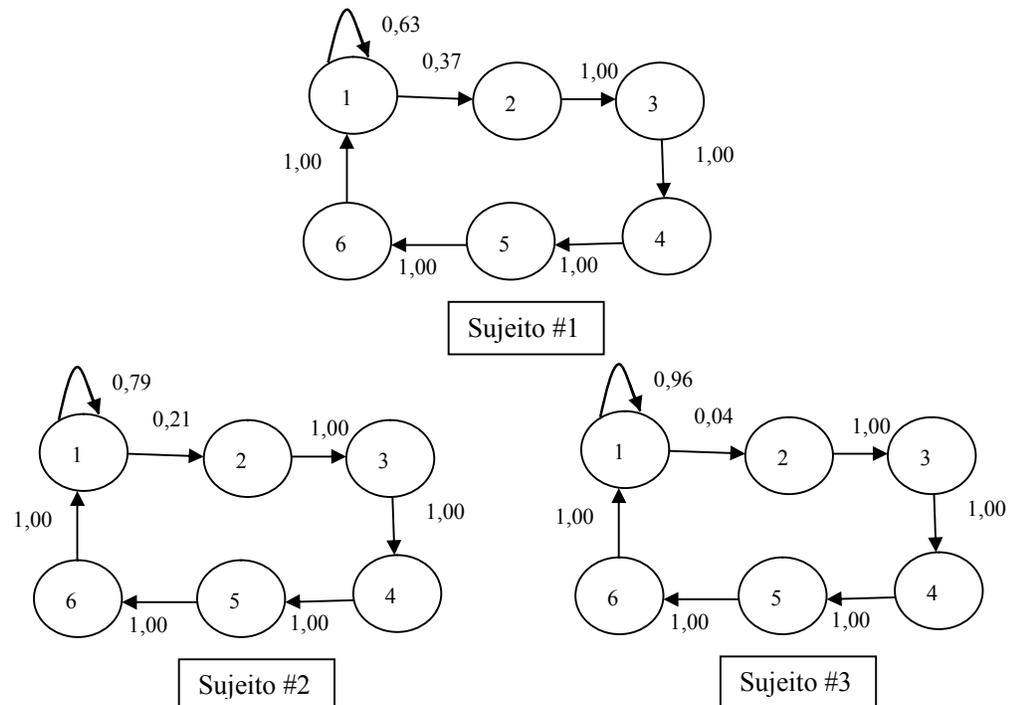


Figura 5.4 – Modelo do EEG da imaginação de movimento dos três sujeitos. As probabilidades de transição dos estados que não são mostradas na figura são nulas.

Para o EEG espontâneo a matriz de probabilidade de emissão das observações mostrou uma grande aleatoriedade entre os estados e as bandas, caracterizando o mesmo (tabela 11). Diferentemente dos dois EEG's analisados anteriormente, este apresentou

sempre a probabilidade de transição de 100 %, ou seja, decorrido um determinado intervalo ocorrerá a mudança de estado (Fig. 5.5).

Tabela 11 – Matriz de probabilidades de emissão das observações, para diferentes estados do EEG espontâneo para todos os indivíduos.

Sujeitos	Estados	Banda Delta	Banda Alfa	Banda Beta
#1	1	0,14	0,29	0,57
	2	0,00	0,09	0,91
	3	0,29	0,09	0,62
	4	0,00	0,05	0,95
	5	0,00	0,33	0,67
	6	0,24	0,09	0,67
#2	1	0,14	0,29	0,57
	2	0,48	0,00	0,52
	3	0,09	0,34	0,57
	4	0,05	0,09	0,86
	5	0,00	0,29	0,71
	6	0,14	0,24	0,62
#3	1	0,00	0,14	0,86
	2	0,14	0,05	0,81
	3	0,00	0,43	0,57
	4	0,05	0,05	0,90
	5	0,19	0,48	0,33
	6	0,00	0,05	0,95

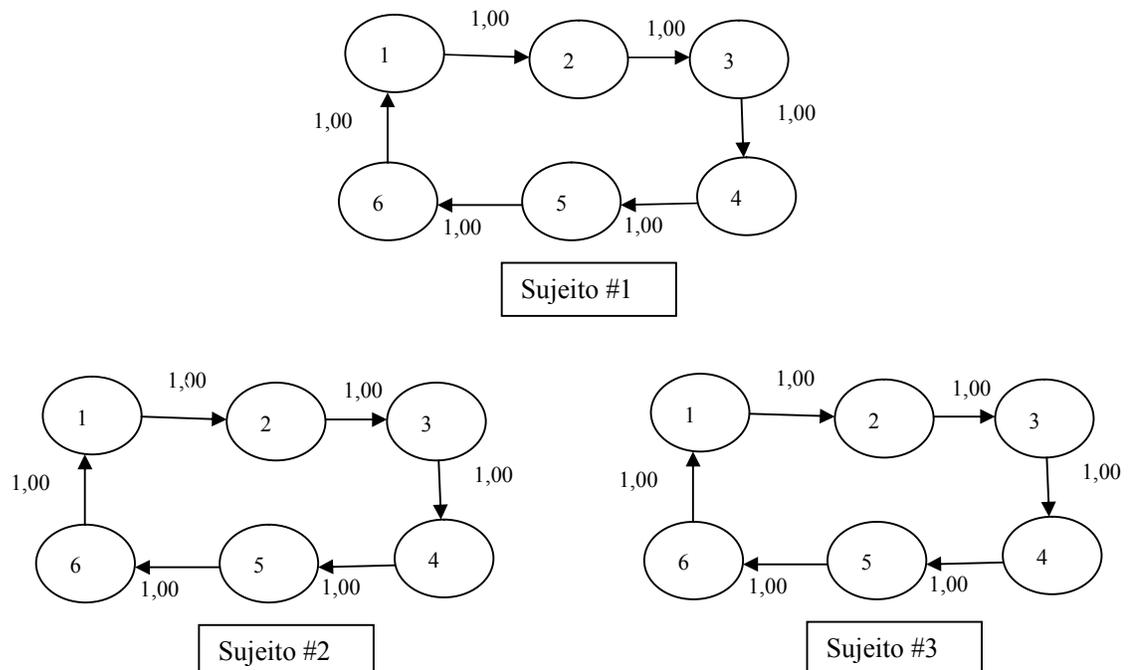


Figura 5.5 – Modelo do EEG espontâneo dos três sujeitos. As probabilidades de transição dos estados que não são mostradas na figura são nulas.

Validação e Classificação

A segunda etapa utilizando modelos ocultos de Markov refere-se à validação e classificação de acordo com o diagrama da Fig. 4.8. Os resultados obtidos com as observações dos eletrodos para os sinais EEG do sujeito # 1 e MSC de $M=12$ são apresentados na Fig. 5.6 (azul), para a segunda etapa de EEG realizada. Esse resultado foi obtido através da validação dos modelos gerados na etapa de treinamento. O índice de sinais dos eletrodos referentes ao EEG espontâneo, MR e IM classificados corretamente foram 40 %, 100 % e 100 %, respectivamente. Somando conflito com acertos, teve-se 80 % do número total de sinais EEG apresentados para a classificação. Para a terceira etapa de EEG analisada (Fig. 5.6 – vermelho), também coletada com a configuração da Fig. 4.2, fez-se a validação com os modelos gerados no treinamento. Para o sujeito # 1 observou-se que o índice de acerto global foi inferior à análise feita com a segunda etapa de EEG. Além disso, como os modelos de imaginação e de movimento possuíam probabilidades muito semelhantes, ocorreu conflito na classificação do EEG da IM e do MR (44 % dos eletrodos analisados).

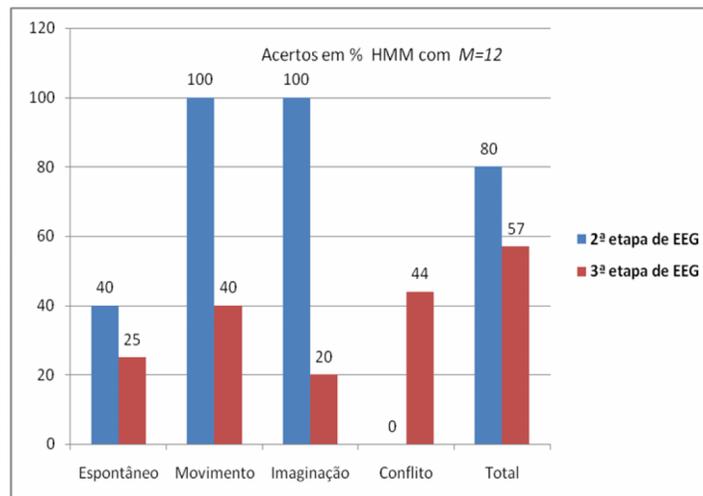


Figura 5.6 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 1, utilizando os modelos feitos no treinamento para as etapas 2 e 3. As observações são obtidas através da coerência de 12 trechos.

Utilizando as observações provenientes da coerência com o número máximo de trechos existentes em cada eletrodo, tem-se a Fig. 5.7. Nesta percebe-se que o número de acertos foi superior ao resultado anterior (Fig. 5.6) para a segunda etapa de EEG. Além disso, o número de conflitos entre MR e IM, foi de 10 % na segunda etapa e de 40% na terceira etapa. Os acertos somados aos conflitos totalizaram 73 % em ambas as etapas.

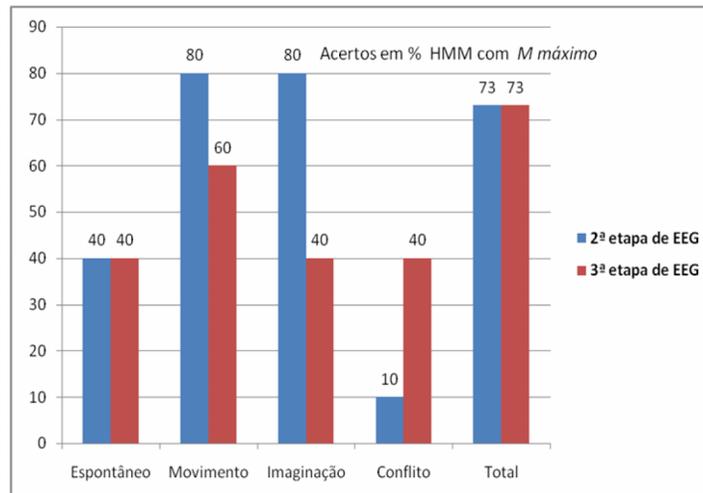


Figura 5.7 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 1 para as 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo para obter as observações.

Para o sujeito # 2 têm-se os resultados apresentados nas Fig. 5.8 ($M=12$) e 5.9 (M máximo). Percebeu-se que o índice de acertos somados aos conflitos foi inferior quando se usava o número máximo de trechos em cada eletrodo, 60 % contra 73 % com $M=12$, para a segunda etapa validada. O conflito entre MR e IM foi de 40 % e 0 % ($M = 12$ e M máximo, respectivamente), ao passo que, o índice de acerto do EEG da IM aumentou de 60 % ($M=12$) para 100 % (M máximo). Analisando a terceira etapa de EEG realizada (Fig. 5.8 em vermelho), o índice de sinais dos eletrodos referentes ao EEG espontâneo, IM e MR classificados corretamente foi 20 %, 60 % e 60 %, respectivamente. Além disso, ocorreu conflito na classificação do EEG da IM e do MR (20 % dos eletrodos analisados), sendo que, esse valor somado aos acertos, totalizou 60 % do número total de sinais EEG apresentados para a classificação. Por outro lado, utilizando as observações da terceira etapa provenientes da coerência com o número máximo de trechos, tem-se a Fig. 5.9 (vermelho). Nesta percebeu-se que o número de acertos foi superior ao resultado anterior (Fig. 5.8 em vermelho), apresentando 80 %. Além disso, o número de conflitos entre MR e IM foi 20 % e os acertos somados aos conflitos totalizaram 80 % (valor superior ao apresentado na análise usando $M=12$).

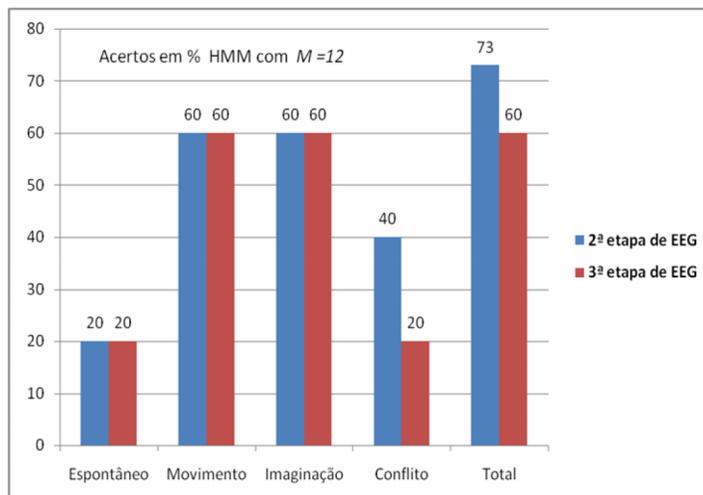


Figura 5.8 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 2 da 2ª e 3ª etapas de EEG, utilizando os modelos construídos no treinamento e $M=12$.

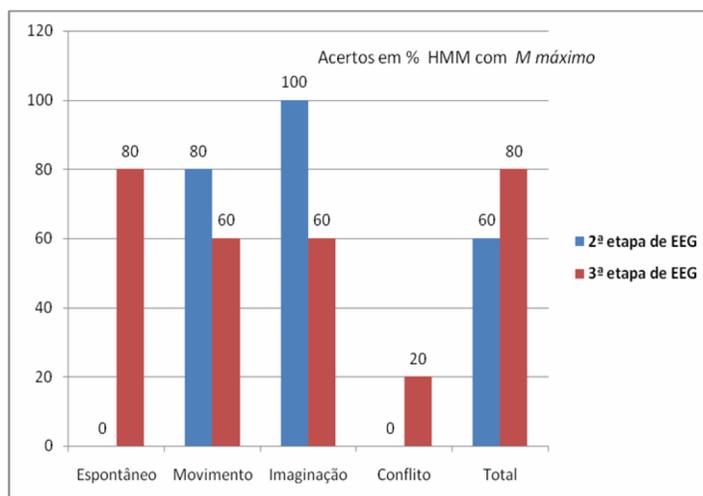


Figura 5.9 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 2 para as 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo.

Para o sujeito # 3 têm-se as Fig.s 5.10 ($M=12$) e 5.11 (M máximo), mostrando que os índices de acertos somados aos conflitos foram inferiores aos dos sujeitos # 1 e # 2. Os eletrodos do EEG espontâneo que foram classificados corretamente representam 20 % e 40 % para $M=12$ e M máximo, respectivamente e segunda etapa (barras azuis das Fig.s 5.10 e 5.11). O EEG do MR apresentou 40 % de índice de acerto em ambos, ao passo que, o IM reduziu de 80 % para 40 %. Os conflitos entre MR e IM também reduziram de 40 % para 30 %. Para a terceira etapa (barras vermelhas nas Fig.s 5.10 e 5.11) os eletrodos classificados corretamente para o EEG espontâneo, MR e IM, utilizando $M=12$ foram 40 %, 100 % e 40 %, respectivamente, apresentando 13 % de conflito. Por outro lado, utilizando observações feitas com o número máximo de trechos, os números de eletrodos

classificados corretamente foram 20 %, 80 % e 20 % para o EEG espontâneo, de MR e IM, respectivamente. Somando-se os acertos e os conflitos teve-se uma taxa de 53 % utilizando M máximo ao passo que, utilizando observações provenientes da coerência com 12 trechos, teve-se uma taxa de 62 %.

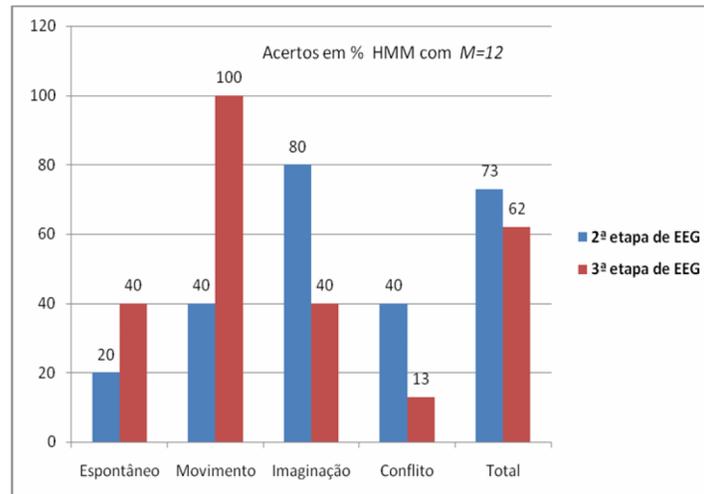


Figura 5.10 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 3 para a 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e $M=12$.

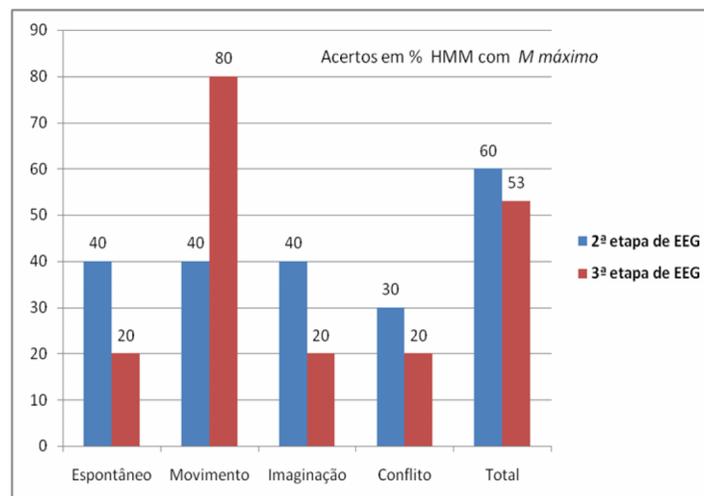


Figura 5.11 – Classificação com HMM do EEG do MR, IM e espontâneo do sujeito # 3 para a 2ª e 3ª etapas, utilizando os modelos construídos no treinamento e M máximo.

De forma geral, o índice de acerto médio para os três sujeitos utilizando coerência com $M=12$ e M máximo está representado na tabela 12. Na tabela também se tem a média dos acertos somados aos conflitos.

Tabela 12 – Média dos índices de acerto na classificação dos eletrodos para os três sujeitos com HMM.

	Taxa média de acerto	EEG espontâneo (%)	EEG do MR (%)	EEG da IM (%)	Conflitos (%)	Acertos + Conflitos (%)
<i>M = 12</i>	Sujeito # 1	32,5	70,0	60,0	22,0	68,5
	Sujeito # 2	20,0	60,0	60,0	30,0	66,5
	Sujeito # 3	30,0	70,0	60,0	26,5	67,5
<i>M Máximo</i>	Sujeito # 1	40,0	70,0	60,0	25,0	73,0
	Sujeito # 2	40,0	70,0	80,0	10,0	70,0
	Sujeito # 3	30,0	60,0	30,0	25,0	56,5

5.2.2. RNA

Assim como nos modelos HMM, as redes neurais na configuração MLP (capítulo 3) foram utilizadas na classificação dos sinais EEG das etapas dois e três. O treinamento foi realizado com os sinais EEG da primeira e segunda etapa de coletas. Como apresentado no capítulo 4, as redes foram treinadas e o critério de classificação dos novos sinais foi estabelecido através de uma análise linear simples de diferença entre os pontos.

Utilizando coerência com 12 trechos para o sujeito # 1, obteve-se o índice de acerto apresentado na Fig. 5.12, para a segunda (azul) e terceira (vermelho) etapas. Essa rede foi composta por duas camadas ocultas com dois e nove neurônios, respectivamente. Nessa configuração observou-se que o índice de sinais EEG classificados corretamente foi maior para a segunda etapa analisada: 57 %, 81 % e 67 %, para EEG espontâneo, EEG de MR e da IM, respectivamente. O menor índice de acerto para a terceira etapa de EEG foi a IM com 1 % de acerto, ao passo que o número de conflitos existentes foi de 50 %. Comparando com segunda etapa observou-se um acerto maior do EEG da IM (67 %) e menor número de conflitos (9 %).

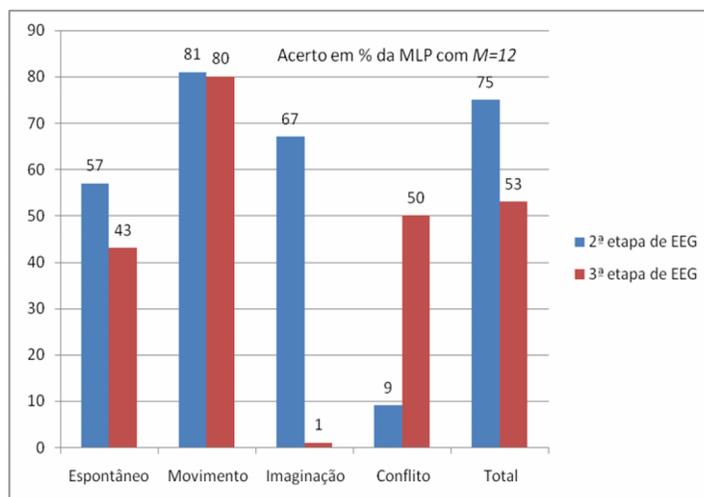


Figura 5.12 – Classificação do EEG do MR, IM e espontâneo do sujeito # 1, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.

A rede adaptada para o sujeito # 1 com número máximo de trechos apresentou uma camada escondida com 18 neurônios e seus resultados estão ilustrados na Fig. 5.13 (azul para a segunda etapa de EEG e vermelho para a terceira). Para a segunda etapa, os índices de acerto foram elevados para todos os eventos (100 %, 83 % e 100 % para espontâneo, MR e IM, respectivamente) ao passo que o índice de conflitos foi nulo. Para a terceira etapa o índice de acerto do EEG espontâneo reduziu-se para 53 % assim como os índices de acertos da IM e do MR, 6 % e 18 %, respectivamente. Por outro lado, o número de conflitos aumentou-se em virtude da redução do número de acertos em IM e MR (59 %).

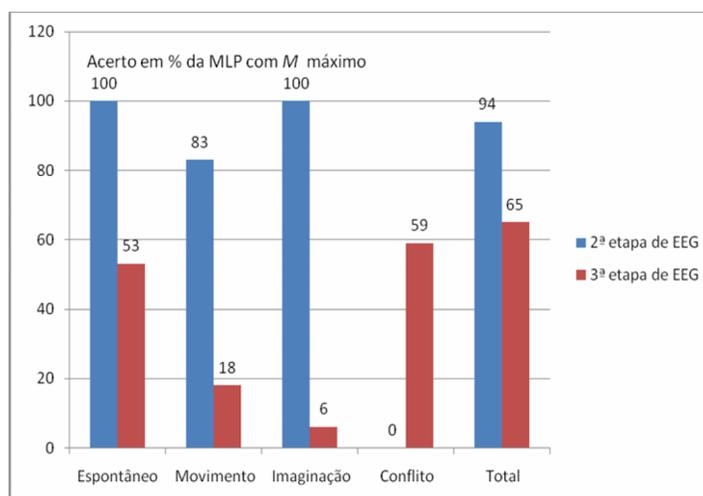


Figura 5.13 – Classificação do EEG do MR, IM e espontâneo do sujeito # 1, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.

Para o sujeito # 2 com observações referentes à $M=12$, a rede foi composta por uma camada oculta com seis neurônios. Nessa configuração observou-se que o índice de sinais EEG classificados corretamente foi muito semelhante nas duas etapas analisadas (Fig. 5.14 – azul: 2ª etapa e vermelho: 3ª etapa). A segunda etapa apresentou valores de EEG espontâneo e de MR inferiores: 29 % e 84 %, respectivamente, ao passo que os eventos de IM e conflitos foram superiores, 60 % e 43 %, respectivamente.

Ao analisarem-se os sinais EEG do mesmo sujeito considerando características obtidas com M máximo, obteve-se uma rede ajustada com duas camadas escondidas contendo 3 e 1 neurônios, respectivamente. Nessa configuração (Fig. 5.15), a segunda etapa de EEG também apresentou maiores índices de acerto sendo superiores para o MR e IM: 100 % e 83 %, respectivamente. Os conflitos presentes na classificação das duas etapas tiveram média de 17,5 %. O menor índice de acerto para a terceira etapa foi o EEG espontâneo com 47 % de acerto.

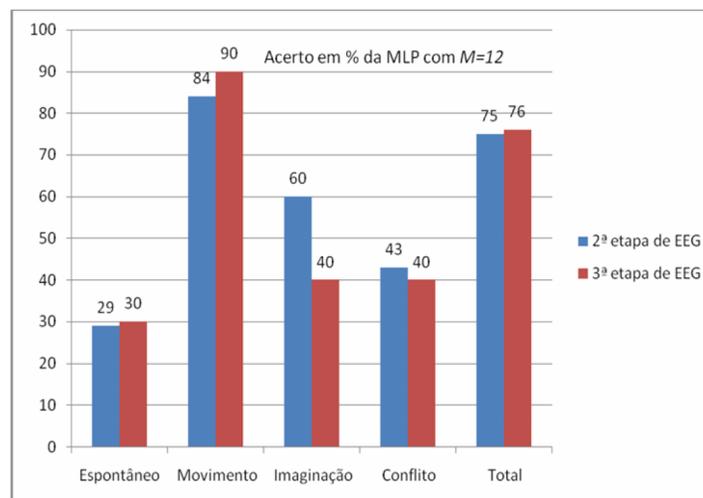


Figura 5.14 – Classificação do EEG do MR, IM e espontâneo do sujeito # 2, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.

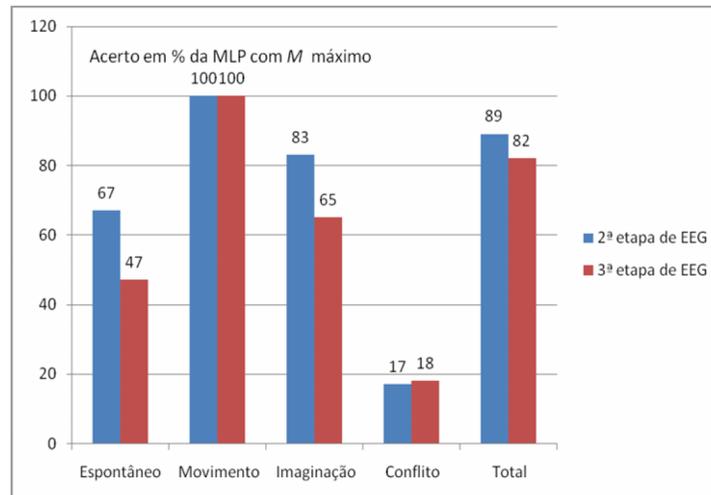


Figura 5.15 – Classificação do EEG do MR, IM e espontâneo do sujeito # 2, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.

Para o terceiro sujeito têm-se os resultados apresentados nas Figs 5.16 ($M=12$) e 5.17 (M máximo). As redes ajustadas para cada configuração possuíam três camadas escondidas com 1, 1 e 6 neurônios para $M=12$ e uma camada escondida com um neurônio para M máximo. Para $M=12$, notaram-se valores muito próximos para as segunda e terceira etapas, sendo que, em ambas, não houve acerto para o EEG da IM. Além disso, o índice de acerto para EEG espontâneo foi relativamente baixo, com média de 26 % e os conflitos totalizaram 43 %.

Por outro lado, analisando a resposta obtida com M máximo, notou-se para o EEG espontâneo um número de acertos superior ao da análise com $M=12$: 50 % e 81 %, para a segunda e terceira etapas, respectivamente. Os acertos para o IM continuaram sendo nulos ao passo que o MR apresentou 100 % de acerto médio para as duas etapas. Os conflitos também apresentaram valor semelhante e equivalente a 50 %.

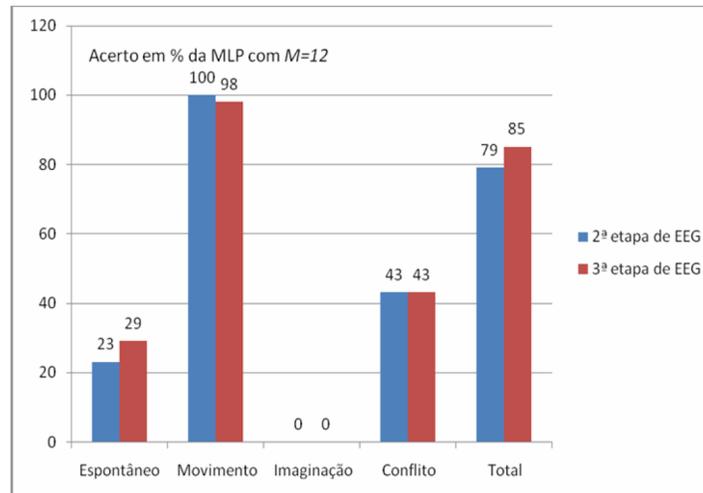


Figura 5.16 – Classificação do EEG do MR, IM e espontâneo do sujeito # 3, utilizando a MLP no treinamento e $M=12$, segunda e terceira etapas.

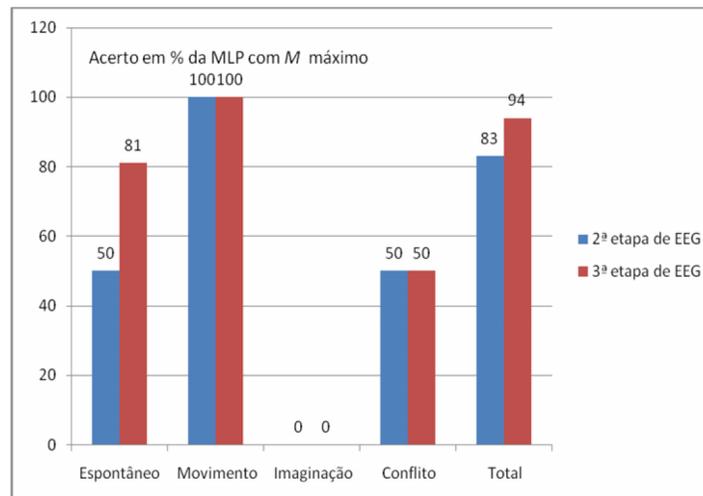


Figura 5.17 – Classificação do EEG do MR, IM e espontâneo do sujeito # 3, utilizando a MLP no treinamento e M máximo, segunda e terceira etapas.

O índice de acerto médio para os três sujeitos utilizando coerência com $M=12$ e M máximo está representado na tabela 13, onde se tem também a média dos acertos somados aos conflitos.

Tabela 13 – Média dos índices de acerto na classificação dos eletrodos para os três sujeitos para RNA.

	Taxa média de acerto	EEG espontâneo (%)	EEG do MR (%)	EEG da IM (%)	Conflitos (%)	Acertos + Conflitos (%)
<i>M = 12</i>	Sujeito # 1	50,0	80,5	34,0	29,5	64,0
	Sujeito # 2	29,5	87,0	50,0	41,5	75,5
	Sujeito # 3	26,0	99,0	0,0	43,0	82,0
<i>M Máximo</i>	Sujeito # 1	76,5	50,5	53,0	29,5	79,5
	Sujeito # 2	57,0	100,0	74,0	17,5	85,5
	Sujeito # 3	65,5	100,0	0,0	50,0	88,5

CAPÍTULO 6: DISCUSSÃO

Esse trabalho apresentou uma investigação do uso da MSC para extrair características do EEG, e comparou os classificadores com HMM e RNA para três eventos: EEG espontâneo, EEG da IM e EEG do MR.

Inicialmente foi feita uma avaliação com sinais simulados contendo uma senóide e ruído branco com vistas a entender o modelo oculto de Markov (resultados não apresentados). Obtiveram sempre 100 % de índice de acerto da identificação dos estados na frequência da senóide. Devido a este fato, utilizou-se como sinal simulado um ruído branco adicionado o período do EEG relativo ao MR e a IM (período corresponde ao estado 4) dos 3 três voluntários. Neste caso, o índice de acerto da identificação dos estados foi em média de 87,51 % para o MR e 83,80 % para a IM. Como esperado a banda delta sempre teve probabilidade de 1 para o quarto estado, sendo que para as outras bandas (alfa e beta) a probabilidade foi nula. Nos outros estados as bandas apresentaram diferentes probabilidades, inclusive a banda delta com probabilidade de 1. Este fato é explicado pela presença do ruído branco, que poderia fornecer maior coerência em qualquer banda.

Com os sinais EEG a primeira etapa consistiu em avaliar os modelos HMM de acordo com as características atribuídas como observações para os mesmos. Analisando os modelos construídos com os eletrodos das regiões central, frontal e parietal, observou-se que estes apresentaram diferenças entre as probabilidades do primeiro estado e as probabilidades de emissão das observações. Esse resultado é esperado, pois os eventos estão relacionados com períodos de tempo, ou seja, depois de determinado intervalo a transição de estados irá ocorrer. Para todos os modelos a diferença aparece na matriz de emissão das probabilidades. Modelos com números de estados distintos poderiam ser avaliados para verificar se os índices de acerto seriam superiores, porém, neste estudo, manteve-se esse número fixo em seis. Foi feita uma análise isolada com o sujeito #1, utilizando apenas dois estados, porém os resultados não foram apresentados, pois o índice de acerto foi inferior ao obtido com seis estados.

No quarto estado dos modelos de IM e MR, em todos os sujeitos, obteve-se probabilidade de 100 % de ocorrer a banda delta. Esse resultado é justificado por haver coerência da banda delta durante a realização do evento de MR ou IM (SANTOS FILHO

et al., 2009). As bandas nos outros estados apresentaram probabilidades distintas sendo essas características peculiares a cada indivíduo. Além disso, para cada sujeito e evento o número de observações para o HMM e entradas para a RNA tiveram valores distintos (devido aos trechos rejeitados por considerá-los com artefatos), podendo ser este um dos motivos para os diferentes índices de acertos encontrados entre os indivíduos e técnicas. O menor índice de acerto para IM também pode ser devido à habilidade do indivíduo para imaginação motora (SANTOS FILHO *et al.*, 2009).

No EEG de movimento e da IM a banda beta apresentou, respectivamente, 62 % e 68 % de probabilidade média de ocorrência no terceiro estado, sendo o mesmo correspondente a preparação para a realização da tarefa (LED amarelo aceso). Esta coerência da banda beta poderia estar representando um estado de concentração em que o indivíduo se prepara para realizar a tarefa. No segmento após a execução da tarefa (estado 5) - referente ao EEG espontâneo - existe predomínio, em alguns indivíduos, da banda alfa (37 % no MR), podendo representar um estado de relaxamento. Maiores estudos devem ser realizados em relação a estes achados.

Na classificação observam-se diferenças entre a RNA (MLP) e o HMM. Na maioria dos resultados ressalta-se que o índice de acerto da segunda etapa de coleta do EEG é superior ao da terceira. Isso pode ocorrer, pois os padrões de EEG podem sofrer alterações de acordo com a situação do sujeito: motivação, fadiga, dentre outros aspectos (GYSELS *et al.*, 2004). Assim, em trabalho futuro o modelo e a rede poderiam ter seus parâmetros ajustados com técnicas adaptativas (GYSELS *et al.*, 2004).

O acerto total foi considerado como a junção dos acertos em cada evento mais os conflitos. Isso foi assim considerado, pois a banda de frequência característica para o MR e IM é a mesma (banda delta – SANTOS FILHO *et al.*, 2009) gerando o conflito entre os dois eventos. No HMM isso pode ser observado quando se avalia os modelos, verificando que os mesmos apresentam probabilidades de observações semelhantes. Esse conflito seria favorável para o acionamento de algum dispositivo ao se fazer um protótipo em ICM, principalmente em aplicações como próteses em sujeitos com algum tipo de limitação motora, por exemplo. Em estudos futuros seria interessante verificar o desempenho de tais modelos em um sistema *online* além de testes com indivíduos com deficiências motoras.

Analisando as tabelas 12 e 13, nota-se que, para $M=12$, o índice de acerto total é maior no sujeito # 3 com a classificação por meio da MLP (82 %), porém esse mesmo sujeito apresentou baixo índice de acerto para o EEG espontâneo (26 %). Por outro lado, avaliando-se cada evento separadamente observou-se que o maior índice de acerto no EEG espontâneo foi do sujeito # 1, usando $M=12$ e MLP (50 %). A variação no índice de acerto para o EEG espontâneo pode ser explicado pela utilização da máxima coerência sem considerar um limiar de detecção. Em trabalho futuro pode ser considerado este limiar. Para o EEG do MR teve-se 99 % de acerto do sujeito # 3 utilizando RNA. A IM apresentou maior índice de acerto para o sujeito # 2 e utilizando classificação com HMM (60 %). Para M máximo, tiveram-se os maiores valores para o EEG espontâneo, do MR e da IM representados por 76,5 % (sujeito # 2), 100 % (sujeitos # 2 e # 3) e 80 % (sujeito # 2), nas técnicas de RNA, RNA e HMM, respectivamente. De forma geral, a MLP mostrou-se com desempenho melhor para a classificação dos eventos. Como esperado, com o número máximo de trechos, teve-se maiores índices de acerto na maioria dos casos. Os resultados que apresentaram menor índice de acerto com M máximo do que com $M=12$, podem ser devido a não execução de tarefa (MR ou IM) ou ao movimento indevido na sessão de EEG espontâneo.

De forma geral, comparando os resultados das duas técnicas, observa-se que a RNA apresentou maior índice de acerto, principalmente na classificação do EEG de MR (Tabelas 12 e 13). Além disso, comparando os resultados obtidos com alguns resultados apresentados na literatura, notam-se índices de acerto similares. Um exemplo é o trabalho de GYSELS *et al.* (2004) que apresenta a classificação de três tarefas cognitivas com índices de acerto de 62,35 % (imaginação do movimento da mão esquerda), 60,81 % (imaginação do movimento da mão direita) e 55,14 % (pensar em palavras que se iniciam com a mesma letra) para três sujeitos. Deve-se indicar que nesse estudo as características utilizadas do EEG foram coerência e fase, nas bandas alfa e beta, sendo a classificação feita por meio das máquinas de vetor de suporte (*SVM – Support Vector Machine*). Além disso, outros estudos que envolvem tarefas relacionadas à IM também têm apresentado índices de acerto similares (PFURTSCHELLER *et al.*, 2001; EBRAHIMI *et al.*, 2003; GYSELS *et al.* 2004; QIN *et al.*, 2004; WANG *et al.*, 2004; KAMOUSHI *et al.*, 2005; CHIAPPA *et al.*, 2006; YUGE *et al.*, 2008).

Um dos fatores que prejudicaram a melhoria dos resultados foi a RSR, que interfere diretamente na coerência (FELIX *et al.*, 2007). Outra dificuldade encontrada foi a presença de muitos artefatos o que reduziu o número de trechos disponíveis para o cálculo da coerência (menor RSR) e, conseqüentemente, reduziu o número de observações e entradas para o HMM e RNA, respectivamente.

CAPÍTULO 7: CONCLUSÃO

O presente trabalho permitiu a junção de características do EEG obtidas através da coerência, ao longo de intervalos de tempo distintos, formando um vetor de características. A técnica da MSC apresentou-se uma ferramenta eficiente para extração das características do EEG relacionado aos eventos de movimento e imaginação de movimento. Com as características extraídas pela MSC, foi possível gerar modelos HMM e redes MLP, bastante eficazes, utilizando principalmente a associação de eletrodos da região central, frontal e parietal.

Além disso, a aplicação dessas características em modelos HMM e redes MLP proporcionaram resultados com índices de acerto semelhantes aos encontrados na literatura (LOTTE *et al.*, 2007; EBRAHIMI *et al.*, 2003; GYSELS *et al.*, 2004). Dessa forma, os achados no presente trabalho indicam que características da MSC podem fornecer informações relevantes para a classificação do EEG durante a realização de tarefas cognitivas de IM, principalmente na banda delta.

Como propostas para trabalhos futuros sugere-se: a implementação do sistema *online* fazendo os ajustes necessários para a utilização dos algoritmos; a utilização das técnicas de HMM e RNA combinadas com vistas a incrementar a eficiência na classificação; utilizar a energia de outras bandas de frequência como características, conforme utilizado na literatura junto com a coerência da banda delta; utilizar a coerência média da banda analisada em substituição a coerência máxima. Com as adaptações e a verificação do funcionamento do sistema *online* será possível avaliar melhor os resultados e analisar o desempenho em aplicações de interface cérebro-máquina.

Publicações

SOUZA, A. P.; SANTOS FILHO, S. A.; XAVIER, P. A. M.; FELIX, L. B.; MAIA, C. A.; TIERRA-CRIOLLO, C. J., **Modeling Movement and Imaginary Movement EEG by means of Hidden Markov Models and Coherence**. *ISSNIP Biosignals and Biorobotics Conference 2010*, Vitória – ES, 2010.

SANTOS FILHO, S. A.; SOUZA, A. P.; TIERRA-CRIOLLO, C. J.; XAVIER, P. A. M., **Simple and Multiple Coherence Application to Detect Event Related Potential to due Movement Imagination**. *ISSNIP Biosignals and Biorobotics Conference 2010*, Vitória – ES, 2010.

SOUZA CRUZ, A. A.; XAVIER, P. A. M.; SANTOS FILHO, S. A.; SOUZA, A. P.; TIERRA-CRIOLLO, C. J., **Four Freedom HMI Actuated by Electrooculogram**. *ISSNIP Biosignals and Biorobotics Conference 2010*, Vitória – ES, 2010.

SOUZA, A. P.; SANTOS FILHO, S. A.; XAVIER, P. A. M.; FELIX, L. B.; MAIA, C. A.; TIERRA-CRIOLLO, C. J., **Técnicas markovianas na identificação de potenciais relacionados a eventos utilizando coerência**. *REVISTA MÉDICA DE MINAS GERAIS*, pp.71 - 71, 2009.

SANTOS FILHO, S.A.; TIERRA-CRIOLLO, C.J.; SOUZA, A.P.; PINTO, M.A.S.; LIMA, M.L.C.; MANZANO, G.M., **Magnitude Squared of Coherence to detect imaginary movement**. *EURASIP Journal on Advances in Signal Processing*, Vol. 2009, article ID 534536, pp.1-12, 2009.

SANTOS FILHO, S. A.; SOUZA, A. P.; TIERRA-CRIOLLO, C. J.; XAVIER, P. A. M., **Investigação do uso da coerência simples e coerência múltipla para identificação de sinais relacionados a imaginação de movimento**. *REVISTA MÉDICA DE MINAS GERAIS*, p.70 - 70, 2009.

Referências

AHMADI, M.; ERFANIAN, A.; **An On-Line BCI System for Hand Movement Control Using Real-Time Recurrent Probabilistic Neural Network.** *Proceedings of the 4th International IEEE EMBS Conference on Neural Engineering*, Antalya, Turkey, 2009.

ANDERSON, C. W.; SIJERCIC, Z., **Classification of EEG signals from four subjects during five mental tasks.** *Solving Engineering Problems with Neural Networks: Proc. Conf. Engineering Applications in Neural Networks*, pp. 407–414, 1996.

ANDERSON, C.W.; STOLZ, E.A.; SHAMSUNDER, S., **Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks.** *IEEE Trans Biomed Eng.*, Vol.45(3), pp. 277-286, 1998.

ANDREAIO, R.V.; DORIZZI, B.; BOUDY, J., **ECG Signal Analysis through HMM.** *IEEE Transactions on Biomedical Engineering*, Vol. 53 (8), pp. 1541-1548, 2006.

AZEVEDO, A. P., **Estudo do sinal de Eletroencefalográfico (EEG) aplicado a Interfaces Cérebro Computador com uma abordagem de reconhecimento de padrões.** Dissertação de mestrado, Universidade Federal do Espírito Santo, Vitória – ES, 2005.

BANG-HUA, Y.; GUO-ZHENG, Y.; RONG-GUO, Y.; TING, W. **Adaptive subject-based feature extraction in brain–computer interfaces using wavelet packet best basis decomposition.** *Med. Eng. & Physics.*, Vol.29, pp. 48-53, 2007.

BARRETO, G. A.; FROTA, R. A.; MEDEIROS, F. N. S., **On the classification of mental tasks: a performance comparison of neural and statistical approaches.** *Machine Learning for Signal Processing, 2004. Proceedings of the 14th IEEE Signal Processing Society Workshop*, pp. 529-538, 2004.

BAZTARRICA, O. J., **EEG Signal Classification for Brain Computer Interface Applications.** Ecole Polytechnique Federale de Lusanne, 2002.

BAYLISS, J. D., **A Flexible Brain-Computer Interface.** Tese de Doutorado. University of Rochester, New York, EUA, 2001.

BENGIO, Y.; FRASCONI, P., **Input/output HMMs for sequence processing.** *IEEE Transactions on Neural Networks*, Vol. 7, pp. 1231-1249, 1996.

BIRBAUMER, N.; KÜBLER, A.; GHANAYIM, N.; HINTERBERGER, T.; PERELMOUTER, J. P.; KAISER, J.; IVERSEN, I.; KOTCHOUBEY, B.; NEUMANN, N.; FLOR, H., **The thought translation device (TTD) for completely paralyzed patients.** *IEEE Trans. Rehabil. Eng.*, Vol.8, pp.190-193, 2000.

BIRBAUMER, N.; COHEN, L.G., **Brain-computer interfaces: communication and restoration of movement in paralysis.** *The Journal of Physiology*, Vol.579, pp. 621-636, 2007.

BITTENCOURT, G., **Inteligência Artificial: Ferramentas e Teorias.** 2.ed. Florianópolis: Ed. UFSC, 2001.

BRAGA, A. P.; LUDERMIR, T.B.; CARVALHO, A. C. P. L. F., **Redes Neurais Artificiais – Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.

BRAGA, E.Q., **Estimação da resposta evocada à estimulação somatossensorial elétrica senoidal de 5 hz e 2 khz, utilizando wavelets e análise em componentes independentes**. Dissertação de mestrado, Universidade Federal de Minas Gerais, Belo Horizonte, 2007.

BRAIN CONNECTION. <<http://brainconnection.positscience.com/>>. Acesso em 07 de outubro de 2009.

CARTER, G. C., **Tutorial overview of coherence and time delay estimation**. *Coherence and Time Delay Estimation-An Applied Tutorial for Research, Developing, Test and Evaluation Engineers*, pp. 1–27, IEEE Press, New York, NY, USA, 1987.

CARVALHO, S. M. F., **Contribuição da imagem funcional por ressonância magnética para o estudo da reorganização do córtex motor pós-AVCI**. Dissertação apresentada à Faculdade de Medicina de Ribeirão Preto da USP para a obtenção do título de Mestre em Neurociências, Ribeirão Preto, SP, 2006

CHENG, M.; GAO, X.; GAO, S.; XU, D., **Design and Implementation of a Brain Computer Interface with high Transfer Rate**. *IEEE Trans. on Biomedical Eng.*, Vol. 49 (10), pp. 1181 – 1186, 2002.

CHIAPPA, K.H., **Evoked Potentials in Clinical Medicine**. 2 ed. New York, Raven Press. NY, USA, 1997.

CHIAPPA, S.; BENGIO, S., **HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems**. *European Symposium on Artificial Neural Networks*, Bruges (Belgium), pp. 199-204, 2004.

CHIAPPA, S.; BARBER, D., **EEG classification using generative independent component analysis**. *Neurocomputing*, Vol.69, pp.769-777, 2006.

DANGELO, J. G.; FATTINI, C.A., **Anatomia Humana Básica**. 2 ed., Atheneu, 2002.

DOBIE, R.A.; WILSON, M.J., **Analysis of Auditory Evoked Potentials by Magnitude-Squared Coherence**. *Ear and Hearing* Vol.10 (1), pp. 2-13, 1989.

DORNHEGE, G. **Increasing Information Transfer Rates for Brain-Computer Interfacing**. Tese de Doutorado, Universidade de Potsdam, Potsdam, Alemanha, 2006.

DUBIN, M. **Brodmann Areas in the Human Brain with an Emphasis on Vision and Language**. <<http://spot.colorado.edu/~dubin/talks/brodmann/brodmann.html>>. Acesso em 10 de novembro de 2009.

EBRAHIMI, T.; VESIN, J. M.; GARCIA, G., **Brain computer Interface in Multimedia Communication**. *IEEE Signal Processing Magazine*, Vol. 20, pp. 14-24, 2003.

FELIX, L. B.; MORAES, J. E.; MIRANDA DE SÁ, A. M. F. L.; YEHIA, H. C.; MORAES, M. F. D., **Avoiding spectral leakage in objective detection of auditory steady-state evoked responses in the inferior colliculus of rat using coherence.** *Journal of Neuroscience Methods*, Vol. 144, pp. 249-245, 2002.

FELIX, L. B.; MIRANDA DE SÁ, A. M. F. L.; INFANTOSI, A. F. C.; YEHIA, H. C., **Multivariate objective response detectors (MORD): statistical tools for multichannel EEG analysis during rhythmic stimulation.** *Annals of Biomedical Engineering*, Vol. 35 (3), pp. 443-452, 2007.

FRIEHS, G. M.; ZERRIS, V. A.; OJAKANGAS, C. L.; FELLOWS, M. R.; DONOGHUE, J. P., **Brain-Machine and Brain-Computer Interfaces .** *Stroke*, Vol. 35, pp. 2702-2705, 2004.

FUNÇÕES DO CÉREBRO.
<http://www.guia.heu.nom.br/fun%C3%A7oes_do_cerebro.htm>. Acesso em 10 de novembro de 2009.

GAO, X.; XU, D.; CHENG, M.; GAO, S., **A BCI-based environmental controller for the motion-disabled.** *IEEE Neural Systems and Rehabilitation Engineering*, Vol. 11, pp. 137-140, 2003.

GARCIA, G.; EBRAHIMI, T.; VESIN, J.-M., **Classification of EEG signals in the ambiguity domain for brain computer interface applications.** *14th International Conference on Digital Signal Processing*, Vol. 1, pp. 301- 305, 2002.

GARRETT, D.; PETERSON, D. A.; ANDERSON, C. W.; THAUT, M. H., **Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification.** *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 11 (2), pp. 141-144, 2003.

GREENSTEIN, B.; GREENSTEIN, A., **Color Atlas of Neuroscience: Neuroanatomy and Neurophysiology.** *Thieme, New York*, 2000.

GUYTON, A. C.; HALL, J. E., **Textbook of Medical Physiology.** 11 ed., Elsevier Saunders, Pensilvânia, 2006.

GYSELS, E.; CELKA, P., **Phase Synchronization for the Recognition of Mental Tasks in Brain Computer Interface.** *IEEE Trans. Neural and Rehab. Eng.*, Vol. 12 (4), pp. 406-415, 2004.

HAMMON, P. S.; SA V. R., **Preprocessing and Meta-Classification for Brain-Computer Interfaces.** *IEEE Trans. Biom. Eng.*, Vol.54 (3), pp.518-525, 2007.

HAN, J.; PARK, K.S., **Independent Component Analysis for Identification and Minimization of EOG Artifacts in EEG Recordings.** *Proceedings of the First Joint BMES/EMBS Conference.* Atlanta, EUA, Vol. 1, pp.428, 1999.

HAYKIN, S., **Redes Neurais: princípios e prática.** Trad. ENGEL, P. M.. 2.ed.,Porto Alegre: Ed. Bookman, 2001.

HELMY, S.; AL-ANI, T.; HAMAM, Y.; EL-MADBOULY, E., **P300 Based Brain-Computer Interface Using Hidden Markov Models**. *International Conference on Intelligent Sensors, Sensor Networks and Information Processing*, Sydney, pp. 127-132, 2008.

HINTERBERGER, T.; KÜBLER, A.; KAISER, J.; NEUMANN, N.; BIRBAUMER, N., **A brain-computer interface (BCI) for the locked-in: comparasion of different EEG classification for the though translation device**. *Clinical Neurophysiology*, Vol.114, p.416-425, 2003.

HIRAIWA, A.; SHIMOHARA, K.; TOKUNAGA, Y., **EEG topography recognition by neural network**. *Conference Proceedings., IEEE International Conference*, Vol.3, pp. 1116-1117, 1989.

HOFFMANN, K.; LEISTRITZ, L.; FEUCHT, M.; BENNINGER, F.; REITER, D.; WITTE, H., **Identification of the stimulated hemiretina in primary school children and adults based on left and righth hemifield pattern reversal visual evoked potentials – a comparative study**. *Clinical Neurophysiology* Vol. 112, pp. 359-368, 2001.

HOFFMANN, U.; VESIN, J. M.; EBRAHIMI, T., **Recent Advances in Brain-Computer Interfaces**. *Signal Processing Institute*. Ecole Polytechnique Federale de Lausanne (EPFL), Switzerland, 2007.

HUANG, H. S.; PAL, N.R.; KO, L.W.; LIN, C. T., **Automatic Identification of Useful Independent Components with a View to Removing Artifacts from EEG Signal**. *Proceedings of International Joint Conference on Neural Networks*, Atlanta, Georgia, 2009.

INFANTOSI, A.F.C.; MELGES, D.B.; TIERRA-CRIOLLO, C.J., **Use of magnitude-squared coherence to identify the maximum driving response band of the somatosensory evoked potential**. *Braz J Med Biol Res*, Vol.39 (12), pp. 1593-1603, 2006.

JUANG, B.-H.; RABINER, L. R., **Hidden Markov models for speech recognition**. *Technometrics*, Vol.33(3), pp. 251-272, 1991.

KALCHER, J.; PFURTSCHELLER, G., **Discrimination between phase-locked and non-phaselocked event-related EEG activity**. *Electroencephalogr. Clin. Neurophysiol.* Vol.94, pp.381- 384, 1995.

KAMOUSHI, B.; LIU, Z.; HE, B., **Classification of Motor Imagery Tasks for Brain Computer Interface Applications by Means of Two Equivalent Dipoles Analysis**. *IEEE Trans. on Neural System and Rehab. Eng.*, Vol. 13 (2), pp. 166- 171, 2005.

KANDEL, E.R.; SCHUWARTS, J.H.; JESSEL, T. M., **Princípios da Neurociência**. 4 ed., *McGraw-Hill*, Nova York, EUA, 2000.

KAPER, M.; MEINICKE, P.; GROSSEKATHOEFER, U.; LINGNER, T.; RITTER, H. **BCI Competition 2003—Data Set Iib: Support Vector Machines for the P300 Speller Paradigm**. *IEEE Transactions on Biomedical Eng.*, Vol. 51 (6), pp.1073-1076, 2004.

KREPKE, R.; CURIO, G.; BLANKERTZ, B.; MÜLLER, K. R., **Berlin Brain-Computer Interface**. The HCI communication channel for discovery. *Int. J. Human-Computer Studies*, n.65, pp.460-477, 2007.

KÜNSCH, H.; GEMAN, S.; KEHAGIAS, A., **Hidden Markov random fields**. *The Annals of Applied Probability*, Vol. 5(3), pp. 577-602, 1995.

LEE, T.W.; GIROLAMI, M.; SEJNOWSKI, T.J., **Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Sub Gaussian and Super Gaussian Sources**. *Neural Computation*, Vol.11, pp. 417-441, 1999.

LEISTRITZ, L.; HOFFMANN, K.; GALICKI, M.; WITTE, H., **Identification of hemifield single Trial PVEP on the basis of generalized dynamic neural network classifiers**. *Clinical Neurophysiology* Vol. 110, pp. 1978-1986, 1999.

LEVINE, S. P.; HUGGINS, J. E.; BEMENT S. L.; KUSHWAHA, R. K.; SCHUH, L. A.; ROHDE, M.; PASSARO, M. E. A.; ROSS, D. A.; ELISEVICH, K. V.; SMITH, B. J., **A Direct Brain Interface Based on Event-Related Potentials**. *IEEE Transactions on Rehabilitation Eng.*, Vol. 8 (2), 2000.

LIN, C.J.; HSIEH, M. H., **Classification of mental task from EEG data using neural networks based on particle swarm optimization**. *Neurocomputing Elsevier*, Vol. 72 (4-6), pp. 1121-1130, 2009.

LI, Y.; DONG, G.; GAO, X.; GAO, S.; GE, M.; YAN, W., **Single trial EEG classification during finger movement task by using hidden Markov models**. *Proceedings of the 2th International IEEE EMBS Conference on Neural Engineering Arlington, Virginia*, 2005.

LIU, H.S.; ZHANG, T.; YANG, F.S., **A Multistage, Multimethod approach for Automatic Detection and Classification of Epileptiform EEG**. *IEEE Trans. on Biomed. Eng.*, Vol.49 (12), pp. 1557 -1566, 2002.

LOTTE, F.; CONGEDO, M.; L'ECUYER, A.; LAMARCHE, F.; ARNALDI, B., **A review of classification algorithms for EEG-based brain-computer interfaces**. *Journal of Neural Engineering*, 4, R1-R13, 2007.

MADER, S. S., **Understanding Human Anatomy & Physiology**. McGraw- Hill Companies, 2004.

MELLONI, L.; MOLINA, C.; PENA, M.; TORRES, D.; SINGER, W.; RODRIGUEZ, E., **Synchronization of Neural Activity across Cortical Areas Correlates with Conscious Perception**. *The journal of Neuroscience*, Vol. 27 (11), pp. 2858- 2865, 2007.

MIDDENDORF, M. S.; McMILLAN, G.; CALHOUN, G.; JONES, K.S., **Brain-computer interfaces based on the steady-state visual-evoked response**. *Brain-Computer Interface Technology: Theory and Practice. First International Meeting Program and Papers*, The Rensselaerville Institute, Rensselaerville, New York, pp. 78-82, 1999.

MIRANDA DE SÁ, A. M. F. L.; INFANTOSI, A. F. C.; SIMPSON, D. M., **Coherence between one random and one periodic signal for measuring the strength of**

responses in the electroencephalogram during sensory stimulation. *Medical and Biological Engineering and Computing*, Vol. 40(1), pp. 99–104, 2002.

MIRANDA DE SÁ, A. M. F. L., **A note the sampling distribution of coherence estimate for the detection of periodic signals.** *Signal Processing Letters, IEEE*, Vol. 11(3), pp. 323- 325, 2004.

MIRANDA DE SÁ, A. M. F. L.; INFANTOSI, A. F. C., **Evaluating the entrainment of the alpha rhythm during stroboscopic flash stimulation by means of coherence analysis.** *Medical Engineering & Physics*, Vol. 27(2), pp. 167–173, 2005.

MIRANDA DE SÁ, A. M. F. L.; INFANTOSI, A. F. C., **Evaluating the relationship of non-phase locked activities in the electroencephalogram during intermittent stimulation: a partial coherence-based approach.** *Medical and Biological Engineering and Computing*, Vol. 45 (7), pp. 635–642, 2007.

MULLER, S.M.T.; ANDREAIO, R.V.; BOUDY, J.; GARCIA-SALICETTI, S.; FILHO, T.F.B., **Online HMM Adaptation Applied to ECG Signal Analysis.** *Industrial Electronics, 2006 IEEE International Symposium*, Vol. 1, pp. 511-514, 2006.

NEUMANN, N.; KÜBLER, A. **Training Locked-in Patients: A Challenge for the Use of Brain– Computer Interfaces.** *IEEE Trans. Neur. Syst. Rehab. Eng.*, Vol.11 (2), p.169-172, 2003.

NEUPER, C.; PFURTSCHELLER, G., **Motor imagery and ERD.** in: PFURTSCHELLER, G.; LOPES DA SILVA, F.H. (Eds.), **Event-related Desynchronization, Revised edition. Handbook. Electroencephalogr. Clin. Neurophysiol.**, Vol.6, Elsevier, pp.303-325, 1999.

NIEDEGGEN, M.; WIST, E. R., **Motion evoked brain potentials parallel the consistency of coherent motion perception in humans.** *Neuroscience Letters*, Vol. 246 (2), pp. 61-64, 1998.

NIEDMEYER, E.; LOPES DA SILVA, F., **Electroencephalography – Basic Principles, Clinical Applications, and Related Fields.** 4ed, New York, Williams&Wilkins, 1988.

NIJBOER, F.; FURDEA, A.; GUNST, I.; MELLINGER, J.; McFARLAND, D. J.; BIRBAUMER, N.; KÜBLER A., **An auditory brain–computer interface (BCI).** *Journal Neurosc. Meth.*, pp.1-8, 2007.

NIJHOLT, A.; Tan, D., **Brain-Computer Interfacing for Intelligent Systems.** *IEEE Intelligent Systems*, Vol. 23 (03), pp. 72-79, 2008.

NOVAK, D.; AI-ANI, T.; HAMAM, Y.; LHOTSKA, L., **Electroencephalogram processing using Hidden Markov Models,** *5th EUROSIM Congress on Modelling and Simulation*, Paris, 2004.

OBERMAIER, B.; NEUPER, C.; GUGER, C.; PFURTSCHELLER, G., **Information Transfer Rate in a Five-Classes Brain–Computer Interface.** *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 9 (3), pp. 283 – 288, 2001.

OBERMAIER, B.; MULLER, G. R.; PFURTSCHHELLER, G., **Virtual keyboard controlled by spontaneous EEG activity.** *IEEE Trans Neural Syst Rehabil Eng.* Vol.11, pp.422- 426, 2003.

OMIDVARNIA, A. H.; ATRY, F.; SETAREHDAN, S. K.; ARABI, B.N. **Kalman filter parameters as a new EEG feature vector for BCI applications.** *13th European Signal Processing Conference*, 2005.

OSTENDORF, M. V.; DIGALAKIS, V.; KIMBALL, O.A., **From HMMs to Segment Models: A Unified View of Stochastic Modeling for Speech Recognition.** *IEEE Trans. Speech and Audio Processing*, Vol. 4 (5), pp. 360-378, 1996.

PALANIAPPAN, R.; PARAMESRAN, R.; NISHIDA, S.; SAIWAKI, N., **A New Brain-Computer Interface Design Using Fuzzy ARTMAP.** *IEEE Transactions on Neural Systems and Rehabilitation Eng.*, Vol. 10 (3), pp. 140-148, 2002.

PALANIAPPAN, R., **Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks.** *Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering*, Arlington, Virginia, pp. 321-324, 2005.

PAPIK, K.; MOLNAR, B.; SCHAEFER, R.; DOMBOVARI, Z.; TULASSAY, Z.; FEHER, J., **Application of neural networks in medicine - a review.** *Med Sci Monit*, Vol. 4(3), pp. 538-546, 1998.

PENNY, W. D.; Roberts, S. J.; Curran, E. A.; Stokes, M. J., **EEG-based communication: A pattern recognition approach.** *IEEE Trans. Rehab. Eng.*, Vol. 8 (2), pp. 214-215, 2000.

PFURTSCHHELLER, G.; NEUPER, C.; FLOTZINGER, D.; PREGENZER, M., **EEG-based discrimination between imagination of right and left hand movement.** *Electroencephalography and clinical Neurophysiology*, Vol. 103, pp. 642-651, 1997.

PFURTSCHHELLER, G.; LOPES DA SILVA, F. H., **Event-related EEG/MEG synchronization and desynchronization: basic principles.** *Clinical Neurophysiology*, Vol.110, pp.1842-1857, 1999.

PFURTSCHHELLER, G.; NEUPER, C. **Motor imagery and direct brain-computer communication.** *Neural Engineering: Merging Engineering and Neuroscience, Proc. IEEE (Special Issue)*, Vol.89 (7), pp.1123-1134, 2001.

PFURTSCHHELLER, G.; NEUPER, C.; MÜLLER, G. R.; OBERMAIER, B.; KRAUSZ, G.; SCHLÖGL, A.; SCHERER, R.; GRAIMANN, B.; KEINRATH, C.; SKLIRIS, D.; WÖRTZ, M.; SUPP, G.; SCHRANK, C., **Graz-BCI: state of the art and clinical applications.** *IEEE Trans. Neural Syst. Rehabil. Eng.*, Vol.11, pp.177-180, 2003.

PFURTSCHHELLER, G.; BRUNNER, C.; SCHLÖGL, A.; LOPES DA SILVA, F. H., **Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery task.** *NeuroImage*, Vol.33, pp.153-159, 2006.

PFURTSCHHELLER, G.; BRUNNER, C., **The State-of-the-Art in BCIs.** *IEEE Intelligent Systems*, Vol. 23 (3), pp. 72-74, 2008.

PICCIONE, F.; GIORGI, F.; TONIN, P.; PRIFTIS, K.; GIOVE, S.; SILVONI, S.; PALMAS, G.; BEVERINA, F., **P300-based brain computer interface: Reliability and performance in healthy and paralysed participants**. *Clin. Neurophys.*, Vol.117, pp.531-537, 2006.

POPESCU, F.; BLANKERTZ, B.; MÜLLER, K. R., **Computational Challenges for Noninvasive Brain Computer Interfaces**. *IEEE Intelligent Systems*, Vol. 23 (3), pp. 78-79, 2008.

PRUTCHI, D.; NORRIS, M., **Design and development of medical electronic instrumentation: a practical perspective of the design, construction, and test of material devices**. New Jersey, John Wiley & Sons, 2005.

QIN, L.; DING, L.; HE, B., **Motor imagery classification by means of source analysis for brain-computer interface applications**. *J. Neural Eng.* Vol. 1, pp. 135-141, 2004.

RABINER L. R., **A tutorial on hidden Markov models and selected applications in speech recognition**. *Proc. IEEE*, Vol. 77, pp. 257-86, 1989.

RAMOS, E. G.; ZAYEN, E. J. B. **Detecção da Resposta Auditiva no EEG de Crianças utilizando Técnicas no Domínio da Freqüência**. *Rev. Bras. Eng. Bioméd.*, Vol. 16 (3), pp. 125-137, 2000.

ROBERT, C.; GAUDY, J.F.; LIMOGÉ, A., **Electroencephalogram processing using neural networks**. *Clinical Neurophysiology*, Vol.113, pp. 694-701, 2002.

RUGG, M. D.; COLES, M. G. H., **Electrophysiology of Mind – Event-Related Brain Potentials and Cognition**. Oxford University Press Inc., New York, 1996.

SANTOS FILHO, S.A.; TIERRA-CRIOLLO, C.J.; SOUZA, A.P.; PINTO, M.A.S.; LIMA, M.L.C.; MANZANO, G.M., **Magnitude Squared of Coherence to detect imaginary movement**. *EURASIP Journal on Advances in Signal Processing*, Vol. 2009, article ID 534536, pp.1-12, 2009.

SIMPSON, D. M.; TIERRA-CRIOLLO, C. J.; LEITE, R. T.; ZAYEN, E. J. B.; INFANTOSI, A. F. C., **Objective response detection in an electroencephalogram during somatosensory stimulation**. *Annals of Biomedical Engineering*, Vol. 28 (6), pp. 691-698, 2000.

TAKAHASHI, M.; GOUKU, M.; ITO, K., **Fundamental Research about Electroencephalogram (EEG) – Functional Electrical Stimulation (FES) Rehabilitation System**. *11th International Conference on Rehabilitation Robotics*, Kyoto, Japan, 2009.

TATUM, W. O.; HUSAIN, A. M.; BENDADIS, S. R.; KAPLAN, P. W., **Handbook of EEG interpretation**. 1 ed., Demos Medical Publishing, USA, 2007.

TAVAKOLIAN, K.; REZAEI, S., **Classification of mental tasks using Gaussian mixture Bayesian network classifiers**. *IEEE International Workshop on Biomedical Circuits and Systems*, pp. S3/6-9-11, 2004.

TAVAKOLIAN, K.; VASEFI, F.; NAZIRIPOUR, K.; REZAEI, S., **Mental Task Classification for Brain Computer Interface Applications.** *Canadian Student Conference on Biomedical Computing CSCBC 2006*, 2006.

TAYLOR, D. M.; TILLERY, S. I.; SCHWARTZ, A. B., **Direct cortical control of 3D neuroprosthetic devices.** *Science*, Vol.296, pp.1829-1832, 2000.

TIERRA-CRIOLLO, C. J., **Monitorização Objetiva da Resposta à Estimulação Somato-Sensitiva Utilizando Parâmetros Espectrais.** Tese (Doutorado em Ciências)-COPPE/UFRJ, Rio de Janeiro, Brasil, 2001.

TING, W.; GUO-ZHENG, Y.; BANG-HUA, Y.; HONG, S., **EEG feature extraction based on wavelet packet decomposition for brain computer interface.** *Measurement*, Vol. 41 (6), pp. 618-625, 2008.

VANDER, A., SHERMAN, J., & LUCIANO, D., **Human Physiology: The Mechanism of Body**, 8ª ed., McGraw-Hill, 2001.

ZEIDENBERG, M. **Neural Networks in Artificial Intelligence.** Ellis Horwood Limited, 1990.

ZHONG, S.; GHOSH, J. **HMMs and Coupled HMMs for Multi-channel EEG Classification.** *IJCNN Proceedings of the 2002 International Joint Conference on Neural Networks*, Vol. 2, pp.1154-1159, 2002.

WANG, T.; DENG, J.; HE, B., **Classifying EEG-based motor imagery tasks by means of time–frequency synthesized spatial patterns.** *Clin Neurophysiol., Elsevier*, Vol.115(12), pp. 2744-2753, 2004.

WEBSTER, J. G., **Medical Devices and Instrumentation.** 2.ed. Nova York: John Wiley & Sons, 2006.

WILKINSON, I.; LENNOX, G., **Essential Neurology.** 4 ed., *Blackwell Publishing*, 2005.

WOLPAW, J. R.; BIRBAUMER, N.; HEETDERKS, W. J.; MCFARLAND, D. J.; PECKHAM, P. H.; SCHALK, G.; DONCHIN, E.; QUATRANO, L. A.; ROBINSON, C. J.; VAUGHAN, T. M., **Brain–Computer Interface Technology: A Review of the First International Meeting.** *IEEE Trans. Rehabil. Eng.*, Vol. 8(2), pp. 164-174, 2000.

YAN, T.; JINGTIAN, T.; ANDONG, G.; WEI, W. **Classifying EEG signals based HMM-AR.** *2nd International Conference on Bioinformatics and Biomedical Engineering*, pp. 2111-2114, 2008.

YNOGUTI, C. A., **Reconhecimento de Fala Contínua usando Modelos Ocultos de Markov.** Tese de doutorado apresentada à Universidade Estadual de Campinas, Campinas, São Paulo, 1999.

YU, B.M.; RYU, S.I.; SANRHANAM, G.; CHURCHALAND, M.M.; SHENOY, K.V., **Improving Neural Prosthetic System Performance by Combining Plan and Peri-Movement Activity.** *Proceedings of the 26th Annual International Conference of the IEEE EMBS San Francisco, CA, USA*, 2004.

YUGE, S.; NING, Y.; LIHONG, Z.; XINHE, X., **Research on feature extraction Algorithms in BCI.** *Chinese Control and Decision Conference*, pp. 4294-4298, 2008.