

# DETECTOR DE COERÊNCIA E MODELOS OCULTOS DE MARKOV APLICADOS À CLASSIFICAÇÃO DE TAREFAS DE IMAGÉTICA MOTORA

Ana Paula Souza<sup>1,2</sup>, Sady Antonio dos Santos Filho<sup>2,3</sup>, Carlos Julio Tierra-Criollo<sup>2</sup>

<sup>1</sup>Universidade Federal de Viçosa – Campus Florestal, Rodovia LMG 818, Km 6, Florestal – MG – Brasil

<sup>2</sup>Núcleo de Estudos e Pesquisa em Engenharia Biomédica (NEPEB), Universidade Federal de Minas Gerais, Belo Horizonte – MG – Brasil

<sup>3</sup>Departamento de Engenharia Eletrônica, Instituto Politécnico (IPUC), Pontifícia Universidade Católica de Minas Gerais (PUC Minas), Av. D. José Gaspar, 500, 30535-901, Belo Horizonte – MG - Brasil

ana.psouza@ufv.br, sasfilho@planetarium.com.br, carjulio@cpdee.ufmg.br

**Abstract**— The most investigated stages in Brain–Computer Interface are features extraction and task classification. Thus, this work investigates the application of the coherence detector (Magnitude Squared Coherence – MSC) and the Hidden Markov Models (HMM) in the extraction of features and tasks classification, respectively. Features were extracted from electroencephalogram (EEG) in the Delta band (0.1–2 Hz), Alpha band (8–13 Hz) and Beta band (14–30 Hz) using coherence with 5% and 10% significance level ( $\alpha$ ). The EEG signals were recorded from three healthy subjects during three events: spontaneous EEG, EEG-based motor task and EEG-based motor imagination. We recorded EEG with electrodes placed according to the international 10–20 (first section) and 10–10 systems (second and third sections). HMM observations were obtained by the coherence calculated with 12 trials and the detected frequency range with higher MSC was adopted as a feature for classifier. The hit rate in classification was 72.5 %, 68 % and 65 % for subjects # 1, # 2 and # 3, respectively, using  $\alpha=5$  %. When we used  $\alpha=10$  %, the rates were 72 %, 57.5 % and 67.5 %. Results shown we can extract features from brain activities related to different events by using coherence detector and that HMM is useful in the classification of imaginary movements.

**Keywords**— Brain Machine Interface, EEG, HMM, Coherence Detector, Real Movement, Movement Imagination

## 1 Introdução

A Interface Cérebro Máquina (ICM) é um sistema que viabiliza o controle de dispositivos, estabelecendo uma forma de comunicação entre usuários e o ambiente [1]. Essa técnica pode enviar para os dispositivos comandos provenientes da atividade cerebral relacionada a tarefas cognitivas (movimento motor ou imaginação motora) e tem como alvo as pessoas que possuem algum tipo de deficiência motora, seja essa parcial (amputações) ou total - esclerose lateral amiotrófica (ELA), por exemplo [2-3].

A forma de utilizar as atividades cerebrais na comunicação é um dos problemas na implementação da ICM. Essa atividade elétrica cerebral registrada 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 relacionado ao evento (PRE), que pode ser processado pela ICM para acionamentos de dispositivos. Para registro dessas atividades uma das técnicas mais utilizadas é o eletroencefalograma (EEG). Entretanto, o EEG coletado contém outras informações, além dos PRE's, conhecidas como EEG espontâneo. Essas informações podem promover falsas detecções em ICM's e tem se tornado um desafio para as técnicas de processamento de sinais.

Dessa forma, a investigação do PRE para a comunicação em ICM exige processamento de sinais que aumentem a confiabilidade da sua detecção para reconhecimento de padrões da atividade cerebral [4], o que permitirá interpretação e tradução das atividades cerebrais em comandos [1,5]. A extração de características no EEG tem sido realizada por meio de várias técnicas, dentre as quais podemos citar: bandas de energia [6]; densidade espectral de potência [7]; características em tempo frequência [8]; modelos auto-regressivos [9-10]; e a Magnitude Quadrática da Coerência – MSC [11]. A MSC ou coerência tem se mostrado promissora, reduzindo o número de épocas necessárias para a detecção do PRE [11]. Essa técnica usa informação de energia e fase para a detecção do PRE [12], sendo a fase pouco explorada em ICM [13].

Além da escolha das características, existe uma etapa de classificação dos sinais EEG. Vários algoritmos estão sendo aplicados em ICM tais como classificadores lineares (discriminante de Fisher, K Vizinhos mais próximos -  $K$ -NN, distância de Mahalanobis), redes neurais, classificadores bayesianos não lineares (Modelos de Markov), dentre outros [5, 14]. O Modelo Oculto de Markov – HMM – é muito utilizado em reconhecimento de fala [15], e sua aplicação em ICM tem sido investigada [10].

Assim, o presente trabalho investiga o uso do detector de coerência, com níveis de significância de 5% e 10%, para extração de características de sinais EEG nas bandas delta, alfa e beta. Além disso, são avaliadas as classificações de tarefas (Movimento Real – MR, Movimento Imaginário – MI e EEG Espontâneo – ESP) utilizando o classificador HMM.

## 2 Materiais e Métodos

O EEG de três indivíduos saudáveis (21-47 anos), que não faziam uso de qualquer medicamento que pudesse interferir nos sinais foi registrado no Laboratório de Engenharia Biomédica da Universidade Federal de Minas Gerais de acordo com protocolo aprovado pelo comitê de ética local. As coletas foram realizadas com o amplificador de sinais biológicos (BrainNet de 36 canais), que possui filtro passa-alta e passa-baixa de 0,1 Hz e 100 Hz, respectivamente, filtro *notch* de 60Hz e frequência de amostragem de 600 Hz.

Foram realizadas três coletas: a primeira utilizando o sistema 10-20 e as demais utilizando 17 eletrodos posicionados conforme o sistema 10-10 (Figura1). Em todos os processos de registro os eletrodos foram referenciados aos eletrodos auriculares (média entre A1 e A2). Inicialmente, as coletas foram realizadas com o Sistema Internacional 10-20 e, após investigações, Santos Filho *et al.* (2009) verificou a existência de resposta relacionada a imagética motora na região central (eletrodos C3, Cz e C4) deste sistema. Dessa forma, com o intuito de se obter respostas mais evidentes do PRE relacionado a tarefas motoras (Movimento Real ou Imaginação de Movimento), foram realizadas novas coletas utilizando os eletrodos da região central e adjacências com a configuração do sistema 10-10 (Figura 1).

Para cada coleta o EEG foi registrado em três sessões independentes: (1) EEG espontâneo; (2) Movimento do dedo indicador da mão esquerda; (3) Imaginação do mesmo movimento. Todas as coletas foram realizadas com duração aproximada de 15 minutos e o tempo entre as tarefas foi de 14 segundos. Além disso, todas as coletas se iniciavam com 60 segundos de registro de EEG espontâneo que servia como referência para a rejeição de artefatos.

Como comando para a realização das tarefas de movimento e imaginação de movimento foram utilizados dois LEDs (Light Emitter Diodes) fixados em um painel retangular preto (30x20 cm) situado no ângulo de visão do sujeito (80 cm de seus olhos). A ordem para a execução da tarefa foi feita da seguinte forma: o LED vermelho acendia para indicar atenção; três segundos depois o LED amarelo acendia indicando preparação; um segundo após o LED amarelo estar aceso, os dois eram desligados e o sujeito era orientado a fazer a tarefa (Figura 2). Para o EEG espontâneo, no desligamento dos LEDs, os sujeitos foram orientados a permanecerem quietos e não realizarem nenhuma tarefa. O registro de EEG espontâneo foi realizado para que a resposta obtida pudesse ser comparada com os PRE's do MR e da MI.

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  $\pm 1.2$  g, afixado no dedo indicador da mão esquerda.

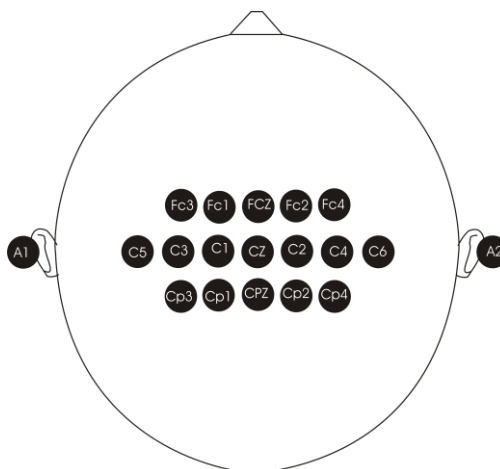


Figura 1 – Eletrodos do Sistema 10-10 utilizados para registro de EEG na 2ª e 3ª coletas.

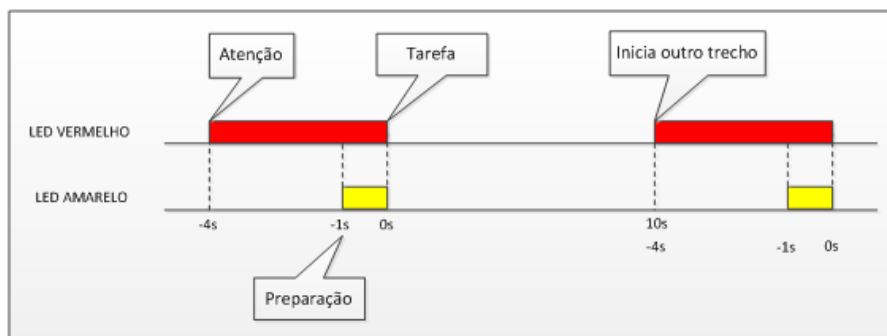


Figura 2 – Protocolo do evento: LED vermelho quando aceso indica atenção e LED amarelo indica preparação para as tarefas de movimento e imaginação de movimento. Quando os LEDs eram desligados ( $t=0s$ ) os indivíduos eram orientados a executar a tarefa.

## 2.1. Processamento

Os sinais EEG foram divididos em trechos de 14 s, como pode ser observado na Figura 2. Os trechos que possuíam artefatos foram removidos como descrito em [16].

### 2.1.1 Magnitude Quadrática da Coerência

A MSC ou coerência é uma das técnicas de Detecção Objetiva de Resposta (ORD – Objective Response Detection), apontada na literatura como uma das mais robustas, reduzindo o número de trechos necessários para a detecção do PRE [12, 17]. Essa técnica se baseia em critérios estatísticos e quantitativos e seu limiar é independente da forma de resposta [18]. Dentro das aplicações pode-se citar as detecções dos potenciais relacionados à estimulação somatossensitiva [16], à estimulação auditiva [12, 19], do PRE visual [18] e do potencial relacionado à imaginação de movimento [11].

De acordo com Dobie e Wilson (1989) a MSC é baseada na função de coerência entre dois sinais  $y[n]$  e  $x[n]$

$$\gamma_{yx}(f) = \frac{P_{yx}(f)}{\sqrt{P_{yy}(f)}\sqrt{P_{xx}(f)}} \quad (1)$$

onde  $P_{yx}(f)$  é a densidade espectral de potência cruzada e  $P_{yy}(f)$  e  $P_{xx}(f)$  são as densidades espectrais de potência individuais. Elevando ao quadrado o valor absoluto obtido pela equação 1 tem-se:

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

Para sinais ergódicos o  $\hat{\kappa}(f)$  é dado por [12, 18]:

$$\hat{\kappa}(f) = \frac{\left| \sum_{i=1}^M Y_i(f) X_i^*(f) \right|^2}{\sum_{i=1}^M |Y_i(f)|^2 \sum_{i=1}^M |X_i(f)|^2} \quad (3)$$

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, 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 [17, 18]:

$$MSC(f) = \frac{\left| \sum_{i=1}^M X_i(f) \right|^2}{M \sum_{i=1}^M |X_i(f)|^2} \quad (4)$$

Para o nível de significância desejado ( $\alpha$ ) 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 [18]

$$MSC_{crit} = 1 - \alpha^{\frac{1}{M-1}} \quad (5)$$

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  $\alpha$  é esperada em todas as frequências.

## 2.1.2 Hidden Markov Models – HMM

Segundo Rabiner (1989), os modelos ocultos de Markov podem ser descritos como um processo duplamente estocástico contendo um processo oculto – estados conectados por transições probabilísticas – e outro observável – conjunto de observações atribuído a cada estado:

- $S = \{S_1, S_2, \dots, S_N\}$  é o conjunto de estados, sendo  $N$  o número de estados do modelo e o estado em cada tempo  $t$  é dado por  $q_t$ ;
- $V = \{v_1, v_2, \dots, v_O\}$  é o conjunto de observações ( $O$  observações distintas);
- $A = \{a_{ij}\}$  é a matriz de transição dos estados, onde  $a_{ij} = P[q_{t+1} = S_j | q_t = S_i]$  ( $1 \leq i, j \leq N$ ) é a probabilidade de transição do estado  $i$  para o estado  $j$ ;
- $B$  é a matriz de probabilidades das observações. Para o HMM discreto, o número de observações é finito e a matriz de probabilidades da mesma é dada por,  $B^t = \{b_j(k)\}$ , onde  $b_j(k) = P[v_k \text{ in } t | q_t = S_j]$ ,  $1 \leq j \leq N$  e  $1 \leq k \leq O$ ;
- $\pi = \{\pi_i\}$ , onde  $\sum_i \pi_i = 1$ , é a probabilidade à priori dos estados do HMM.

Com esses parâmetros é possível obter um modelo de Markov denotado por  $\lambda = (A, B, \pi)$  e usá-lo para obter um conjunto de observações. De acordo com Rabiner (1989) existem três problemas básicos que o Modelo Oculto de Markov pode resolver:

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  $P(V|\lambda)$ .

O terceiro problema do HMM é o mais complexo. Uma alternativa para solucioná-lo é ajustar o modelo por meio das observações e com o algoritmo de Baum - Welch [7, 15]. A validação foi realizada utilizando o algoritmo de Viterbi [15], que obtém a seqüência de estados ótima usando a seqüência de observações, a matriz de transição de estados e a matriz de emissão das observações.

## 2.1.3 Processamento

Após a rejeição de trechos com artefatos, cada trecho restante foi dividido em seis segmentos que continham diferentes características do EEG, como indicado na tabela 1.

No primeiro segmento os LEDs estão apagados e o indivíduo está em repouso, sendo registrado o EEG espontâneo. Esse segmento tem duração de três segundos e, após esse intervalo, tem-se o acendimento do LED vermelho e o início do segundo segmento. O EEG registrado neste segmento tem duração de dois segundos, sendo interrompido pelo início do EEG com a visualização do LED amarelo (terceiro segmento). O terceiro segmento, por sua vez, tem duração de 1,3 segundos e, após esse intervalo, se inicia o 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 na Figura 2). Os segmentos cinco e seis são caracterizados pelo EEG espontâneo e têm duração de 2,5 segundos cada. O intervalo do segmento referente ao evento (-0,7 s até 2,0 s) foi escolhido para que o estímulo visual (LED vermelho em  $t = -4$  s e LED amarelo em  $t = -1$  s) não interferisse nos resultados (o potencial evocado vai até 125 milissegundos após o estímulo). Esses segmentos foram definidos de acordo com resultados obtidos em Santos Filho *et al* (2009).

Após a obtenção dos segmentos, foi feito o levantamento de características por meio da coerência com  $\alpha=5$  % e  $\alpha=10$  %, utilizando o número de trechos igual a 12 ( $M = 12$ ). A MSC foi aplicada aos sinais EEG dos eletrodos C3, Cz, C4, F3, Fz, F4, P3, Pz e P4 do sistema 10-20 (primeira coleta) e para os eletrodos FC3, FC1, FCz, FC2, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2 e CP4 do sistema 10-10 (2ª e 3ª coletas). Em todos os eletrodos a técnica foi avaliada para as bandas delta (0,1-2 Hz), alfa (8-13 Hz) e beta (14-30 Hz). Para cada segmento foi calculada a coerência e verificada a banda que possuísse o maior valor detectado, esta seria a observação do HMM. Em casos em que não era detectada resposta em nenhuma frequência, a característica adotada era o valor nulo.

**Tabela 1.** Intervalos de divisão dos trechos. Cada trecho foi dividido em seis segmentos com intervalos distintos.

Segmentos	Intervalos (s)	Evento
1	-7,0 até -4,0	EEG espontâneo
2	-4,0 até -2,0	EEG durante visualização do LED vermelho
3	-2,0 até -0,7	EEG durante visualização do LED amarelo
4	- 0,7 até 2,0	EEG durante o evento *
5	2,0 até 4,5	EEG espontâneo
6	4,5 até 7,0	EEG espontâneo

\*Os eventos podem ser EEG espontâneo, EEG de movimento do dedo indicador da mão esquerda e imaginação deste mesmo movimento.

Para montar o conjunto de treinamento empregaram-se todos os eletrodos da primeira coleta (sistema 10-20). Os sinais dos eletrodos da 2ª e 3ª coletas foram utilizados para validação.

### 2.1.4 Treinamento e validação usando HMM

Os seis segmentos definidos na tabela 1 foram utilizados para extrair as observações dos estados do HMM. Para cada sujeito e cada evento (EEG espontâneo, EEG da MR e da MI) foram utilizados todos os eletrodos da primeira coleta para montar o modelo. No final, cada indivíduo teve um modelo específico para cada evento. O treinamento foi realizado com o algoritmo de Baum-Welch, utilizando a coerência com  $M=12$  trechos e a validação foi realizada utilizando as coletas com o sistema 10-10 com  $M=12$  trechos. As observações do conjunto de validação (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 da probabilidade de observações dado o modelo ( $P(V/\lambda)$ ), decidia-se qual era o evento apresentado. Em todos os casos manteve-se o número de estados fixo e igual a seis.

Cada um dos sujeitos analisados possuía um sistema de classificação que foi composto pelos três modelos:  $\lambda_{MRi}$ ,  $\lambda_{MIi}$ ,  $\lambda_{ESP_i}$  ( $i=1,2$  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. Feito isso se verificou qual era a maior probabilidade ( $\log(P(V/\lambda))$ ) e classificou-se a seqüência como MI, MR ou Espontâneo. Na Figura 3 tem-se o diagrama esquemático do processo de classificação descrito acima. O índice de acerto foi calculado verificando o número de eletrodos classificados corretamente.

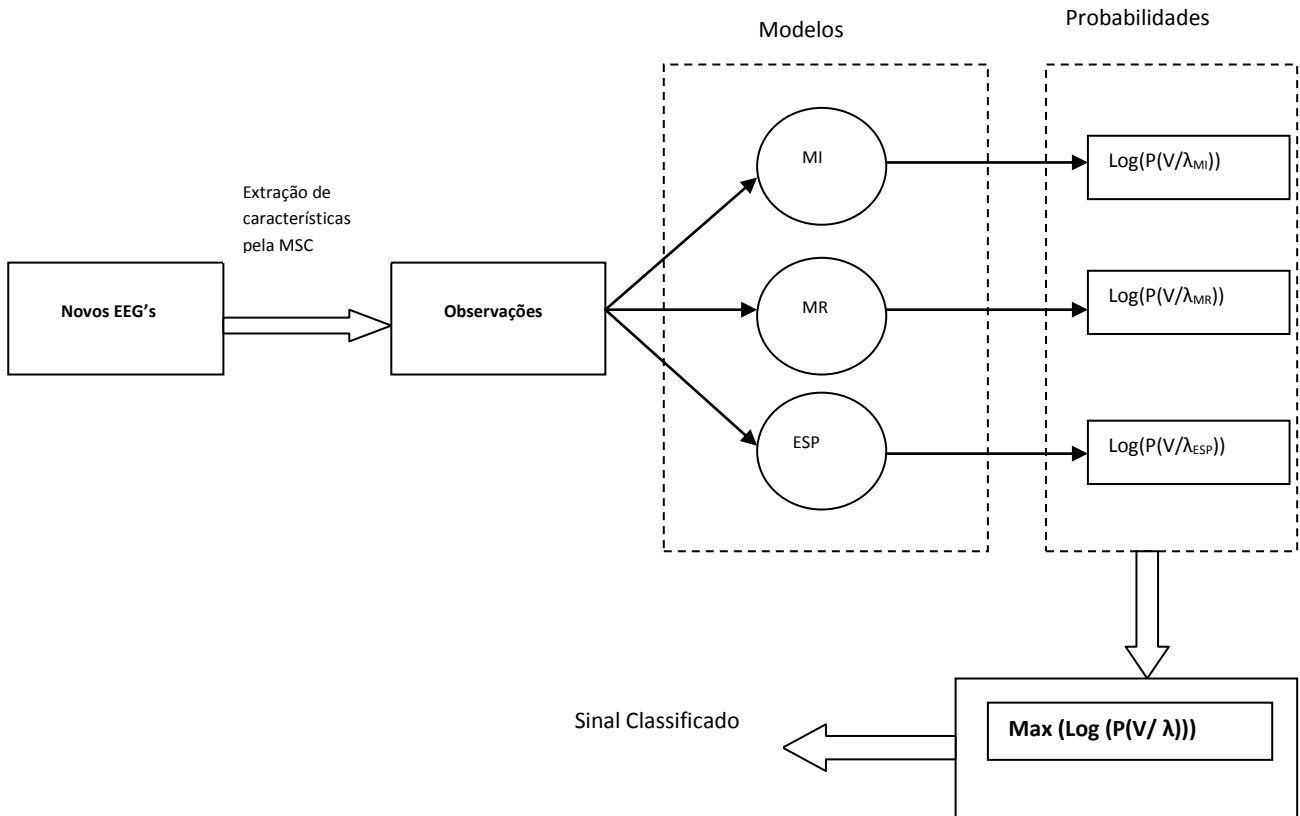


Figura 3 – Sistema de classificação dos sinais EEG usando modelos HMM.

### 3 Resultados

Para o indivíduo # 1, obtiveram-se os índices de acerto apresentados na tabela 2. Para  $\alpha=5\%$  e a segunda coleta o número de sinais dos eletrodos referentes ao EEG espontâneo (ESP), MR e MI classificados corretamente foram 67 %, 53 % e 93 %, respectivamente. Os conflitos entre imaginação e movimento totalizaram 13% na segunda coleta e 10 % na terceira. Na classificação dos sinais da 3ª coleta observou-se redução nos índices de acerto do EEG espontâneo e do movimento (53% e 38%, respectivamente). Considerando  $\alpha=10\%$  obteve-se índices de acerto inferiores, exceto para o EEG espontâneo na segunda coleta. Além disso, a porcentagem de conflitos foi maior, tanto para a segunda quanto para a terceira coleta (18% e 12%, respectivamente). Como total de acertos nota-se maior índice na segunda coleta, utilizando  $\alpha=10\%$ .

**Tabela 2.** Índices de acerto para o indivíduo # 1, utilizando  $\alpha=5\%$ ,  $\alpha=10\%$  e HMM.

	$\alpha=5\%$		$\alpha=10\%$	
	2ª coleta	3ª coleta	2ª coleta	3ª coleta
ESP	67%	53%	71%	53%
MR	53%	38%	59%	38%
MI	93%	93%	76%	76%
Conflito	13%	10%	18%	12%
Total	78%	67%	80%	64%

Para o indivíduo # 2 têm-se os resultados apresentados na tabela 3. Analisando  $\alpha=5\%$  percebeu-se que o índice de acertos somados aos conflitos foi 60 % na segunda coleta e 76 % na terceira coleta. Os conflitos totalizaram 26 % e 44 % (valor superior ao apresentado pelo indivíduo # 1). Para o mesmo indivíduo utilizando  $\alpha=10\%$ , nota-se que todos os índices, exceto o de conflitos, apresentam valores inferiores aos obtidos com  $\alpha=5\%$ . O EEG do MR não apresentou acerto e a taxa de acerto total foi maior com os sinais da terceira coleta, tanto para  $\alpha=5\%$  quanto para  $\alpha=10\%$ .

**Tabela 3.** Índices de acerto para o indivíduo # 2, utilizando  $\alpha=5\%$ ,  $\alpha=10\%$  e HMM.

	$\alpha=5\%$		$\alpha=10\%$	
	2ª coleta	3ª coleta	2ª coleta	3ª coleta
ESP	27%	50%	35%	35%
MR	0%	0%	0%	0%
MI	100%	82%	75%	71%
Conflito	26%	44%	24%	41%
Total	60%	76%	52%	63%

Para o indivíduo # 3 têm-se a tabela 4. Considerando  $\alpha=5\%$  e segunda coleta, os eletrodos do EEG espontâneo classificados corretamente representam 12 %, ao passo que o EEG do MR e o do MI apresentaram 59 % e 27 % de acerto, respectivamente. Os conflitos entre MR e MI foram de 28 % e 52%, semelhante ao obtido no indivíduo # 2. Utilizando-se  $\alpha=10\%$  para os sinais EEG deste mesmo sujeito é possível notar que não houve acerto para o EEG da MI. Além disso, os conflitos totalizaram 35% e 44 %, para a 2ª e 3ª coletas, respectivamente.

**Tabela 4.** Índices de acerto para o indivíduo # 3, utilizando  $\alpha=5\%$  e  $\alpha=10\%$  e HMM.

	$\alpha=5\%$		$\alpha=10\%$	
	2ª coleta	3ª coleta	2ª coleta	3ª coleta
ESP	12%	50%	24%	59%
MR	59%	33%	76%	88%
MI	27%	50%	0%	0%
Conflito	28%	52%	35%	44%
Total	51%	79%	57%	78%

O índice de acerto médio para os três indivíduos utilizando  $\alpha=5\%$  e  $\alpha=10\%$  está representado na tabela 5.

**Tabela 5** – Índice de acerto médio para a classificação HMM, usando  $\alpha=5\%$  e  $\alpha=10\%$ .

	$\alpha=5\%$	$\alpha=10\%$
	Taxa de acerto	Taxa de acerto
Indivíduo #1	72,5%	72,0%
Indivíduo #2	68,0%	57,5%
Indivíduo #3	65,0%	67,5%

### 4 Discussão

Esse trabalho apresentou uma investigação do uso do detector de coerência com  $\alpha=5\%$  e  $\alpha=10\%$  para extrair características do EEG. A classificação foi realizada com o HMM para três eventos: EEG espontâneo, EEG do MI e EEG do MR. Com os resultados obtidos se observa diferenças nas taxas de acerto de cada evento e também entre os indivíduos. Esse fato pode ser explicado pelas alterações nos padrões do EEG dos indivíduos, causadas por fadiga, estresse, dentre outros [20].

O acerto total foi considerado como a soma dos acertos em cada evento mais os conflitos. Isso foi assim considerado, pois a banda de frequência característica para o MR e MI é a mesma (banda delta) gerando o conflito entre os dois eventos [11]. Esse conflito pode ser 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.

Analisando a tabela 5, nota-se que o índice de acerto total é maior no indivíduo # 1, considerando  $\alpha=5\%$ , (72,5 %). Além disso, observa-se que os indivíduos # 1 e # 2 apresentaram maior índice de acerto total para  $\alpha=5\%$ . Por outro lado, avaliando-se cada evento separadamente observou-se que o maior índice de acerto foi no EEG do MI do indivíduo # 2, usando  $\alpha=5\%$  na segunda coleta (100 %).

Observando os resultados do EEG do MI, nota-se que a taxa de acertos é maior na terceira coleta de EEG realizada (exceto no indivíduo # 1, em que o valor permaneceu o mesmo). Isso é esperado, pois com o treinamento da imaginação motora, a resposta tende a ser melhor, ocasionando melhoras na detecção do PRE [21]. Para o EEG do MR a maior taxa de acerto foi de 88 %, obtida na 3ª coleta do indivíduo # 3, com  $\alpha=10\%$ . Por outro lado, avaliando-se o EEG espontâneo, observam-se taxas variadas, sendo que os indivíduos #2 e #3 apresentaram sempre maior taxa de acerto na terceira coleta, independente do  $\alpha$ .

As taxas de acerto obtidas nesse trabalho são semelhantes às encontradas na literatura, com a diferença de utilizar-se a banda delta [1, 4, 8, 14, 20]. A variação obtida na classificação dos eventos pode estar relacionada com a não execução de tarefa (MR ou MI) ou com o movimento indevido no evento de EEG espontâneo. Além disso, devido à presença de muitos artefatos, o número de trechos disponíveis para o cálculo da coerência foi reduzido o que, conseqüentemente, reduziu o número de observações para os modelos.

## 5 Conclusão

O presente trabalho investigou a utilização do detector coerência com os níveis de significância de  $\alpha=5\%$  e  $\alpha=10\%$  para extração de características do EEG. Com essas características foi possível fazer a classificação de sinais EEG durante movimento, imaginação e EEG espontâneo, usando HMM. Dessa forma, os resultados mostram que o detector MSC pode fornecer informações relevantes para a classificação do EEG durante a realização de tarefas cognitivas, principalmente na banda delta. Além disso, verificou-se que o treinamento do indivíduo aumenta a probabilidade de detecção do PRE, uma vez que, para o EEG do MI, observou-se aumento no índice de acerto na terceira coleta.

## Agradecimentos

À FAPEMIG, CAPES (Projeto PE-107) e CNPq pelo apoio financeiro.

## 6 Referências

- [1] T. Ebrahimi, J. M. VESIN, G. GARCIA, Brain computer Interface in Multimedia Communication, **IEEE Signal Processing Magazine**, 20 (2003), 14-24.
- [2] U. Hoffmann, J. M. VESIN, T. EBRAHIMI, Recent Advances in Brain-Computer Interfaces, **Signal Processing Institute. Ecole Polytechnique Federale de Lausanne (EPFL), Switzerland**, (2007).
- [3] N. J. Huan, R. Palaniappan, Neural network classification of autoregressive features from electroencephalogram signals for brain-computer interface design, **Journal of Neural Engineering**, 1 (2004), 142-150.
- [4] G. Pfurtscheller, C. Neuper, Motor imagery and direct brain-computer communication. **Neural Engineering: Merging Engineering and Neuroscience, Proc. IEEE (Special Issue)**, 89 (2001), 1123-1134.
- [5] F. Lotte, M. Congedo, A. L'Ecuyer, F. Lamarche, B. Arnaldi, A review of classification algorithms for EEG-based brain-computer interfaces, **Journal of Neural Engineering**, 4 (2007), R1-R13.
- [6] R. Palaniappan, Brain Computer Interface Design Using Band Powers Extracted During Mental Tasks, **Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering, Arlington, Virginia**, (2005), 321-324.
- [7] S. Chiappa, S. Bengio, HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems, **European Symposium on Artificial Neural Networks, Bruges, Belgium**, (2004), 199-204.
- [8] T. Wang, J. Deng, B. He, Classifying EEG-based motor imagery tasks by means of time-frequency synthesized spatial patterns, **Clinical Neurophysiology, Elsevier**, 115 (2004), 2744-2753.
- [9] D. Garrett, D. A. Peterson, C. W. Anderson, M. H. Thaut, Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification, **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, 11(2003), 141-144.
- [10] S. Rezaei, K. Tavakolian, A. M. Nasrabadi, S. K. Setarehdan, Different classification techniques considering brain computer interface applications, **Journal of Neural Engineering**, 3 (2006), 139-144.
- [11] S. A. Santos Filho, c. J. Tierra-Criollo, A. P. Souza, M. A. S. Pinto, M. L. C. Lima, G. M. Manzano, Magnitude Squared of Coherence to detect imaginary movement, **EURASIP Journal on Advances in Signal Processing**, 2009 (2009), 1-12.
- [12] R. A. Dobie, M. J. Wilson, Analysis of auditory evoked potentials by magnitude-squared coherence, **Ear and Hearing**, 10 (1989), 2-13.
- [13] D. J. Krusienski, M. G. Wentrup, F. Gal'An, D. Coyle, K. J. Miller, E. Forney, C. W. Anderson, Critical issues in state-of-the-art brain-computer interface signal processing, **Journal of Neural Engineering**, 8 (2011), 025002 (8pp).

- [14] S. Yuge, Y. Ning, Z. Lihong, X. Xinhe, Research on feature extraction Algorithms in BCI, **Chinese Control and Decision Conference**, (2008), 4294-4298.
- [15] L. R. Rabiner, A tutorial on hidden Markov models and selected applications in speech recognition, **Proc. IEEE**, 77 (1989), 257–86.
- [16] D. M. Simpson, C. J. Tierra-Criollo, R. T. Leite, E. J. B. Zayen, A. f. C. Infantosi, Objective Response Detection in an Electroencephalogram During Somatosensory Stimulation, **Annals of Biomedical Engineering**, 28 (2000), 691–698.
- [17] A. M. F. Miranda de Sá, A. F. C. Infantosi, D. M. Simpson, 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**, 40 (2002), 99–104.
- [18] A. M. F. Miranda de Sá, A. F. C. Infantosi, 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**, 45 (2007), 635–642.
- [19] L. B. Felix, J. E. Moraes, A. M. F. Miranda de Sá, H. C. Yehia, M. F. D. Moraes, Avoiding spectral leakage in objective detection of auditory steady-state evoked responses in the inferior colliculus of rat using coherence, **Journal of Neuroscience Methods**, 144 (2002), 249-245.
- [20] E. Gysels, P. Celka, Phase Synchronization for the Recognition of Mental Tasks in Brain Computer Interface, **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, 12 (2004), 406-415.
- [21] M. G. Lacourse, J. A. Turner, E. Randolph-Orr, S. L. Schandler, M. J. Cohen, Cerebral and Cerebellar Sensorimotor Plasticity Following Motor Imagery-based Mental Practice of a Sequential Movement, **Journal of Rehabilitation and Development**, 41(2004), 505-524.