

# RECONHECIMENTO DE PADRÕES DE EEG DURANTE O MOVIMENTO E IMAGINAÇÃO DO MOVIMENTO DAS MÃOS

G. N. M. S. Marilú e B. R. Marco Aurélio

Departamento de Eletrônica e Sistemas, UFPE, Recife, Brasil  
e-mail: gome.marilu@gmail.com

**Resumo:** O registro de eletroencefalograma (EEG) é uma das principais ferramentas para a Interface Cérebro Máquina (ICM). Várias técnicas têm sido propostas para identificar a dessincronização relacionada ao evento (ERD) e resincronização (ERS), que ocorre no ritmo  $\mu$  do EEG, durante o movimento e a imaginação do movimento (IM). Este trabalho teve por objetivo o desenvolvimento de técnicas e algoritmos para detecção do movimento e imaginação do movimento das mãos por meio da análise de EEG, em apenas um trecho, para futura aplicação em ICM. Os algoritmos desenvolvidos são baseados em técnicas de processamento de sinais para eliminação de artefatos biológicos, separação dos ritmos do EEG, e de detecção de padrões. Esses algoritmos usam a Transformada Wavelet (TW), Redes Neurais Artificiais (RNA) e outras ferramentas matemáticas. Utilizando uma RNA estática obteve-se uma eficiência de 49% na classificação dos eventos e com a utilização de uma RNA dinâmica obteve-se 72%. As ferramentas utilizadas são promissoras, podendo ser facilmente aplicadas na detecção de padrões da IM, tornando viável sua utilização em uma ICM.

**Palavras-chave:** Eletroencefalograma, ICM, Imaginação do Movimento, ERD e Redes neurais Artificiais.

**Abstract:** *The record electroencephalogram (EEG) is one of the main methods for Brain Machine Interface (BMI). Various techniques have been proposed to identify the event-related desynchronization (ERD) and resynchronization (ERS) that occurs in the EEG  $\mu$  rhythm during the movement and movement imagination (MI). This work aimed to develop techniques and algorithms for movement and IM of hands detection of volunteers by analysis of EEG, only using a stretch, for future application in BMI. The developed algorithm is based on signal processing techniques for the elimination of biological artifacts, separation of EEG rhythms, and detection patterns. These algorithms use Wavelet Transform (TW), Artificial Neural Networks (ANN) and other mathematical methods. Using a static ANN, it was obtained an efficiency of 49% in the classification of events and the use of dynamic RNA was obtained 72%. The methods are promising and can be easily applied in the detection of movement and MI patterns, making feasible their use in BMI.*

**Keywords:** *Electroencephalogram, BMI, Imagination Movement, ERD and Artificial Neural Networks.*

## Introdução

A atividade cerebral pode ser mapeada utilizando diferentes técnicas, por exemplo, por técnicas de captura de biopotenciais elétricos, que pode ser realizada de forma invasiva, o eletrocorticograma (ECoG), ou não invasiva, o EEG. Dentre essas técnicas, a eletroencefalografia é a mais utilizada na implementação de uma ICM por ser um método não invasivo e de fácil registro, e por utilizar um equipamento de pequeno porte e de baixo custo.

Várias técnicas têm sido propostas para identificar padrões relacionados à IM, que vem a beneficiar indivíduos que apenas possuem sua parte cognitiva preservada. Uma vertente dessas técnicas está relacionada à identificação da ERD e ERS, que ocorre no ritmo  $\mu$  do EEG, no início e fim do movimento e da IM [1]. O principal problema da maioria das técnicas, que possuem processamento *off-line* é a necessidade da análise de vários trechos do EEG [2], o que aumenta o tempo necessário para a detecção de eventos, tornando-as inviáveis para a aplicação em uma ICM em tempo real.

Desta forma, este trabalho teve por objetivo o desenvolvimento de técnicas e algoritmos para detecção do movimento e IM das mãos por meio da análise de EEG, em apenas um trecho, para futura aplicação em ICM. Principalmente, apresentar uma Rede Neural Artificial Dinâmica para a identificação desses padrões variantes no tempo.

## Materiais e métodos

A aquisição do sinal de EEG foi realizada por meio do equipamento VERTEX SC823 da Meditron, composto pelo *hardware* EEG COMPACT 723 (com filtro passa-alta e passa-baixa de 0,1 Hz e 100 Hz, respectivamente, e taxa de amostragem de 250Hz) e *software* SOMNIUM. A captura dos sinais foi realizada em 10 indivíduos saudáveis do sexo masculino e destros, na faixa etária de 18 a 40 anos, que não possuíam qualquer problema neurológico aparente e que não faziam uso de medicação que pudesse provocar alterações no sinal de EEG. A pesquisa obteve aprovação pelo Comitê de Ética e Pesquisa em Seres Humanos conforme a resolução N° 466/12 do Conselho Nacional de Saúde (CAAE - 01971812.1.0000.5208). Os eletrodos foram instalados na região de interesse (F3, F4, C3 e C4) no couro cabeludo de acordo com o

Sistema Internacional 10-20, utilizando dois eletrodos de referência, auriculares, e um eletrodo de terra, na região peri-clavicular direita (para diminuir artefato de movimento ocular). Para melhorar a condutividade, para detecção da atividade cerebral desejada no estudo, foi utilizada pasta condutora Carbofix, misturada com água, e gaze, para a fixação dos eletrodos. Os eletrodos foram fixados de forma a se obter uma impedância menor que 5k $\Omega$ .

A aquisição foi realizada de forma sincronizada, com um equipamento marcador, desenvolvido neste trabalho, que envia pulsos ao equipamento de EEG enquanto uma interface projeta telas que indicam ao voluntário o início e fim da manobra. O EEG foi registrado em dois dias para cada voluntário, com duas sessões com a mão direita e duas com a esquerda. Todas as sessões foram realizadas conforme o seguinte protocolo: (1) 10s de EEG espontâneo ou basal; (2) 1s de preparação para a atividade, em que aparece M ou I indicando o tipo de atividade, movimento ou IM respectivamente; (3) 3s de movimento ou IM da mão direita/esquerda, por flexão do punho. Conforme a sequência da Figura 1. Cada sessão teve duração de 4,83min, e foram gerados 80 registros.

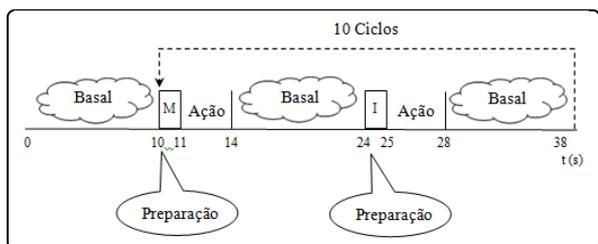


Figura 1: Procedimento do protocolo de aquisição de cada sessão.

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

**Separação dos ritmos com Wavelet** – A primeira etapa de pré-processamento realizada nos sinais de EEG adquiridos neste trabalho foi determinada pela extração de características utilizando a Transformada Wavelet Discreta (DWT), decompondo o sinal em suas aproximações e detalhes, e eliminando as componentes indesejadas. Com o objetivo de obter as frequências relacionadas aos ritmos de EEG, utilizou-se a Análise Multiresolução (AMR) realizando a decomposição em oito níveis pela DWT conforme Tabela 1. Para essa decomposição foi adotada como wavelet-mãe a Daubechies 4, muito utilizada na literatura [3]. Na Tabela 1 podem ser observadas as frequências referentes às aproximações e detalhes relacionados a cada nível de decomposição.

Após a decomposição foi realizada a reconstrução utilizando apenas os detalhes e/ou aproximações desejadas, com o objetivo de analisar apenas a faixa de frequência importante. Primeiramente, para aumentar a relação sinal ruído foram eliminados, de canal utilizado, artefatos com padrões relacionados a movimento ocular

(eletrooculograma, EOG) e muscular (eletromiograma, EMG), conforme [4]. Após a eliminação dos artefatos o sinal de EEG foi separado em seus ritmos de frequência pela reconstrução utilizando detalhes conforme a Tabela 2.

Tabela 1: Lista de frequências relacionadas a cada nível de decomposição para um sinal de 250 Hz de frequência de amostragem.

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

Tabela 2: Separação dos ritmos do EEG, pela reconstrução utilizando detalhes.

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

Como o objetivo foi detectar a dessincronização que ocorre no ritmo mi no início do movimento e IM e a resincronização que ocorre ao final, nas frequências iniciais de beta, denominado por alguns autores de beta 1, foi suficiente a reconstrução do sinal de EEG com o detalhe D4, que possui uma faixa de frequência de 8 a 16Hz, Figura 2a. Aqui, o detalhe D4 é denominado de ritmo mi, e a partir dele foi realizado o processamento para o reconhecimento do movimento e IM.

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

**Energia do sinal** – Após a obtenção do ritmo mi foi realizado o cálculo da sua energia no decorrer do tempo dentro de uma janela de tamanho, determinado experimentalmente, de 100 pontos. A janela percorre o sinal ponto a ponto realizando o cálculo da energia segundo a Equação 1:

$$E = \sum_{n=i}^{n=i+99} |x(n)|^2 \quad (1)$$

Com o cálculo da energia na banda mi, Figura 2b, é possível visualizar quando ocorre ERD no início do movimento ou IM e ERS ao final desses eventos. Ainda, do sinal de energia foi retirado seu valor médio e em seguida normalizado por seu desvio padrão.

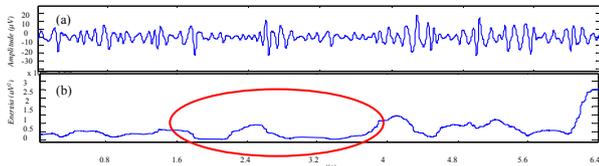


Figura 2: Em (a) Ritmo mi (D4) e (b) energia de (a).

O sinal resultante de todo o pré-processamento foi percorrido pelo algoritmo de reconhecimento de padrões que determina o instante em que ocorreu o movimento ou IM. Ainda foi realizada uma média de 10 trechos desse sinal resultante de um voluntário para o treinamento do algoritmo de reconhecimento.

Existem diversas abordagens na literatura que trata do reconhecimento do movimento e da IM na análise do EEG, por exemplo, para a identificação da IM, segundo [1] ocorre a diminuição da potência do ritmo mi. A abordagem desenvolvida por [2] utiliza Magnitude Quadrática da Coerência (MSC) para analisar o ritmo delta.

Neste trabalho foram utilizados os canais C3 e C4, para detecção do movimento e IM da mão direita e esquerda, respectivamente. Devido a maior diminuição da energia que ocorre no lado contralateral do cérebro com relação ao membro que efetuou a atividade [2]. Para a detecção foram desenvolvidas duas RNAs, uma RNA estática e uma RNA dinâmica, para o auxílio na identificação do movimento e IM por meio da análise do registro de EEG. As duas utilizam o algoritmo de treinamento supervisionado Backpropagation. Para a entrada das duas RNAs efetuou-se uma subamostragem de 20 pontos no sinal de energia para diminuir o número de pontos do padrão de entrada da rede, diminuindo o custo computacional. A taxa de amostragem passou de 250 para 12,5Hz.

**Rede Neural Estática (RNAE)** – A primeira rede desenvolvida foi a RNAE, e para seu treinamento foram utilizados cinco padrões de entrada (Figura 3), 2 padrões para a identificação de movimento ou IM, e três referentes a EEG espontâneo. A topologia da RNAE é composta de 30 neurônios na camada de entrada, duas camadas intermediárias, a primeira com 20 e a segunda com 10 neurônios, totalmente interconectados e 1 neurônio na camada de saída. A escolha de 30 neurônios na camada de entrada deve-se ao número de pontos do padrão desejado. O padrão alvo para saída da RNAE é de 0,9 para movimento ou IM e 0 para EEG espontâneo. O critério de parada para o treinamento da rede foi o somatório do erro médio quadrático total (SEQT), quando o SEQT for menor ou igual a 0,001, ou até atingir 10.000 ciclos de treinamento, o treinamento é interrompido, pois se considera que a rede “aprendeu”

com esses elementos de entrada. Tanto o critério de parada como a taxa de aprendizado foi mantida constante (0,2) para as duas redes.

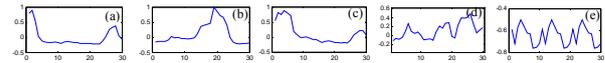


Figura 3: Padrões de treinamento para a RNAE: (a) e (c) movimento, (b), (d) e (e) EEG basal.

**Rede Neural Dinâmica (RNAD)** – A RNAD possui como entrada uma malha de atraso constituída de 40 elementos de retardo, Figura 4. Cada um destes elementos é interligado a cada um dos neurônios da camada de entrada da rede. A RNAD possui duas camadas intermediárias, a primeira com 20 neurônios totalmente interconectados com a camada de entrada, e a segunda com 10 neurônios totalmente interconectados com o único neurônio de saída.

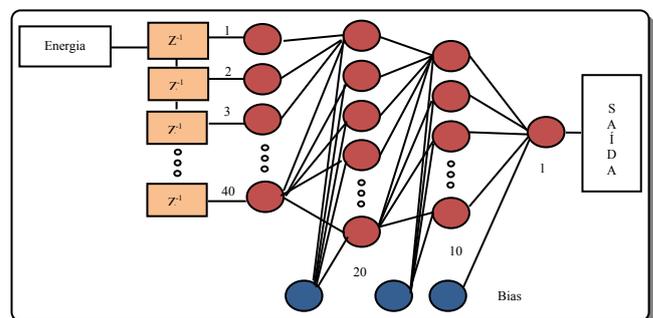


Figura 4: Estrutura da RNA dinâmica (RNAD).

A malha de atraso na entrada da RNAD faz todos os pontos do registro de EEG percorrerem cada um dos 40 neurônios de entrada da rede, sendo que, o primeiro ponto, é eliminado após o seu valor ser computado por todas as entradas da rede. Este procedimento se repete até o final do registro a ser analisado. O treinamento da rede é realizado, ponto a ponto, isto é, para cada ponto que entra na malha de atraso é realizado um treinamento pela rede. No início, entram 40 pontos e em seguida a entrada vai se deslocando e atualizando um ponto de cada vez na malha de atraso. A principal característica desta RNA é a de verificar a maneira com que os pontos variam no decorrer do tempo e não a disposição física dos pontos no plano, como é o caso da RNA estática, possibilitando desta forma a identificação de sinais variantes no tempo. Os padrões de entrada da rede, juntamente com o padrão desejado, podem ser visualizados na Figura 5. O padrão alvo, bem como o critério de parada para o treinamento da rede foi o mesmo da RNAE.

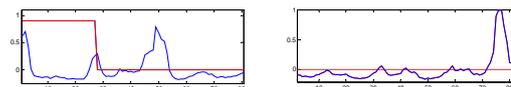


Figura 5: Em azul os sinais de entrada da RNAD e em vermelho os padrões desejados.

## Resultados

Todas as RNAs desenvolvidas foram testadas individualmente, para que se pudesse definir a mais

adequada para o reconhecimento do padrão do movimento e da IM. O padrão de movimento e IM são os mesmos diferindo apenas do EEG espontâneo. Os índices de desempenho, utilizados para a análise dos resultados obtidos pelas RNAs, foram a sensibilidade, a especificidade e a eficiência, conforme em [4]. Esses índices são calculados utilizando os seguintes indicadores: verdadeiro-positivos (VP), verdadeiro-negativos (VN), falso-positivos (FP) e falso-negativos (FN).

Apesar da RNAE ser estática o reconhecimento foi realizado de forma dinâmica, simulando um processamento *online*. Logo, a análise do sinal foi realizada em uma janela de tamanho 30 pontos que se desloca ponto a ponto no sinal. Com o intuito de analisar o valor de saída da rede foi criado um Sistema Simbólico [4] baseado em regras, a fim de identificar a presença ou não de um padrão de movimento ou IM. Neste sistema foi criado um limiar de 70%, ou seja, se a saída da rede for maior que 0,7 significa que um padrão de movimento ou IM foi encontrado.

O reconhecimento com a RNAD da mesma forma que a RNAE, ocorreu dinamicamente, simulando um processamento *online*. Logo, a análise do sinal foi realizada em uma janela de tamanho 40 pontos que se desloca ponto a ponto no sinal. No reconhecimento, os padrões de entrada identificados como atividade de movimento ou IM não necessariamente são iguais aos treinados, mas que possuam a mesma dinâmica de pontos ou similar, devido ao seu poder de generalização, colocando valores entre 0 e 0,9 de acordo com a similaridade com os padrões treinados. Com o intuito de analisar o vetor de saída da rede optou-se pela utilização da análise da média em um segmento de 10 pontos, e assim informar se o valor da média situa-se entre o valor desejado. Este valor desejado é chamado de sensibilidade da RNAD e possui a finalidade de criar um limiar na identificação destes padrões. Para essa rede foi adotado um valor de sensibilidade igual a 90%, isto é, um padrão somente irá ser identificado como padrão de movimento ou IM se a média do segmento ultrapassar um valor de 0,9. Na Figura 6 podem ser visualizados os resultados do reconhecimento realizado para dois indivíduos diferentes, ou seja, seus padrões médios não participaram do treinamento.

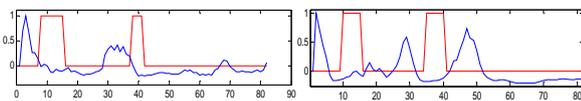


Figura 6: Exemplo de reconhecimento pela RNAD, estando em vermelho a saída da rede e em azul o sinal de entrada.

Foi gerada automaticamente uma tabela com o nome de todos os registros, bem como o resultado da análise da saída de cada rede. Foram acrescentadas colunas de análise dos dados para se obter a sensibilidade, a especificidade e a eficiência das RNAs, por meio do cálculo dos VP, VN, FP e FN. Na Tabela 3 podem ser visualizados os resultados finais da análise das duas redes.

Tabela 3: Resultado da análise das RNAs.

RNA	Sensibilidade	Especificidade	Eficiência
RNAE	82%	14%	49%
RNAD	79%	64%	72%

## Discussão

Na Tabela 3 observa-se uma maior eficiência no reconhecimento quando utilizada a RNAD em relação à RNAE. Apesar de sua menor sensibilidade, possivelmente devido ao treinamento ter sido efetuado apenas para padrões de dois voluntários, sua especificidade foi substancialmente maior que a da RNAE, ou seja, teve uma maior detecção de VN, o que significa maior qualidade no reconhecimento nos trechos de EEG basal, quando comparado a RNAE. Essa maior eficiência se deve ao treinamento que foi realizado dinamicamente, identificando os padrões de forma variante no tempo.

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

Como trabalho futuro pretende-se gerar um *feedback* em tempo real para o voluntário, para que o mesmo possa aprender a lidar com suas atividades cerebrais, e como consequência melhorar ainda mais a qualidade do reconhecimento dos padrões.

## Referências

- [1] Stecklow M V. Imagética Motora Em Tarefa Complexa: Análise Na Banda Alfa Do Eletroencefalograma, Dissertação de Mestrado, Universidade Federal Do Rio De Janeiro, Rio de Janeiro, Junho, 2006.
- [2] Santos Filho S A. Magnitude Quadrática da Coerência na Detecção da Imaginação do Movimento para Aplicação em Interface Cérebro-Máquina, Tese de Doutorado, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.
- [3] Vardhan P, Majumdar K. Automatic Seizure Detection In Ecog By DB4 Wavelets And Windowed Variance: A Comparison, In proceeding of: Communications and Signal Processing (ICCSPP), International Conference on Source: IEEE Xplore, 2011.
- [4] da Silva M G N M. Redes Neurais Artificiais Para o Reconhecimento de Padrões de EEG Durante o Movimento e Imaginação do Movimento das Mãos. Tese de Doutorado, Universidade Federal de Pernambuco, Recife, junho, 2014.
- [5] Rodrigues M A B. Sistema Para Detecção e Classificação Automática de Apnéias do Sono a Partir de Registros Polissonográficos, Tese de Doutorado, Universidade Federal de Santa Catarina, fevereiro, 2002.