

# *Reconhecendo padrões relacionados com o movimento dos dedos das mãos em sinais ECoG com o uso de Redes Neurais ARTMAP-Fuzzy*

Rhycardo Luiz Monteiro  
Departamento de Computação  
Universidade do Estado de Mato Grosso  
Cáceres-MT, Brasil  
rhycardo@unemat.br

Anna Diva Plasencia Lotufo  
Departamento de Engenharia Elétrica  
Universidade Estadual Paulista  
Ilha Solteira-SP, Brasil  
annadiva@ieee.org

Jozué Vieira Filho  
Departamento de Engenharia Elétrica  
Universidade Estadual Paulista  
Ilha Solteira-SP, Brasil  
jozuef@yahoo.com.br

**Resumo** — O reconhecimento de padrões em sinais cerebrais é essencial para a implementação de interfaces computacionais para comandar dispositivos de auxílio a indivíduos com limitações motoras. A identificação de características relacionadas com movimentos corporais, tal como o dos dedos das mãos, exige uma sequência de tarefas de filtragem, extração de características e classificação de dados do sinal. Sinais obtidos através de implantes com córtex cerebral possuem maior quantidade de informação. O uso de redes neurais artificiais do tipo ARTMAP-Fuzzy constitui uma solução eficaz para identificação de padrões no conjunto de sinais dessa natureza.

**Palavras-chave:** ECoG; Redes Neurais; ARTMAP-Fuzzy.

**Abstract** – Recognizing patterns in brain signals is essential to implement computational interfaces to command devices to aid individuals with motor limitations. Identifying characteristics related to body movements, such as the hand fingers demands a sequence of filtering tasks, extraction of characteristics and classification of signal data. Signals obtained by brain cortex implants have more information than others. Using neural networks as Fuzzy ARTMAP is a good solution to identify patterns with these kind of signals.

**Key Words:** ECoG, Neural Networks, ARTMAP fuzzy.

## I. INTRODUÇÃO

Atualmente, a Interface Cérebro-Computador (BCI)<sup>1</sup>, constitui o estado-da-arte no desenvolvimento de interfaces homem-computador. Trata-se basicamente de um sistema, hardware e software, que processa sinais elétricos oriundos da atividade cerebral e comunica padrões identificados à dispositivos externos [1]. A BCI tem sido utilizada na mobilidade a indivíduos com limitação motora, em navegação em realidade virtual, controle de exoesqueletos, robótica, jogos e etc.

A primeira evidência da relação entre a atividade elétrica cerebral e os estímulos dos sentidos foi constatada pelos estudos do físico Richard Caton em 1875 [2] e, já em 1973 Jacques Vidal conseguiu identificar movimento dos olhos baseando-se em sinais EEG (eletroencefalografia) captados por sensores no escalpo [3]. Mais recentemente, com

aperfeiçoamento dos implantes cerebrais, tornou-se possível diagnosticar também a partir de sinais ECoG (eletrocorticograma) captados por matriz de eletrodos na superfície do córtex cerebral, método considerado de baixa invasibilidade [1].

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

Esse trabalho objetiva o desenvolvimento de um modelo de tratamento de sinais ECoG, relacionados com o movimento dos dedos das mãos, o que inclui extração de características e classificação de padrões baseados no uso de redes neurais do tipo ARTMAP-Fuzzy [4], visando a uma futura utilização na implementação de BCIs.

## II. JUSTIFICATIVA

Blankertzl em [5] estima que, entre 15 e 30% dos indivíduos, as BCIs não respondem adequadamente, esses casos são conhecidos como BCI-analfabetismo. Isso ocorre provavelmente em função de alguma variação no arranjo cognitivo do cérebro, que gera um padrão dos sinais, especificamente nas frequências mais baixas, diferente do encontrado em grande parte dos indivíduos.

Segundo Wolpaw em [1], a aplicabilidade futura das BCIs está condicionada aos seguintes fatores críticos: o desenvolvimento de hardware de aquisição de sinais confortáveis, convenientes e estáveis; à validação e disseminação das BCIs e, ainda, à confiabilidade comprovada para diferentes grupos de indivíduos.

A maioria dos modelos procura capturar alterações nas características dos sinais para identificar padrões de comportamento. As pesquisas atuais apresentam soluções particulares que não podem ser estendidas a outros cenários, pois soluções abrangentes necessitariam de algoritmos que detectem particularidades e realizem adaptações de forma automática. Tal abordagem permitiria também a portabilidade do método tanto para populações e membros do corpo distintos, como para neuroimplantes (matriz de eletrodos) com

<sup>1</sup> BCI – Brain-Computer Interface

outras configurações. Esses aspectos constituem um espaço de soluções ainda a ser explorado.

### III. BCI ECoG x EEG

A imprecisão dos sinais EEG devida à mixagem dos sinais originais, quando eles passam pelas camadas de intermediárias entre o cérebro e o escalpo, e também aos ruídos dos artefatos, sugere o exame de novas proposições para atender indivíduos amputados ou lesionados. A instalação de matriz de eletrodos abaixo da dura-máter<sup>2</sup> é considerada de baixo risco e os sinais ECoG dela obtidos contém informações de maior confiabilidade.

O uso de sinais EEG tem resolução espacial reduzida, pois a informação obtida apresenta elevado grau de redundância e, apesar do baixo custo, exige um longo tempo de treinamento. Tal fato não ocorre com os sinais ECoG, que têm boa resolução espacial (distam 10mm entre si), exigindo tempo de treinamento reduzido [6].

O processamento digital de sinais de ECoG para uso em BCIs, consiste na aquisição e filtragem dos sinais, extração de características e sua posterior classificação de acordo com os padrões de comportamento definidos, conforme o fluxo apresentado em [7], adaptado para sinais ECoG, conforme a fig. 1.

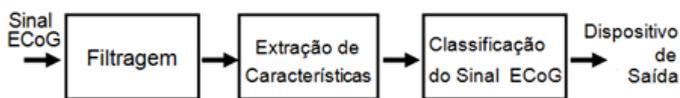


Fig. 1: Sequência de processamento de sinais em uma BCI.

### IV. PARADIGMA EXPERIMENTAL

O conjunto de dados foi obtido a partir de implante temporário, sob a dura-mater, no lado direito do cérebro, em 3 pacientes portadores de epilepsia do Harborview Hospital, Seattle nos EUA, que concordaram no registro anônimo de seções de experimentos. Todos os procedimentos satisfizeram às recomendações de ética interna e norte-americanas. Esse mesmo conjunto de dados foi disponibilizado para instituto europeu Pascal, que o tornou público para realização da 4ª versão do evento BCI Competition, em 2008 [8], originando dezenas de trabalhos, dentre os quais [9] e [10].

Cada implante continha uma matriz eletrodos de platina configurados em arranjos de 8x6 ou 8x8. O diâmetro dos eletrodos era de 4 mm (2,3mm exposto), distanciados entre si em 1 cm. O implante de cada indivíduo possui uma quantidade específica de canais variando entre 48 à 62, correspondente ao número de eletrodos. Os sinais foram adquiridos tendo como referência o couro cabeludo. Foram amostrados em 1 kHz e filtrados para uma banda passante entre 0,15 a 200 Hz.

Os indivíduos foram orientados a mover um dedo específico mediante à apresentação da palavra correspondente à sua identificação (por exemplo: "polegar") em um monitor de vídeo colocado na lateral da cama.

<sup>2</sup> dura-máter – membrana mais externa que envolve o cérebro.

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

Ao todo, foram 30 experimentos para cada dedo, e a sequência de requisição de dedos foi aleatória. A seção de experimentos durou 10 min para cada indivíduo. Uma análise posterior mostrou que o movimento do dedo anelar estava correlacionado ao movimento dos dedos médio e mínimo.

A abordagem desse trabalho considerou apenas os dados do primeiro indivíduo da base de dados.

A flexão dos dedos foi gravada utilizando luva de dados, uma interface que fornece sinais relativos ao movimento dos dedos do usuário. Os sinais da luva de dados foram amostrados em 25 Hz.

A fig. 2 ilustra os elementos e a sistemática de estímulo e registro de sinais da luva de dados e do implante no cérebro do paciente.

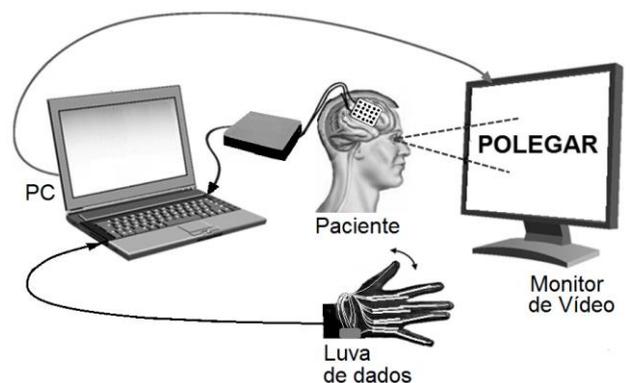


Fig. 2: Captura de sinais da flexão individual dos dedos.

### V. PRÉ-PROCESSAMENTO

#### A. Seleção de Canais

Apesar do cuidado na colocação do implante de forma a cobrir região do córtex motor direito, a operação é imprecisa. É importante identificar e selecionar os eletrodos localizados na região de interesse, pois isso resulta em precisão da informação e redução do esforço computacional.

O Teste  $t$  de Student é um teste de hipóteses paramétrico e consiste em formular uma hipótese nula ( $\mu_X = \mu_Y$ ) e uma hipótese alternativa. O cálculo do valor de  $t$  conforme (1), uma vez posicionado na curva de distribuição  $t$ , é possível determinar a densidade de probabilidade, permitindo aceitar ou rejeitar as hipóteses propostas. Em (1),  $X$  e  $Y$  denotam as amostras e  $\mu$  a média,  $S$  é a soma do quadrado dos afastamentos [11].

$$t = \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{S_{X-Y}} \quad (1)$$

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

## B. Filtragem

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

Estudos recentes apontam que as informações referentes à flexão dos dedos estão contidas em bandas de frequência específicas de ECoG, desde então, essas bandas identificadas têm sido usadas intensivamente para extração de características. A dinâmica dos sinais gerados no córtex cerebral parece correlacionar-se com uma variedade de tarefas visuais, auditivos e motoras, e compreendem: os potenciais lentos (1-60 Hz), banda gama (60-100 Hz), banda gama rápida (100-300 Hz) e agrupamento despolarizado (300-6 kHz), conforme sugerido em [12].

Outras distribuições foram obtidas também por análise espectral como em [5], entretanto, este trabalho considerou as 3 primeiras faixas identificadas pela neurologia, excluindo-se as faixas: 35-70 Hz, por refletir comprovadamente fenômenos espectrais conflitantes [13] e, 200-300Hz por ter sido excluída pela filtragem inicial.

Os filtros elípticos permitem efetuar a mais rápida transição entre a banda passante e a banda de rejeição. Esses filtros têm oscilações controladas tanto na banda passante como na banda de rejeição. A expressão em (2) representa a magnitude da resposta à frequência de um filtro elíptico passa baixa, onde  $R_n$  é uma função racional de Chebyshev de ordem  $n$ . [14].

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

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

## C. Extração de Características

O processamento desses sinais em BCIs consiste em extrair características que indiquem a intenção do usuário.

A extração de características consiste na obtenção de parâmetros que expressem ou representem o comportamento matemático dos sinais ECoG. Nesse aspecto, os métodos autorregressivos, o uso de técnicas de PCA<sup>3</sup>, estão entre as diversas técnicas utilizadas.

A análise no domínio da frequência permite evidenciar características espectrais do sinal. A transformada discreta de Fourier fornece as frequências presentes em séries temporais.

A autorregressão (AR) é o método estatístico de estimação para séries históricas. O método de Burg [15] é um modelo AR baseado na máxima entropia, utilizando um critério de mínimos quadrados. Nele, o comportamento matemático da série histórica (sinal) é caracterizado pela estimação de um número determinado de coeficientes.

Para a extração de características, nesse caso, fez-se uso de janelamento sem superposição, adotando o comprimento de

<sup>3</sup>PCA - *Principal Component Analysis*, método de análise pela escolha de formas mais representativas do conjunto.

100ms. Para uma amostragem de 1 kHz isso implica em 4.000 valores por experimento de 4 seg.

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

Para acrescentar o fator de temporariedade e evitar a sobreposição no janelamento, inseriu-se no vetor de características o valor medido no experimento anterior pela luva de dados.

Assim, no vetor de características, cada janela representa uma linha na matriz  $A$ , e tem comprimento 79. Essa dimensão pode ser considerada baixa se comparado aos demais trabalhos aqui citados.

Observando o gráfico da fig. 3 que apresenta os 10 primeiros experimentos, é possível observar que não ocorre simultaneidade de picos nos sinais relativos ao movimento dos dedos.

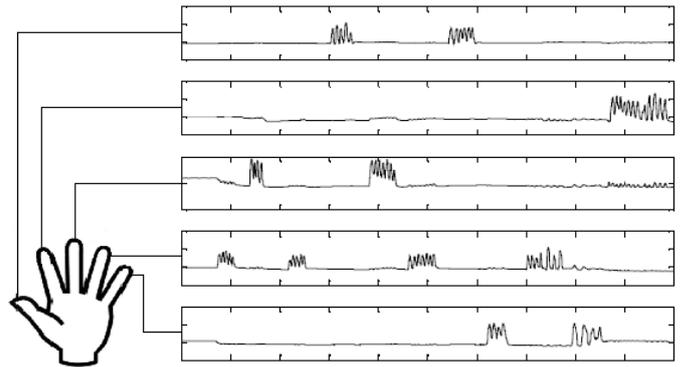


Fig. 3: Sinais da luva de dados para os 10 primeiros experimentos.

## VI. CLASSIFICAÇÃO DE PADRÕES

O tratamento matemático estatístico, as Máquinas de Vetor de Suporte (SVM) e os métodos baseados em inteligência artificial, tais como as redes neurais artificiais (RNA), aplicados às características extraídas dos sinais ECoG, são também técnicas usuais para a classificação de padrões.

### A. Teoria da Ressonância Adaptativa (ART)

Em 1987, Carpenter e Grossberg propuseram o paradigma da ressonância adaptativa, que visava realizar o processo de aprendizado de forma similar aos seres humanos, fazendo uso da heurística e da lógica de primeira ordem, baseado no conceito sobrevivência por adaptação, próprio dos seres vivos. [16].

Assim, uma rede ART busca incorporar o modelo de aprendizagem competitiva sob uma estrutura de controle auto organizável. Nesse caso, o reconhecimento e o aprendizado autônomo continuam estáveis para qualquer sequência de padrões de entrada.

Em uma rede ART, a aprendizagem ocorre quando a informação dos neurônios oscila entre as camadas da rede,

alterando seu estado de ativação até chegar a um equilíbrio (ressonância). Caso nenhuma classe ressoar com um padrão de entrada, uma nova classe é criada. O grau de similaridade pode ser controlado através de parâmetros de vigilância.

Essa capacidade de se adaptar e se reorganizar com rapidez conferiu à rede ART plasticidade de estabilidade superior aos modelos de RNA até então propostos.

A fig. 5a ilustra a arquitetura da rede ART, que é constituída de dois subsistemas: o subsistema de atenção e o subsistema de orientação, que atuam na verificação de similaridade entre um padrão presente em um neurônio treinado e um padrão apresentado, dessa forma habilitam ou não o treinamento do neurônio. [4]

O subsistema de atenção contém duas camadas de neurônios:  $F_1$ , que atua no processamento dos dados de entrada e  $F_2$ , que atua agrupando padrões de treinamento em categorias de reconhecimento.

Esses campos são conectados com pesos de conexão do tipo *feedforward* ( $w_i$ ) e *feedback* ( $w_j$ ) que são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento.

A ART deu origem a uma família de redes baseadas na mesma arquitetura. A rede ART-Fuzzy usa conjuntos e operadores difusos, cooperando com a preservação da amplitude da informação, implementando um algoritmo de classificação com rapidez de aprendizagem.

### B. Redes ARTMAP-Fuzzy

Desde que, em 1943, o neurofisiologista Warren McCulloch, do MIT, e o matemático, Walter Pits, da universidade de Illinois apresentaram a primeira proposta de neurônio artificial, baseados no funcionamento do neurônio biológico [16], um grande número de arquiteturas para redes neurais tem sido propostas.

As redes ARTMAP diferenciam-se por ser de aprendizado supervisionado e composta por dois módulos ART: a sub-rede ARTa, que recebe e processa um determinado padrão de entrada apresentado e, uma sub-rede ARTb, que constitui a resposta desejada para o padrão apresentado à rede.

Estas sub-redes são interligadas por um módulo de memória associativa, denominado Inter-ART, que realiza o mapeamento, conforme mostra a fig. 5(b). [17]

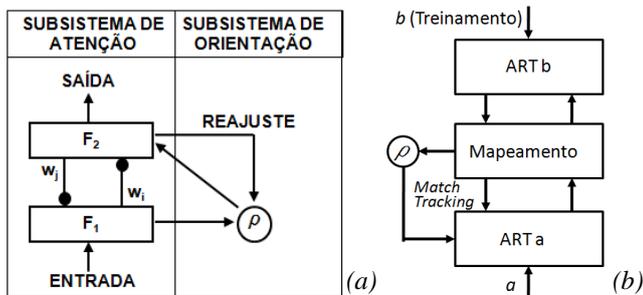


Fig. 5. Arquiteturas (a) ART e (b) ARTMAP.

A regra *match tracking* controla o incremento mínimo contínuo do parâmetro de vigilância da rede ARTa afim de corrigir um erro preditivo.

Cada módulo ART possui uma matriz de pesos associados que são inicializadas com o valor 1, situação que considera inicialmente todas as atividades como inativas.

A ocorrência de ressonância entre os padrões de entrada e saída modificam o estado dessas atividades, tornando-as ativas.

O fluxograma comentado da fig. 6 apresenta o trecho essencial para a compreensão do algoritmo de treinamento da rede ARTMAP-Fuzzy, baseados em [16]. As matrizes  $Ia$  e  $Ib$  são obtidas pela concatenação da matriz  $A$  (dados de entrada) e  $B$  (dados de saída) com seus respectivos complementos.

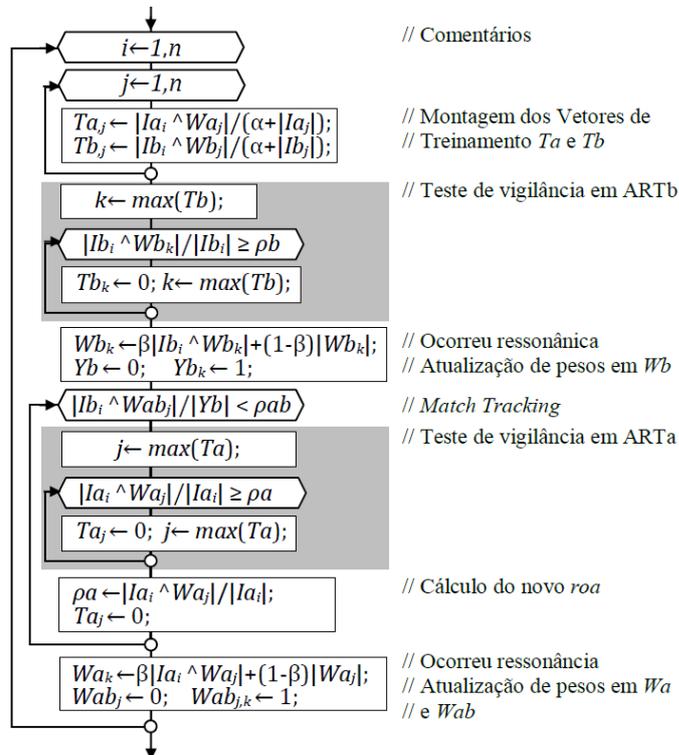


Fig. 6. Fluxograma do trecho principal de uma rede ARTMAP-Fuzzy.

Devem ser pré-definidos os parâmetros de vigilância  $roa$ ,  $rob$  e  $roa$ , o incremento de  $roa$  ( $qsi$ ) e os percentuais de atualização aplicada aos pesos:  $alfa$  e  $beta$ . Tem-se com entrada a matriz  $A$  e o vetor  $B$ , o resultado é expresso nas matrizes de peso  $Wa$ ,  $Wb$  e  $Wab$ , que serão usadas na etapa de testes. O algoritmo de teste da RNA segue o roteiro como proposto em [17]:

1. Determinar o vetores de teste  $I^a = [A \ A^c]$ , onde  $A$  contém os valores de teste;
2. Identificar o neurônio vencedor  $j_v$  da rede ARTa, sem adaptar pesos;
3. Obter  $I^b$  como em (4)
4. Separar o sinal correspondente que iria ser gerado pela luva de dados descartando apenas o complemento de  $B$ .

$$I^b \equiv W_{j_v}^{ab} W^b = [b_1 \ b_2 \ \dots \ b_{M_b} \ b_1^c \ b_2^c \ \dots \ b_{M_c}^c] \quad (4)$$

$$B = [b_1 \ b_2 \ \dots \ b_{M_b}] \quad (5)$$

### C. Aplicação e resultados.

O diagrama da fig. 7 apresenta de forma sintética, as etapas de implementação desse trabalho. Observe que os dados relativos ao movimento dos dedos também foram incluídos na composição da matriz de entrada (A) a fim de conferir o aspecto de temporariedade ao modelo, pois o conjunto físico dos dedos também atua como uma máquina de estados e tem sempre que considerar o estado anterior do dedo em questão.

Considerando a montagem da matriz para a RNA ARTMAP-Fuzzy, a partir dos dados provenientes da extração de características, foi possível montar a matriz com os dados de entrada, com dimensões 2000 x 79 para o indivíduo número 4.

Já o vetor B, como para uma primeira aproximação utilizou-se os dados correspondentes ao polegar, portanto, 1 x 2000 de comprimento. Para a fase de treinamento utilizou-se 75% dos dados e os 25% restantes, para fase de teste.

Os parâmetros de vigilância  $roa$ ,  $rob$  e  $roab$  foram inicialmente ajustados com o valor 0.95, afim de que o treinamento da rede se desse com grau elevado de aproximação com os valores obtidos. Já  $alfa$  e  $beta$  respectivamente com 0.1 e 1, são valores adotados experimentalmente. Todos esses valores representam uma aproximação inicial, podendo ser alterados em caso de não convergência no treinamento. O incremento ( $qsi$ ) adotado foi de 0.01.

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

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

Um algoritmo foi implementado para descartar os trechos redundantes, ocorrendo na maioria das vezes, em janelas adjacentes. A forma mais simples e rápida de excluí-las é comparar leituras da luva de dados e descartando as iguais.

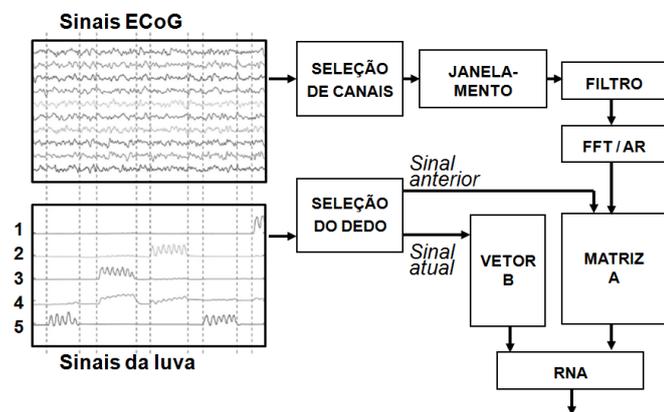


Fig. 7: Fluxograma da Extração de Características e Classificação de Padrões.

Os gráficos da fig. 8 apresentam parte dos dados de saída do sistema, relacionados com o dedo polegar, sendo que o superior mostra os dados reais registrados a partir da luva de dados e, o inferior os dados gerados a partir da RNA treinada.

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

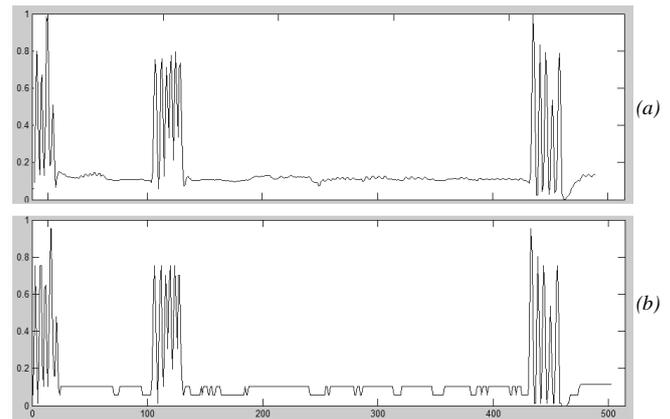


Fig. 8: Gráficos de Sinais: (a) gravado e o (b) gerado pelo modelo.

O coeficiente de correlação obtido pelo método proposto a partir de RNA ARTMAP-Fuzzy, descartando-se os trechos estáveis citados, foi de 0.94, índice bastante superior aos obtidos nos trabalhos [9], [10] e [18]. A baixa precisão nos trechos de estabilidade nos sinais (linhas horizontais no gráfico b) ocorreram devido à inexistência de padrões reconhecidos para a faixa de valores. A solução passa pelo ajuste nos parâmetros de vigilância ou a implementação de algoritmo de descarte desses trechos, já que não são de interesses.

## VII. ESTUDOS FUTUROS

A evolução nas técnicas de aquisição de sinais cerebrais certamente elevarão a resolução destes cada vez mais próximos aos ECoGs, razão pela qual se torna viável estudá-los mesmo sem a perspectiva de disseminar o uso de implantes.

É visível o envelhecimento de determinadas populações, devida à melhoria na qualidade de vida. O uso de exoesqueletos parece uma aplicação viável de BCIs desse tipo de aplicação.

Para estudos futuros sugere-se também a aplicação desta metodologia em outros cenários, a fim de certificar sua abrangência e eficácia.

Outra possibilidade a ser explorada seria o uso dos sinais no domínio do tempo no treinamento da rede, ao menos para fins de comparação. A redundância nos dados pode ser evidenciada na matriz de pesos, esse fato sugere a possibilidade de efetuar a seleção de canais relevantes, valendo-se apenas das matrizes de peso.

Inovações futuras poderão implementar de maneira interativa a alteração nos parâmetros de vigilância dentro de uma faixa de variação pré-definida.

### VIII. REFERENCIAS BIBLIOGRAFICAS

- [1] J.R. Wolpaw e E.W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. New York: Oxford University Press, 2012.
- [2] R. Caton, "The electric currents of the brain," *British Medical Journal*, vol. 2, no. 765, Aug. 1875.
- [3] J.J. Vidal, "Toward direct brain-computer communication," *Annual Review of Biophysics and Bioengineering*, vol. 2, no. 1, pp. 157-180, 1973.
- [4] G.A. Carpenter, S. Grossberg, N. Markuzon, J.H. Reynolds, e Rosen D.B., "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 698-713, 1992.
- [5] T. Dickhaus, C. Sannelli, K.R. Müller, e G. Curio, "Predicting BCI Performance to Study BCI Illiteracy," *BMC Neuroscience*, vol. 10 Suppl. 1, p. 84, 2009.
- [6] J. Kubánek, K.J. Miller, J.G. Ojemann, J.R. Wolpaw, e G. Schalk, "Decoding flexion of individual fingers using electrocorticographic signals in humans," *Journal Neural Engineering*, vol. 6, pp. 1-14, 2009.
- [7] N.A.N. Norani, W. Mansor, e L.Y. Khuan, "A Review of Signal Processing in Brain Computer Interface System," *30th Conference on Biomedical Engineering and Sciences (IECBES), 2010 IEEE EMBS*, pp. 443-449, Nov. 2010.
- [8] K.J. Miller e G. Schalk, "Prediction of Finger Flexion," in *4th Brain-Computer Interface Data Competition*, 2008, pp. 1-2.
- [9] R. Flamary e A. Rakotomamonjy, "Decoding finger movements from ECoG signals using switching linear models," in *LITIS EA 4108-INSIA*, vol. 6, Université de Rouen, Saint Etienne du Rouvray, France, 2012.
- [10] L. Bougrain e N. Liang, "Band-specific features improve Finger Flexion Prediction from ECoG," in *Jornadas Argentinas sobre Interfaces Cerebro Computadora - JAICC 2009*, Paraná, Entre Rios-Argentina, 2009, pp. 45-48.
- [11] R.C. Souza, *Modelos Estruturais para Previsão de Séries Temporais : Abordagens Clássica e Bayesiana*. Rio de Janeiro: IMPA in 170. Colóquio Brasileiro de Matemática, 1989.
- [12] J.C. Sanchez, A. Gunduz, P.R. Carney, e J.C. Principe, "Extraction and localization of mesoscopic motor control signals for human ECoG neuroprosthetics," *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 63-81, January 2008.
- [13] K.J. Miller et al., "Beyond the gamma band: the role of high-frequency features in movement classification," *IEEE Trans. Biomed. Eng.* 2008, vol. 55, no. 5, pp. 1634-7, May 2008.
- [14] A.V. Oppenheim e R.W. Schaffer, *Digital Signal Processing*. Upper Saddle River-NJ, EUA: Prentice-Hall, 1975.
- [15] J.R. Bokehi, D.M. Simpson, e A.F.C. Infantosi, "Análise Espectral de Sinais EEG utilizando Modelagem Auto-Regressiva," *Revista Brasileira de Engenharia Biomédica*, vol. 09, pp. 5-22, 1993.
- [16] M.L.M. Lopes, C.R. Minussi, e A.D.P. Lotufo, "Electric load forecasting using a fuzzy ART&ARTMAP neural network," *Applied Soft Computing*, vol. 5, no. 2, pp. 235-244, Jan. 2005.
- [17] J.G.M.S. Decanini, M.S. Tonelli-Neto, F.C.V. Malange, e C. R. Minussi, "Detection and classification of voltage disturbances using a Fuzzy-ARTMAP-wavelet network," *Electric Power Systems Research*, vol. 81, no. 12, p. 20, Dec. 2011.
- [18] Z. Wang, G. Schalk, e Q. Ji, "Anatomically Constrained Decoding of Finger Flexion from Electrocorticographic Signals," in *Advances in Neural Information Processing Systems - NIPS 2011*, Vancouver, Canada, 2011.