



UNIVERSIDADE FEDERAL DE VIÇOSA
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E PRODUÇÃO
PROJETO DE MONOGRAFIA

ANA PAULA DE SOUZA

**DETECÇÃO DE RESPOSTAS EVOCADAS NO EEG
USANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL**

VIÇOSA
MINAS GERAIS - BRASIL
DEZEMBRO/2007

ANA PAULA DE SOUZA

**DETECÇÃO DE RESPOSTAS EVOCADAS NO EEG
USANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL**

Monografia apresentada para conclusão
do curso de graduação em Engenharia
Elétrica da Universidade Federal de
Viçosa.

Orientador: Leonardo Bonato Felix

**VIÇOSA
MINAS GERAIS - BRASIL
DEZEMBRO/2007**

ANA PAULA DE SOUZA

**DETECÇÃO DE RESPOSTAS EVOCADAS NO EEG
USANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL**

Monografia apresentada para conclusão
do curso de graduação em Engenharia
Elétrica da Universidade Federal de
Viçosa.

Aprovada: 12 de dezembro de 2007.

Prof. Dr. André Gomes Torres

Prof^ª M.s. Kétia Soares Moreira

Prof. Dr. Leonardo Bonato Felix
(Orientador)

DEDICATÓRIA

*Aos meus pais, à minha irmã e aos meus tios
Ao meu noivo Gustavo*

AGRADECIMENTOS

Agradeço imensamente aos meus pais pela educação, pelos valores morais e apoio constante. Estendo ainda meus agradecimentos à minha irmã que, distante ou não, foi amiga e soube me advertir quando precisei.

Aos meus tios, pela oportunidade, pelos conselhos e amizade. Em especial ao Moacir, grande amigo que muito admiro. Sempre presente expondo oportunidades de crescimento mesmo nas ocasiões difíceis.

Ao meu noivo Gustavo, pelos vários momentos doados a esse projeto. Por ter respeitado minha ausência e pela paciência durante as crises.

Aos meus amigos, Douglas, Gleison, Marcelo e Tatiana. Companheiros de muitas noites mal dormidas, muito desespero, discussões mas, acima de tudo, amizade.

Ao meu orientador, Leonardo Bonato, pelos valiosos ensinamentos. Também pela amizade e paciência durante os instantes de desânimo.

A Priscila, Cintya e Olívia que me receberam em Viçosa, me apoiando nos primeiros percalços encontrados neste lugar.

A Paulinha, Jô e Deise que me acompanharam nos últimos três anos, trocando experiências, conselhos e risos.

“Existe uma coisa que uma longa existência me ensinou: toda a nossa ciência, comparada à realidade, é primitiva e inocente; e, portanto, é o que temos de mais valioso. “

Albert Einstein

RESUMO

O estudo de Potenciais Evocados (PEs) tem sido amplamente utilizado em vários campos da neurociência. Estes são referentes às respostas cerebrais resultantes de um estímulo externo, sendo o eletroencefalograma (EEG) simultaneamente registrado. No entanto, a análise desses registros de EEG é visual, o que a torna bastante subjetiva e demanda intensa responsabilidade do clínico que o avalia. Sendo assim, técnicas de cunho quantitativo podem auxiliar na observação desses exames. Atualmente, uma das técnicas de grande aceitabilidade é a Detecção Objetiva de Respostas (ORD) das quais se destaca a Magnitude Square Coherence (MSC) ou coerência. Essa medida, associada aos mecanismos conexionistas, como Redes Neurais Artificiais (RNAs) e *neurofuzzy*, apresenta dinamismo na solução de problemas. No presente trabalho, ambas as técnicas conexionistas foram utilizadas para identificar a taxa de detecção de 15 indivíduos normais. O EEG foi coletado quando os pacientes estavam sob foto-estimulação intermitente (FEI) com intensidade de 6 ciclos por segundo e também quando os mesmos estavam sem o estímulo. Os eletrodos analisados foram O1, O2, P3, P4, C3 e C4, sendo considerada a coerência entre dois (O1 e O2), quatro (O1, O2, P3 e P4) e seis (O1, O2, P3, P4, C3 e C4). Quando a coerência foi realizada com apenas dois canais (O1 e O2) as redes sem a presença do ritmo alfa cerebral tiveram menor erro quadrático (aproximadamente 0,002). Além disso, pudemos notar maior eficiência quando o método empregado foi a RNA, cujo coeficiente de correlação dispôs-se em torno de 0,98. Por fim, concluímos que a melhor solução do problema apresentou-se quando utilizamos redes neurais, com coerência estimada usando dois canais e sem considerar o ritmo alfa. O erro para essa configuração foi de 0,0005. Logo, verificamos que não é necessário fazer a coerência entre os seis eletrodos e o ritmo alfa não é relevante para o desempenho de detectores automáticos de respostas evocadas.

Palavras-chave: Detecção, Potencial evocado, EEG, coerência, Redes Neurais e Redes *Neurofuzzy*.

ABSTRACT

The presence of cerebral Evoked Potential (EP) has been used in many fields of neuroscience. Those are electrical manifestations of the brain's reception of and in response to an external stimulus. However, electroencephalogram's (EEG) analysis is visual and requires the subjective interpretation of the test results. Therefore, objective and quantitative techniques are required, based only in statistical criteria. The technique used in this paper to detected changes in an EEG synchronous with the stimuli is the Magnitude Square Coherence (MSC). Such a measure, that is a technique of Objective Detection of Response (ORD) class, when associated with neural and neurofuzzy networks may be helpful in EEG investigation. In this work, both networks (Neural and Neurofuzzy - Wang and Anfis) were used in order to identify the detection rate in EEG of 15 normal subjects during photic stimulation. Thus, the EEG was collected in scalp posterior regions and the stimulation frequency was 6 Hertz. The analysis is proposed using two (O1 e O2), four (O1, O2, P3 e P4) and six EEG derivations (O1, O2, P3, P4, C3 e C4). In this first case, when two EEG derivations were used, both networks showed root mean squared error near of 0,002, when cerebral alpha rhythmic wasn't evaluated. Furthermore, the neural networks implementations achieved the best results, with correlation coefficients around 0,98. Nevertheless, the suitable structure to problem's solution was the neural network, with two canals (O1 and O2) and without alpha. Such structure reached error 0,0005. Thus, the investigation with four and six derivations and cerebral alpha rhythmic weren't important at the problem proposed.

Keywords: Detection, Evoked potential, EEG, Coherence, Neural Networks and Neurofuzzy.

LISTA DE FIGURAS

Figura 1 – Modelo linear multivariável que representa o EEG durante fotoestimulação, sendo que $x[k]$ é o sinal de estimulação que será filtrado ($H_j(f)$), tendo como resultado as respostas evocadas. Os sinais EEG são representados por $y_j[k]$, que são obtidos pelo somatório das respostas evocadas com $n_j[k]$ (EEG de fundo) (MIRANDA DE SÁ et al., 2004).	19
Figura 2– Rede neural MLP com duas camadas intermediárias, m entradas e o saídas (SCIELO, 2007).	22
Figura 3 – Rede Wang com duas camadas intermediárias.	26
Figura 4 – Anfis com duas entradas (x_1 e x_2) e uma saída. A primeira etapa é a camada de fuzzificação em que cada elemento de entrada é associado a duas regras. Posteriormente temos a camada de normalização dos pesos e, por fim, a defuzzificação através das funções de pertinência de saída.	30
Figura 5 – Sistema Internacional 10 – 20, onde Fp representa a região fronto polar, C é a região central, T é a temporal, e O a occipital. As letras que são seguidas por números representam os hemisférios direito (números pares) e esquerdo (números ímpares). Já as que são seguidas pela letra z representam a linha média. Os eletrodos O1, O2, P3, P4, C3 e C4 foram os utilizados neste trabalho (TAFNER, 1999).	31
Figura 6– Sinais dos eletrodos O1 e O2 no tempo e na frequência de um paciente sob FEI.	31
Figura 7 – Características do ritmo alfa cerebral com e sem a presença da FEI. Esta avaliação é referente ao espectro do eletrodo O2 de quatro pacientes. A frequência da FEI aplicada é 6 Hertz.	32
Figura 8 – Taxa de detecção referente a dois canais (O1 e O2) de um indivíduo sob FEI.	33
Figura 9 – Taxa de detecção referente a quatro canais (O1, O2, P3 e P4) de um indivíduo sob FEI.	34
Figura 10 – Taxa de detecção referente a seis canais (O1, O2, P3, P4, C3 e C4) de um indivíduo sob FEI.	34
Figura 11 – Diagrama de blocos do detector.	36
Figura 12 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a dois eletrodos (O1 e O2) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui uma camada oculta com 5 neurônios.	37
Figura 13 – Comparação do erro de validação das redes considerando 500 iterações. A coerência é referente aos eletrodos O1 e O2 e o ritmo alfa foi tomado como parâmetro para as redes. A resposta caracterizada pelo erro revela a maior eficácia da RNA.	38
Figura 14 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a dois eletrodos (O1 e O2) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui três camadas ocultas com 1, 3 e 9 neurônios nas mesmas.	39

Figura 15 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a dois eletrodos (O1 e O2) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.....	39
Figura 16 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a quatro eletrodos (O1, O2, P3 e P4) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.....	41
Figura 17 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a quatro derivações (O1, O2, P3 e P4) com a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.	41
Figura 18 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a quatro eletrodos (O1, O2, P3 e P4) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.....	42
Figura 19 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a quatro derivações (O1, O2, P3 e P4) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.	42
Figura 20 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a seis eletrodos (O1, O2, P3, P4, C3 e C4) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.....	44
Figura 21 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a seis derivações (O1, O2, P3, P4, C3 e C4) com a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.	44
Figura 22 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a seis eletrodos (O1, O2, P3, P4, C3 e C4) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.....	45
Figura 23 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a seis derivações (O1, O2, P3, P4, C3 e C4) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.	45
Figura 24 – Disposição gráfica de todos os coeficientes de correlação obtidos durante o desenvolvimento do projeto. O gráfico explicita a redução do coeficiente de correlação à medida que aumenta-se o número de eletrodos a serem analisados.....	47

LISTA DE TABELAS

Tabela 1: Derivações utilizadas no projeto e os números aos quais as mesmas correspondem no cálculo das médias de amplitude especificados acima.	33
Tabela 2: Número de canais usados na detecção e os eletrodos associados aos mesmos, de acordo com a ordem utilizada no trabalho.	35
Tabela 3: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando duas derivações: O1 e O2. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.	40
Tabela 4: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando quatro derivações: O1, O2, P3 e P4. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.	43
Tabela 5: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando seis derivações: O1, O2, P3, P4, C3 e C4. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.	46
Tabela 6: Erros e coeficientes de correlação apresentado pelas estruturas treinadas com dois, quatro e seis eletrodos.	46

SIMBOLOGIA

ANFIS	<i>Adaptive Neurofuzzy Inference Systems</i>
EEG	Eletroencefalograma
FEI	Foto-Estimulação Intermitente
IA	Inteligência Artificial
MFs	<i>Membership Functions</i>
MLP	<i>Multi Layer Perceptron</i>
MSC	<i>Magnitude Square Coherence</i>
ORD	<i>Objective Response Detection</i>
PE	Potencial Evocado
RNAs	Redes Neurais Artificiais
SEC	Silêncio Elétrico Cerebral
TF	Transformada de Fourier

SUMÁRIO

DEDICATÓRIA	4
AGRADECIMENTOS.....	5
RESUMO.....	7
ABSTRACT.....	8
LISTA DE FIGURAS	9
LISTA DE TABELAS	11
SIMBOLOGIA	12
1. INTRODUÇÃO	14
2. OBJETIVOS.....	17
3. MATERIAIS E MÉTODOS	18
3.1 Coerência Múltipla entre o sinal de estimulação e o EEG - $\hat{\kappa}_N^2(f)$	18
3.2 Rede Neural.....	21
3.3 Rede <i>Neurofuzzy</i>	24
3.3.1 Rede Wang.....	24
3.3.2 ANFIS (<i>Adaptive Neurofuzzy Inference Systems</i>).....	27
3.4 Sinais EEG.....	30
3.5 Pré-processamento.....	32
4. RESULTADOS.....	37
5. CONCLUSÃO E DISCUSSÕES	48
6. SUGESTÕES PARA TRABALHOS FUTUROS	50
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	51

1. INTRODUÇÃO

Atualmente, o interesse pelos sinais biológicos tem se tornado cada vez mais evidente. Segundo Haykin (2001, p.29), essas análises objetivam a extração de características dos processos biológicos, promovendo o entendimento das funções e auxiliando, dessa forma, no diagnóstico e tratamento de doenças.

Diante disso, o eletroencefalograma (EEG) tem sido elemento de estudos em muitas literaturas. Tal sinal, que é o registro contínuo da atividade elétrica do córtex cerebral (TAFNER, 1999), tem por finalidade medir a intensidade do campo elétrico em conjunto com a corrente de um grupo de neurônios (HAYKIN, 2001, p.29). De forma geral, o mesmo é estabelecido, há um longo período, como auxiliar na avaliação de demências e encefalopatias, especialmente quando o diagnóstico não é conclusivo diante das avaliações clínicas iniciais (FONSECA, 2002).

Neste contexto, a análise de respostas nos registros do sinal EEG tem instigado o estudo de uma manifestação cerebral: o Potencial Evocado (PE). Tal resposta tem sido utilizada na prática clínica como um exame no qual um estímulo fixo periódico é aplicado (MIRANDA DE SÁ e FELIX, 2003). Deste modo, o PE é a resposta do cérebro diante de um estímulo externo, seja esse visual, auditivo ou somato-sensitivo (MIRANDA DE SÁ e FELIX, 2002).

Dessa forma, a apreciação dos PEs permite, por exemplo, que cirurgias envolvendo a coluna vertebral possam ser monitoradas (MIRANDA DE SÁ e FELIX, 2002) além de serem auxiliares nas análises somato-sensitivas, como apresentado por Simpson *et al.* (2000). De forma análoga, o limiar da audição pode ser determinado em recém nascidos ou em pacientes que não fornecem respostas comportamentais concisas (RAMOS *et al.*, 2000).

Outra característica observada no EEG, que é um importante indicador da vigília e também será foco de estudo neste trabalho, é o ritmo alfa cerebral. No limiar dessa condição, estando o paciente com os olhos abertos, o ritmo não é observado. Porém, quando os olhos são fechados, o mesmo se manifesta na região posterior do cérebro (HUUPPONEN *et al.*, 2001) (região occipital). Como esta é geralmente a situação dos indivíduos durante o exame de foto-estimulação intermitente (FEI) (exame estudado neste projeto) pode-se perceber no espectro do EEG destes, componentes de frequência na faixa de alfa, além das componentes advindas da estimulação. Além disso, a presença da FEI causa modificações nas características dos componentes de alfa (MIRANDA DE SÁ *et al.*, 2004), sendo também esse um dos motivos de avaliarmos tal ritmo no desempenho dos detectores.

Ao mesmo tempo, toda a análise do EEG é visual, sendo puramente dependente da experiência do profissional que o avalia. Diante disso, o uso de técnicas de detecção objetiva de respostas (ORD – *Objective Response Detection*) para automatizar o processo de detecção tem sido proposto (RAMOS *et al.*, 2000). Tais técnicas promovem o controle da razão falso positivo, mostrando-se eficiente e, na maioria dos casos, melhor que as observações humanas (SIMPSON *et al.*, 2000).

As técnicas ORD baseiam-se apenas em critérios estatísticos e quantitativos, em contraste com a avaliação subjetiva e qualitativa de um profissional médico ou técnico. As mesmas podem ser implementadas tanto no domínio do tempo quanto no da frequência, sendo que este último tem apresentado resultados encorajadores em diversas aplicações (RAMOS *et al.*, 2000).

Uma das técnicas ORD que tem sido apontada pela literatura como uma das mais eficientes na análise do EEG durante estimulação periódica é a *Magnitude Square Coherence* (MSC) ou coerência (DOBIE e WILSON, 1989). Dentre o contingente de aplicações da mesma podemos citar a análise de mudanças na distribuição parcial do EEG relacionadas com a epilepsia, agenesia do corpo caloso e outras tais como esquizofrenia e mal de Alzheimer (FERREIRA e MIRANDA DE SÁ, 2005).

Essa metodologia, que calcula a coerência entre o sinal de estimulação e o sinal EEG, neste caso, pode ser estimada considerando-se apenas o sinal EEG. Recentemente, Miranda de Sá *et al.* (2002) e Felix *et al.* (2002) propuseram a estimativa da coerência múltipla entre a estimulação e N sinais EEG objetivando o aumento da taxa de detecção para um tamanho de sinal fixo.

Contudo, a implementação dos detectores ORD demanda o uso de cálculos iterativos (como exposto na seção 3.1) e, conseqüentemente, exige poder computacional proporcional ao número de iterações. Uma alternativa interessante é o emprego de técnicas de inteligência computacional, tais como redes neurais artificiais (RNA) ou redes *neurofuzzy*, que seriam treinadas para incorporar o poder de teste dos detectores.

Levando-se em consideração as RNAs, podem ser citadas as aplicações no reconhecimento de padrões do ciclo de vigília de recém-nascidos (BOSIGNOLI e INFANTOSI, 2002), auxílio no processo de classificação de distúrbios do sono (RODRIGUES *et al.*, 1999), detecção e classificação de eventos epileptogênicos em sinais EEG (ARGOUD *et al.*, 2004), dentre outros. Já as técnicas *neurofuzzy*, no que diz respeito às informações referentes aos seres humanos,

mostram-se bastante valorizadas. As propostas vão desde o controle de eletrodomésticos até o controle do mercado financeiro e aplicações na medicina (SANDRI *et al.*, 1999).

Diante disso, considerando a faixa de frequência do ritmo alfa cerebral, fizemos a detecção de PEs, avaliando tal informação através de sistemas conexionistas (redes *neurofuzzy* e neurais). O resultado das mesmas foi comparado com finalidade de distinguir a que apresentou melhor desempenho. Em ambas, as faixas de frequência de interesse foram apresentadas, para a extração de características relevantes do espectro. Posteriormente, as redes foram treinadas sem a presença da faixa de frequência que compreende o ritmo alfa.

Logo, depois do treinamento, as redes foram capazes de fornecer o valor do detector ORD sem, no entanto, a necessidade de calculá-lo. Além disso, presumi-se que as mesmas possam incorporar dinâmicas no EEG que não são geralmente consideradas. De outro modo, utilizou-se apenas algumas faixas de espectro para treinamento, sendo desnecessário o cálculo de todo o sinal EEG na frequência. Este artifício constitui uma alternativa para implementação de técnicas ORD, sendo a resposta computacionalmente mais favorável e com a vantagem de ser adaptativa. Consequentemente, a análise promoverá uma avaliação mais rápida e não menos precisa do EEG, o que acarretará benefícios diretos à população.

Tendo em vista o apresentado, este trabalho é composto por objetivos, em que são apresentados os propósitos para tal estudo; metodologia, onde são dispostas as técnicas utilizadas; resultados alcançados diante do proposto; conclusão e discussões diante dos objetivos e dos resultados; e sugestões para trabalhos futuros.

2. OBJETIVOS

O trabalho objetivou a construção de um detector automático e objetivo de respostas visuais evocadas em sinais EEG utilizando uma abordagem conexionista com redes neurais e redes *neurofuzzy*.

As redes foram treinadas para testar a hipótese de presença ou ausência de respostas, em função de amostras de energia dos sinais EEG em faixas de frequência distintas. Além disso, ambas foram generalizadas através da influência de informação do ritmo alfa cerebral e também quando o mesmo não foi parâmetro das estruturas.

3. MATERIAIS E MÉTODOS

As técnicas estatísticas, acompanhadas de técnicas computacionais, têm sido amplamente aplicadas na engenharia biomédica, apresentando resultados satisfatórios como demonstra as bibliografias consultadas.

Neste trabalho, um detector de respostas evocadas no EEG sob foto estimulação intermitente (FEI) foi desenvolvido através de redes neurais e *neurofuzzy* (Wang e ANFIS), treinadas a partir dos valores de faixas do espectro dos sinais advindos de indivíduos sob FEI, e da taxa de detecção estimada via coerência múltipla.

O processo foi dividido nas seguintes etapas:

- Estudo das técnicas a serem empregadas;
- Pré-processamento dos dados;
- Treinamento das estruturas;
- Comparação entre os resultados.

Vale ressaltar que todo o processo utilizado no presente trabalho, objetivou a extração de características espectrais do EEG dos pacientes em questão, sendo o espectro, a distribuição de energia de um sinal em função da frequência.

3.1 Coerência Múltipla entre o sinal de estimulação e o EEG - $\hat{\kappa}_N^2(f)$

A coerência entre o sinal de estimulação e o EEG tem sido proposta como uma forma de identificar respostas evocadas no próprio EEG (FELIX *et al.*, 2004). Segundo Ferreira e Miranda de Sá (2005), a coerência é análoga ao coeficiente de correlação, porém no domínio da frequência.

Esta é uma técnica ORD que utiliza a coerência múltipla entre o sinal de estimulação, $x[k]$, e a derivação de EEG $y_j[k]$ ($j=1,2,3\dots$), para um tamanho variável do sinal (MIRANDA DE SÁ e FELIX, 2004). De acordo com Miranda de Sá *et al.* (2004), um modelo linear multivariável, como o apresentado na Fig.1, tem como estimativa de coerência de $x[k]$, considerando os sinais $y_j[k]$ ($j=1,2,3\dots,N$), a seguinte equação

$$\hat{\gamma}_{x,y_1,y_2,\dots,N}^2(f) = \frac{\hat{S}_{yx}^H(f)\hat{S}_{yy}^{-1}(f)\hat{S}_{yx}(f)}{\hat{S}_{xx}(f)}, \quad (1)$$

onde H sobrescrito é o hermitiano de uma matriz, f é a frequência, $\hat{S}_{xx}(f)$ é a estimativa do espectro de potência de $x[k]$, $\hat{S}_{yx}(f)$ é a matriz de espectro cruzado e $\hat{S}_{yy}(f)$ é a matriz de auto-espectro, sendo essas duas últimas representadas por

$$\hat{S}_{yx}(f) = \begin{bmatrix} \hat{S}_{y1x}(f) \\ \hat{S}_{y2x}(f) \\ \vdots \\ \hat{S}_{yNx}(f) \end{bmatrix}, \hat{S}_{yy}(f) = \begin{bmatrix} \hat{S}_{y1y1}(f) & \hat{S}_{y1y2}(f) & \dots & \hat{S}_{y1yN}(f) \\ \hat{S}_{y2y1}(f) & \hat{S}_{y2y2}(f) & \dots & \hat{S}_{y2yN}(f) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{S}_{yNy1}(f) & \hat{S}_{yNy2}(f) & \dots & \hat{S}_{yNyN}(f) \end{bmatrix} \quad (2)$$

na qual os termos de $\hat{S}_{yy}(f)$ podem ser assim calculados

$$\hat{S}_{ypyq}(f) = \sum_{i=1}^M Y_{pi}^*(f) Y_{qi}(f), \quad (3)$$

em que $Y_{pi}(f)$ é a Transformada de Fourier (TF) da i -ésima janela do sinal $Y_p[k]$ e o $*$ significa o conjugado complexo.

Quando $p=q$, obtemos $\hat{S}_{yy}(f)$ e $\hat{S}_{yx}(f)$ é definido por uma equação análoga a equação 3, porém substituindo-se Y_{qi} por X_i (MIRANDA DE SÁ *et al.*, 2004).




Figura 1 – Modelo linear multivariável que representa o EEG durante fotoestimulação, sendo que $x[k]$ é o sinal de estimulação que será filtrado ($H_j(f)$), tendo como resultado as respostas evocadas. Os sinais EEG são representados por $y_j[k]$, que são obtidos pelo somatório das respostas evocadas com $n_j[k]$ (EEG de fundo) (MIRANDA DE SÁ *et al.*, 2004).

Segundo Miranda de Sá *et al.* (2004), para $x[k]$ periódico e determinístico, sendo as janelas sincronizadas com o mesmo, a TF $X(f)$ terá o mesmo valor em todos os seguimentos. Dessa forma, $\hat{S}_{yx}(f)$ se dispõe da seguinte maneira

$$\hat{S}_{yx}(f) = \begin{bmatrix} \sum_{i=1}^M Y_{1i}^*(f)X(f) \\ \sum_{i=1}^M Y_{2i}^*(f)X(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}^*(f)X(f) \end{bmatrix} = X(f) \begin{bmatrix} \sum_{i=1}^M Y_{1i}^*(f) \\ \sum_{i=1}^M Y_{2i}^*(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}^*(f) \end{bmatrix} \quad (4)$$

Aplicando esse resultado na equação 1, tendo que $\hat{S}_{xx}(f) = M|X(f)|^2$, temos (MIRANDA DE SÁ *et al.*, 2004)

$$\hat{\gamma}_{x,y1,y2,\dots,N}^2(f) = \frac{\hat{S}_{yx}^H(f)\hat{S}_{yy}^{-1}(f)\hat{S}_{yx}(f)}{\hat{S}_{xx}(f)} = \frac{\begin{bmatrix} \sum_{i=1}^M Y_{1i}^*(f) \\ \sum_{i=1}^M Y_{2i}^*(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}^*(f) \end{bmatrix}^H \cdot \hat{S}_{yy}^{-1}(f) X(f) \begin{bmatrix} \sum_{i=1}^M Y_{1i}^*(f) \\ \sum_{i=1}^M Y_{2i}^*(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}^*(f) \end{bmatrix}}{M|X(f)|^2}, \quad (5)$$

Com base na expressão da estimativa da coerência múltipla, simplificações podem ser feitas, conforme indicado em Miranda de Sá *et al.* (2004), para tornar o cálculo da expressão independente do sinal de estimulação. Assim, a coerência múltipla de $x[k]$, levando-se em consideração M segmentos $yj[k]$, pode ser estimada como

$$\hat{k}_N^2(f) = \frac{V^H(f)\hat{S}_{yy}^{-1}(f)V(f)}{M}, \quad (6)$$

onde

$$V(f) = \begin{bmatrix} \sum_{i=1}^M Y_{1i}^*(f) \\ \sum_{i=1}^M Y_{2i}^*(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}^*(f) \end{bmatrix} \quad (7)$$

sendo $Y_{ni}(f)$, a TF da i -ésima janela do sinal $y_n[k]$, “*” sobrescrito, o complexo conjugado, H sobrescrito é o Hermitiano da matriz e M é o número de janelas utilizadas no cálculo da TF.

O número de segmentos utilizados no presente trabalho foi $M=12$ e os dados se dispunham amostrados na frequência de 256 Hertz. Além disso, o número de canais utilizados para a análise de coerência foram 2, 4 e 6, respectivamente.

3.2 Rede Neural

De acordo com Braga *et al.* (2000, p.1), Redes Neurais Artificiais (RNAs) são sistemas paralelos, constituídos por nodos, que são unidades simples de processamento. Esses calculam determinadas funções matemáticas que, em sua maioria são não-lineares. Cada nodo tem sua ativação promovida por um valor limiar ao qual o mesmo está associado, mimetizando o funcionamento de um neurônio biológico.

Entre os mesmos existem conexões também associadas a um número o qual chamamos de peso (ZEIDENBERG, 1990, p.15). 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, p.301).

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, p.28).

As características, segundo Bittencourt (2001), que tornam interessante a metodologia das RNAs, 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.
- A possível simulação do raciocínio, em primeira instância, é imprecisa e é realizada através da associação com a lógica nebulosa.

No trabalho proposto, utilizamos a rede com camadas intermediárias, como ilustrado na Fig.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, p.51).




Figura 2 – Rede neural MLP com duas camadas intermediárias, m entradas e o saídas (SCIELO, 2007).

O algoritmo utilizado foi o de retropropagação ou *backpropagation* que, segundo Haykin (2001, p.200), 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 encontra 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 dada por $x(n)$ e a saída $d(n)$, o campo local induzido $v_j(l)(n)$ para o neurônio j na camada l é:

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} \omega_{ji}^{(l)}(n) y_i^{(l-1)}(n) \quad (8)$$

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 :

$$\delta_j^{(l)}(n) = \{e_j^{(L)}(n) \varphi_j'\} v_j^{(L)}(n) \quad (9)$$

e, para o neurônio j da camada oculta l :

$$\delta_j^{(l)} = \varphi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) \omega_{kj}^{(l+1)}(n) \quad (10)$$

onde o apóstrofo em $\varphi_j'(\cdot)$ representa a diferenciação em relação ao argumento. O ajuste dos pesos pode ser generalizado da seguinte forma:

$$\omega_{ji}^{(l)}(n+1) = \omega_{ji}^{(l)}(n) + \alpha [\omega_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (11)$$

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 (equação 12) que retorna valores positivos compreendidos entre zero e um. Já o algoritmo de treinamento foi o Traingdx, 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.

$$f(n) = \frac{1}{1 + e^{-n}} \quad (12)$$

3.3 Rede Neurofuzzy

Segundo Medeiros *et al.* (2001), pesquisas recentes mostram grande aplicabilidade de sistemas inteligentes híbridos, que unem redes neurais e lógica *fuzzy*. Esses sistemas, por apresentarem a junção de duas técnicas, compensam as deficiências de uma com os benefícios de outra, criando, dessa forma, estruturas com amplo potencial.

Os processos envolvidos nessa proposta abrangem as etapas de *fuzzificação* e *defuzzificação*. A primeira consiste em normalizar as variáveis de entrada em um universo de discurso padronizado, transformando-os em conjuntos nebulosos que serão princípios para variáveis lingüísticas. Já a *defuzzificação* identifica o domínio das variáveis de saída em um universo de discurso correspondente (SANDRI *et al.*, 1999).

Essas redes, que são denominadas redes *neurofuzzy*, podem ser constituídas de diferentes tipos de funções de pertinência (*Memberships Functions* - MFs). Sua topologia, bem como a dimensão da mesma, deve ser baseada na complexidade do conjunto de treinamento. Uma das vantagens de se utilizar as redes *neurofuzzy* consiste na possibilidade de inicializar os parâmetros da mesma com base no conjunto de treinamento.

3.3.1 Rede Wang

Uma das redes *neurofuzzy* adotadas neste trabalho segue uma topologia que foi desenvolvida por Wang (1994, p.30). Tal rede implementa um conjunto de regras nebulosas do tipo:

$$R^{(l)} : \text{IF } x_1 \text{ is } F_1^l \text{ and } \dots \text{ and } x_n \text{ is } F_n^l, \text{ THEN } y \text{ is } G^l \quad (13)$$

onde F_i^l e G_i^l são conjuntos nebulosos, e $x = (x_1, \dots, x_n)^T$ e y são variáveis lingüísticas. A regra nebulosa é o coração do sistema lógico nebuloso, no sentido de que todas as outras componentes

são usadas para interpretar estas regras e as tornam úteis para problemas específicos (WANG, 1994, p.15).

A *defuzzificação* é um mapeamento do conjunto nebuloso para um ponto determinístico. O mapeamento utilizado neste trabalho foi a *defuzzificação* da média central (*Center Average Defuzzifier*), de acordo com Wang (1994, p.22). Assim, tem-se o seguinte lemma:

Lemma 1. Os sistemas lógicos nebulosos com *defuzzificação* da média central, regra de inferência do produto, *fuzzificação* singleton, e função de pertinência gaussiana, têm a seguinte forma:

$$f(x) = \frac{\sum_{l=1}^M y^{-l} \left[\prod_{i=1}^n \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]}{\sum_{l=1}^M \left[\prod_{i=1}^n \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \right]} \quad (14)$$

sendo \bar{x}_i^l e σ_i^l referentes às funções de pertinência gaussianas e y^{-l} é o ponto central do conjunto nebuloso descrito pela função de pertinência gaussiana correspondente.

As especificações do lemma 1 foram as utilizadas neste trabalho. Para melhor compreensão da topologia proposta, a Fig.3 apresenta o modelo descrito pela equação 13.

Como a rede demonstrada por Wang (1994) possuía apenas uma camada intermediária o que não se adequou ao problema apresentado, foram feitas implementações de modo que a rede final apresentasse duas camadas intermediárias, resultando na Fig.3.

Na referida ilustração, cada trapézio representa a seguinte equação de *fuzzificação*:

$$saida = \exp \left(- \left(\frac{x_i - \bar{x}_i^l}{\sigma_i^l} \right)^2 \right) \quad (15)$$

onde x_i é a entrada, \bar{x}_i é média dos dados de entrada e σ_i é o desvio padrão dos dados de entrada.




Figura 3 – Rede Wang com duas camadas intermediárias.

Definido o modelo, o treinamento da rede corresponde ao ajuste dos parâmetros \bar{x}_i^l , σ_i^l e y^{-l} . Supondo que temos um par de entrada-saída (x^p, d^p) , nosso objetivo é determinar um sistema lógico nebuloso $f(x)$ tal que

$$e^p = \frac{1}{2} [f(x^p) - d^p]^2 \quad (16)$$

seja minimizado. Nas equações seguintes, usaremos e , f e d para denotar e^p , $f(x^p)$ e d^p , respectivamente. Essas variáveis representam o erro, a função lógica da entrada e a saída, sucessivamente.

Os ajustes são feitos utilizando o método de retropropagação do erro (*error backpropagation procedure*), obtendo:

o algoritmo de treinamento para y^{-l} :

$$y^{-l}(k+1) = y^{-l}(k) - \alpha \frac{f-d}{b} z^l \quad (17)$$

onde y^{-l} é o peso, $l = 1, 2, \dots, M$, $k = 0, 1, 2, \dots$, α é uma constante positiva, f é a função lógica da entrada, d é a saída, z são saídas *fuzzificadas* e b é uma constante.

o algoritmo de treinamento para \bar{x}_i^l :

$$\bar{x}_i^l(k+1) = \bar{x}_i^l(k) - \alpha \frac{f-d}{b} (y^{-l} - f) z^l \frac{2(x_i^p - \bar{x}_i^l(k))}{\sigma_i^{l2}(k)} \quad (18)$$

onde \bar{x}_i é média dos dados de entrada, σ_i é o desvio padrão dos dados de entrada, $k = 0, 1, 2, \dots, l = 1, 2, \dots, M$, y^{-l} é o peso, α é uma constante positiva, f é a função lógica da entrada, d é a saída, z são saídas *fuzzificadas* e b é uma constante.

e o algoritmo de treinamento para σ_i^l :

$$\sigma_i^l(k+1) = \sigma_i^l(k) - \alpha \frac{f-d}{b} (y^{-l} - f) z^l \frac{2(x_i^p - \bar{x}_i^l(k))^2}{\sigma_i^{l3}(k)} \quad (19)$$

onde $i = 1, 2, \dots, n$, $l = 1, 2, \dots, M$, $k = 0, 1, 2, \dots$ e α é uma constante positiva.

3.3.2 ANFIS (*Adaptive Neurofuzzy Inference Systems*)

A Anfis também é uma estrutura *neurofuzzy* que tem sua rotina baseada nos métodos de inferência de Sugeno (JANG *et al.*, 1997, p.335). Tal modelo possui dois tipos de algoritmo de treinamento: híbrido e *backpropagation*, sendo ambos utilizados no presente trabalho. O treinamento híbrido propõe a união do método clássico dos mínimos quadrados com o *backpropagation*, já discutido anteriormente.

Na Fig.4, encontra-se uma estrutura Anfis com duas entradas. Na primeira camada, encontram-se as funções de pertinência de entrada, onde ocorre o processo de *fuzzificação*. Essas funções designam para cada elemento do vetor de entrada ou saída um valor que varia entre zero e um.

As MFs utilizadas neste trabalho foram seno generalizada, gaussiana, sigmoidal, trapezoidal e triangular, expressas nas equações 20, 21, 22, 23 e 24 (JANG *et al.*, 1997, p.25-26), respectivamente.

$$f(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (20)$$

onde a , b e c são os parâmetros que caracterizam a função.

$$f(x; c, \sigma) = e^{-\frac{1}{2} \left(\frac{x-c}{\sigma} \right)^2} \quad (21)$$

onde c é o centro da função de pertinência e σ é a amplitude da mesma.

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (22)$$

onde a controla a inclinação em relação ao ponto $x = c$.

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (23)$$

onde os parâmetros a, b, c e d (com $a < b \leq c < d$) são as coordenadas de x que definem o trapézio.

$$f(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (24)$$

onde os parâmetros a, b e c (com $a < b < c$) definem os três pontos do triângulo.

Consecutivamente, temos a segunda camada, representada pelo símbolo π (Fig.4), onde são associadas as regras. Nesta etapa, temos a utilização do método *and* que pode ser observado na equação 25 (JANG *et al.*, 1997, p.337). No presente trabalho, utilizamos os métodos de mínimo e probabilístico.

$$w_i = \mu_{A_i}(x_1) \cdot \mu_{B_i}(x_2) \quad (25)$$

onde μ_{A_i} e μ_{B_i} são funções de pertinência referentes às entradas e $i=1,2$.

Segundo Jang *et al.* (1997, p.336), para um sistema com n entradas e uma saída, as regras para a Anfis têm a mesma representação expressa na equação 13. Em tal passo é feita a associação dos parâmetros com as MFs.

Após a associação das regras, temos a etapa representada pelo símbolo N que relata o processo de normalização dos pesos. Nesta fase, em que é aplicado o método *or*, foram utilizadas

as técnicas probabilísticas e de máximo. A equação deste método, para uma Anfis com a estrutura disposta pela Fig.4 é dada por (JANG *et al.*, 1997, p.337)

$$\overline{w}_i = \frac{w_i}{w_1 + w_2} \quad (26)$$

onde $i=1,2$.

Nas camadas 4 e 5, ocorre o processo de *defuzzificação* com as MFs de saída e o somatório, resultando na saída esperada. O método de *defuzzificação* utilizado neste caso foi a média ponderada (*weighted average*), já como método de inferência foi utilizado o probabilista e o mínimo, sendo escolhido o que oferecia melhor resposta.

A saída fornecida pela camada 4 é representada por (JANG *et al.*, 1999, p.337)

$$S_{4i} = \overline{w}_i f_i \quad (27)$$

onde \overline{w}_i é o peso normalizado e f_i é a função de pertinência de saída.

Essas MFs de saída para o modelo de Sugeno podem ser linear ou constante e, segundo Jang *et al.* (1997, p.337) essas podem ser expressas pelas equações 28 e 29, respectivamente. Quando a mesma é constante temos um modelo *Fuzzy* de Sugeno de ordem zero e, quando linear, o modelo é de ordem um. Ambas as funções foram utilizadas neste projeto, permanecendo a que obtinha melhor desempenho para o problema apresentado.

$$f_i = (p_i x_1 + q_i x_2 + r_i) \quad (28)$$

onde $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros de consequência.

$$f_i = (r_i) \quad (29)$$

A camada 5 é obtida através da média ponderada que, de acordo com Jang *et al.* (1997, p.337) é dada por

$$Saida = \sum_i \overline{w}_i f_i \quad (30)$$

onde \overline{w}_i é o peso normalizado e f_i é a função de pertinência de saída.

Vale ressaltar que as camadas de *fuzzificação*, regras *fuzzy*, normalização e *defuzzificação*, compreendem todo o processo realizado pela Anfis e designam a camada intermediária dessa

estrutura. Dessa forma o modelo de Sugeno disponibiliza apenas uma camada oculta não permitindo ajustes.

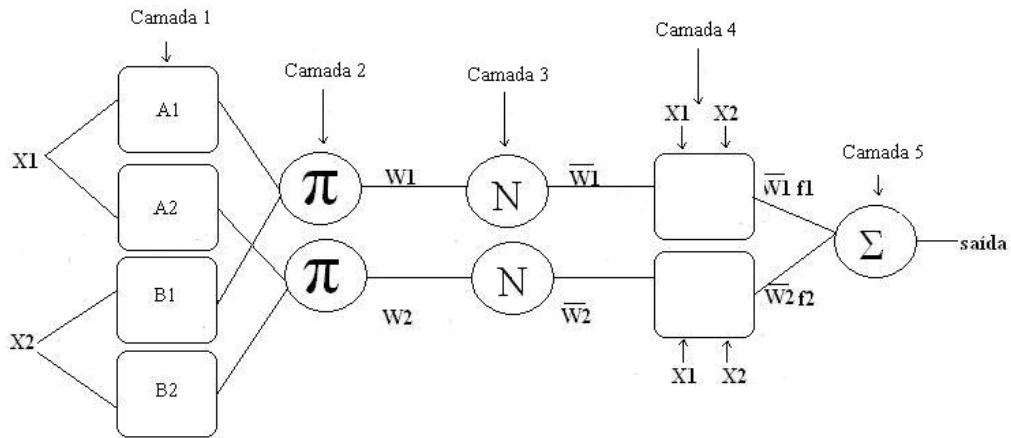


Figura 4 – Anfis com duas entradas (x_1 e x_2) e uma saída. A primeira etapa é a camada de *fuzzificação* em que cada elemento de entrada é associado a duas regras. Posteriormente temos a camada de normalização dos pesos e, por fim, a *defuzzificação* através das funções de pertinência de saída.

3.4 Sinais EEG

Os dados utilizados foram fornecidos pelo professor Antonio M. F. L. Miranda de Sá e são referentes ao EEG de 15 pacientes normais submetidos à FEI. O estímulo foi aplicado aos indivíduos na frequência de 6 ciclos por segundo durante aproximadamente 25 segundos, sendo o EEG sem estimulação coletado por igual período, nos mesmos pacientes.

Essas informações, após pré-processamento, embasaram o treinamento das redes neurais (Fig.2), Wang (Fig.3) e Anfis (Fig.4) com vistas a obter uma metodologia alternativa para a detecção de respostas no EEG. Para isto, fizemos uma extração de características do espectro de potência do EEG das derivações O1, O2, P3, P4, C3 e C4, cuja disposição está ilustrada na Fig.5.

A escolha de tais derivações é fundamentada no fato de que as mesmas se situam sobre o córtex visual (O1 e O2) ou nas proximidades do mesmo (demais eletrodos), onde se espera respostas evocadas mais intensas.

Os sinais das derivações O1 e O2, no tempo e na frequência, de um determinado paciente sob FEI podem ser observados na Fig.6. Os espectros foram obtidos utilizando a função de densidade espectral. A partir da figura podemos notar uma intensidade relevante do espectro na frequência de estimulação.

Além disso, como durante o exame os indivíduos se encontram de olhos fechados temos a presença do ritmo alfa cerebral. Baseando-se neste fato e também na interferência causada pela FEI neste ritmo (Fig.7), o mesmo foi avaliado de forma a verificar o desempenho do detector diante de sua presença ou ausência. Essa interferência pode ser claramente observada na Fig.7, em que se encontram os espectros de quatro pacientes sobre fotoestimulação.

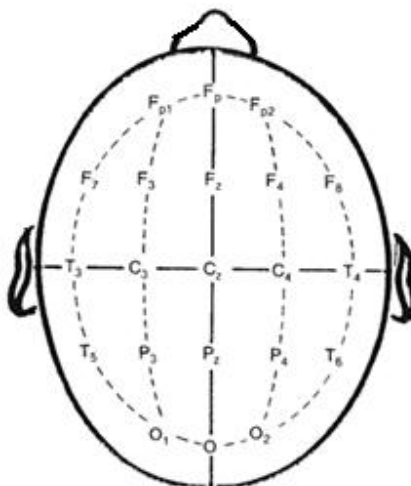


Figura 5 – Sistema Internacional 10 – 20, onde Fp representa a região fronto polar, C é a região central, T é a temporal, e O a occipital. As letras que são seguidas por números representam os hemisférios direito (números pares) e esquerdo (números ímpares). Já as que são seguidas pela letra z representam a linha média. Os eletrodos O1, O2, P3, P4, C3 e C4 foram os utilizados neste trabalho (TAFNER, 1999).

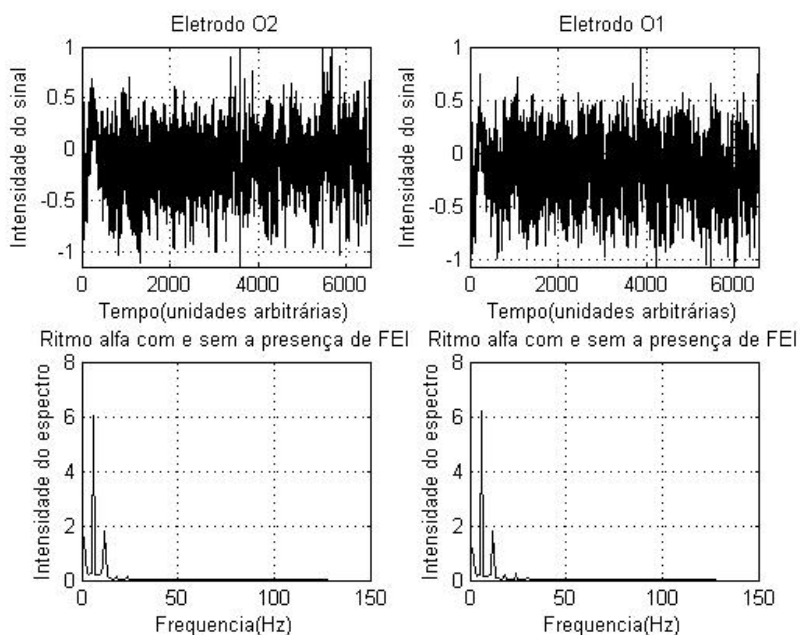


Figura 6 – Sinais dos eletrodos O1 e O2 no tempo e na frequência de um paciente sob FEI.

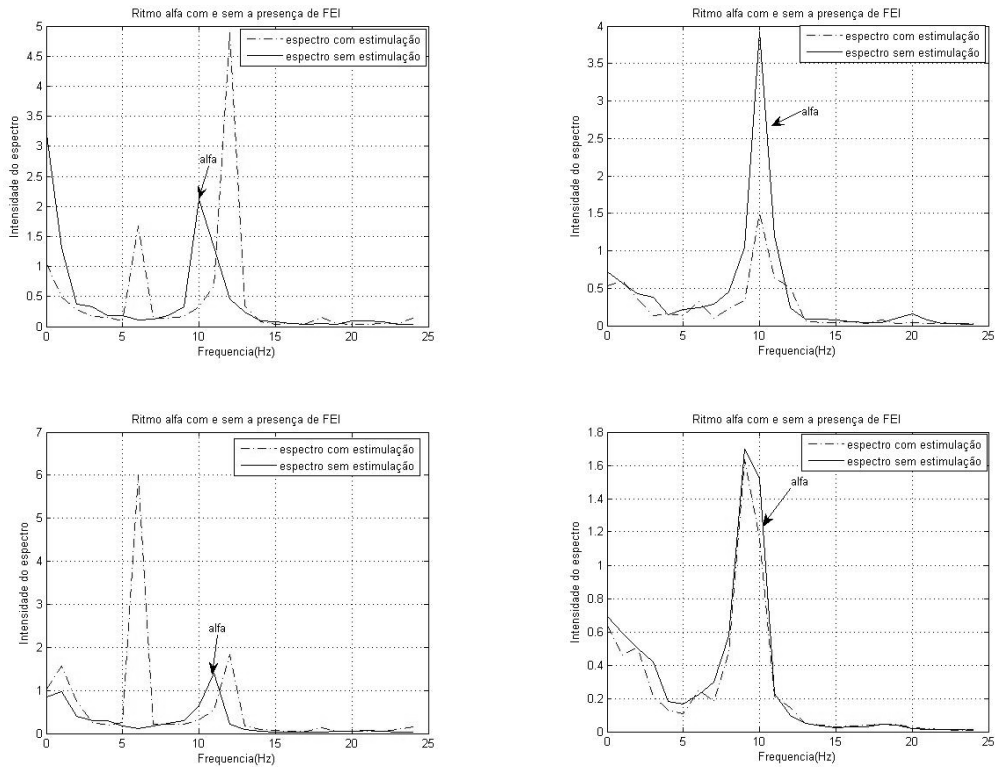


Figura 7 – Características do ritmo alfa cerebral com e sem a presença da FEI. Esta avaliação é referente ao espectro do eletrodo O2 de quatro pacientes. A frequência da FEI aplicada é 6 Hertz.

3.5 Pré-processamento

A extração de características teve como cerne o fato de que é esperado um acréscimo de energia no espectro em torno da frequência de estimulação (6 ciclos por segundo), como observado na Fig.6. Portanto, os valores de características M_{ij} foram obtidos através do espectro de potência dos eletrodos para quatro conjuntos de frequência em cada eletrodo, como se segue, considerando o ritmo alfa como parâmetro das redes:

M_{i1} : média das amplitudes do espectro de i nas frequências (4 – 5 Hz);

M_{i2} : média das amplitudes do espectro de i nas frequências (6 – 7 Hz);

M_{i3} : média das amplitudes do espectro de i na faixa de frequência (8– 10 Hz);

M_{i4} : média das amplitudes do espectro de i na faixa de frequência (11 – 13 Hz);

Quando o ritmo alfa não foi considerado, as entradas tiveram uma pequena alteração, como pode ser observado:

M_{i1} : média das amplitudes do espectro de i nas frequências (4 – 5 Hz);

M_{i2} : média das amplitudes do espectro de i nas frequências (6 Hz);

M_{i3} : média das amplitudes do espectro de i nas frequências (7 – 8 Hz);

Onde i varia de 1 a 6 e representa o eletrodo em questão, como pode ser observado na tabela 1. Tal associação baseou-se na disposição das informações das derivações na matriz de dados.

Tabela 1: Derivações utilizadas no projeto e os números aos quais as mesmas correspondem no cálculo das médias de amplitude especificados acima.

	Derivação
$i = 1$	O1
$i = 2$	O2
$i = 3$	P3
$i = 4$	P4
$i = 5$	C3
$i = 6$	C4

Para cada paciente, com e sem estimulação, foi feita a coerência entre os sinais de eletrodos utilizados e, posteriormente, foi calculada a taxa de detecção, cujo exemplo está ilustrado nas Fig.s 8, 9 e 10, sendo que as mesmas são relativas a 2, 4 e 6 canais, respectivamente. Esta taxa, por sua vez, é referente ao número de harmônicos da frequência de estimulação cujo valor ultrapassou o limiar estabelecido nos cálculos (seção 3.1). A mesma foi tomada como saída para as redes desenvolvidas.




Figura 8 – Taxa de detecção referente a dois canais (O1 e O2) de um indivíduo sob FEI.

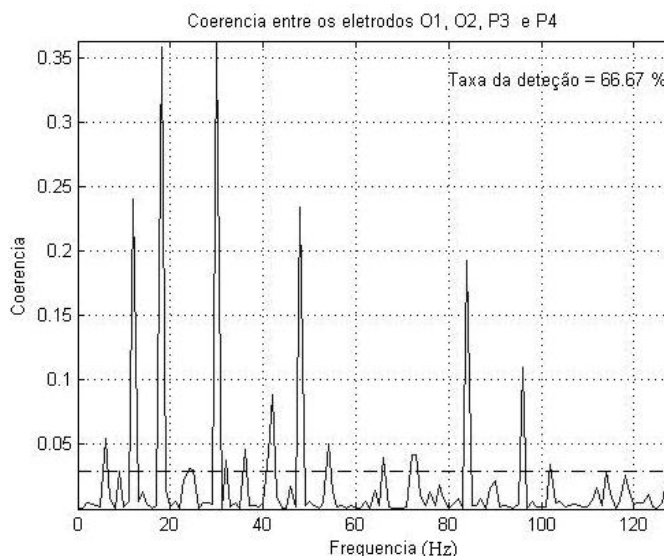


Figura 9 – Taxa de detecção referente a quatro canais (O1, O2, P3 e P4) de um indivíduo sob FEI.

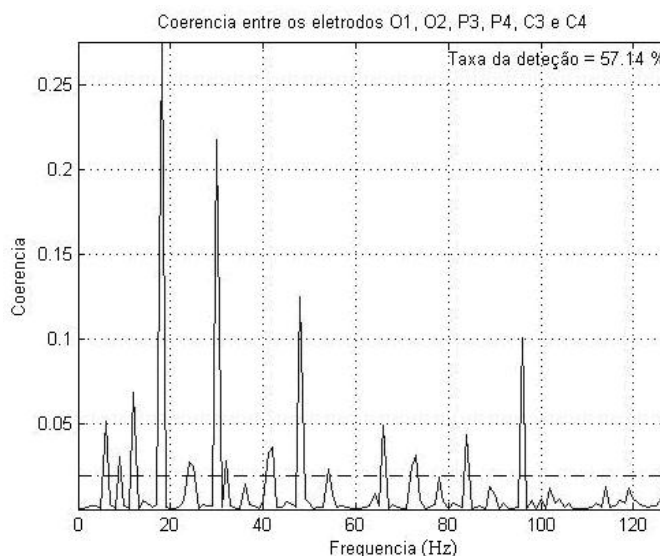


Figura 10 – Taxa de detecção referente a seis canais (O1, O2, P3, P4, C3 e C4) de um indivíduo sob FEI.

Definidas as entradas e saídas, essas foram aplicadas às redes. Para o treinamento foram utilizados 75% dos dados, sendo os demais designados para a validação. Como o conjunto total era composto por dados com e sem estimulação, em igual proporção, retirou-se um número semelhante de dados de cada grupo de forma que os caracteres de treinamento e validação possuíssem também amostras dos dois tipos e dispostas de maneira não uniforme. O diagrama de blocos do detector é mostrado na Fig.11. A partir dele podemos acompanhar todo o processo de extração de características, treinamento e aquisição de respostas.

Vale ressaltar que em todas as estruturas preocupou-se em evitar o *overfitting*. Tal resposta foi obtida avaliando-se o erro de validação, ou seja, apenas a estrutura que apresentasse menor erro de validação durante o treinamento seria armazenada, processo conhecido como *early-stopping*.

Além disso, como a estimativa da coerência requer um maior custo computacional em comparação com o espectro, neste trabalho, as redes foram treinadas com os valores associados de coerência, para inferir sobre a taxa de detecção de sinal periódico em ruído.

Primeiramente, foram feitas análises com dois eletrodos com a presença e a ausência do ritmo alfa cerebral. Para tal configuração, foram analisadas as três ferramentas: redes neurais, Wang e Anfis. Posteriormente foram feitos os mesmos procedimentos considerando quatro eletrodos. O número de canais e os eletrodos associados aos mesmos podem ser observados na tabela 2.

Tabela 2: Número de canais usados na detecção e os eletrodos associados aos mesmos, de acordo com a ordem utilizada no trabalho.

	Eletrodos
$N = 2$	O1 e O2
$N = 4$	O1, O2, P3 e P4
$N = 6$	O1, O2, P3, P4, C3 e C4

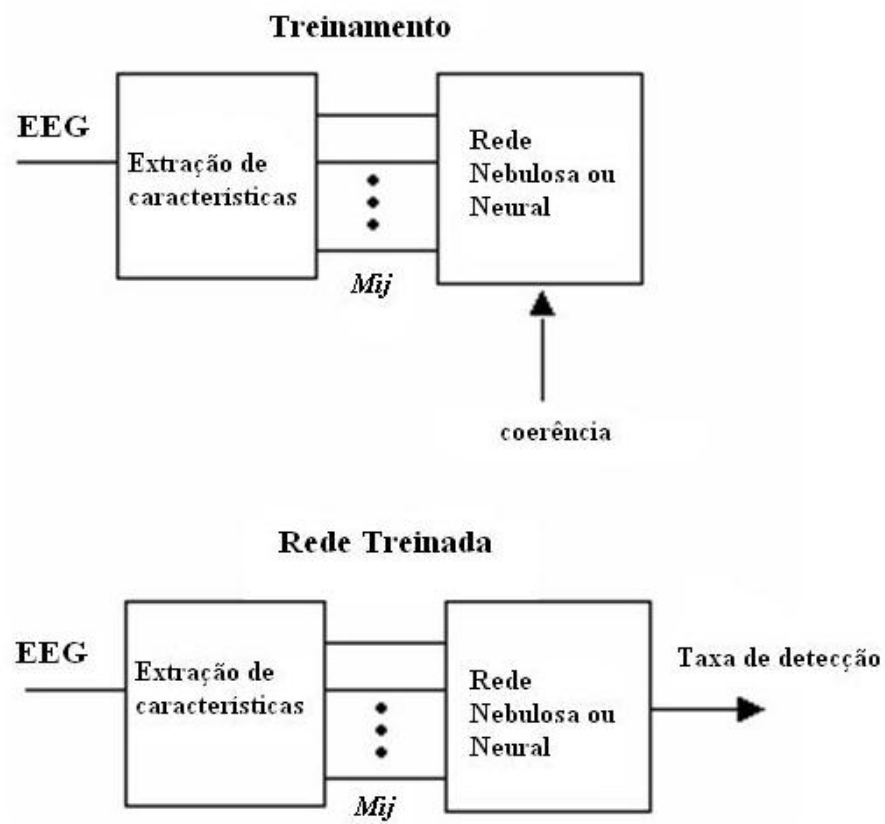


Figura 11 – Diagrama de blocos do detector.

4. RESULTADOS

Para o primeiro caso, considerando dois eletrodos e o ritmo alfa como entrada das redes, obteve-se o resultado apresentado na Fig.12 e, na Fig.13, temos a comparação do erro em relação ao número de iterações das três redes utilizadas nesta configuração.

A resposta apresentada na Fig.12 é referente a uma RNA. Essa, por sua vez, teve como estrutura uma camada intermediária com cinco neurônios, ao passo que, a rede Wang necessitou de duas camadas intermediárias, com dois e nove neurônios nas respectivas camadas e a Anfis dispôs-se de 256 regras. Neste caso, a resposta fornecida pela rede neural foi mais eficiente que a das estruturas *neurofuzzy* utilizadas, no que diz respeito ao coeficiente de correlação e erro médio quadrático. A MLP apresentou-se 97% correlacionada com a saída padrão do detector, enquanto a Wang teve como resposta 96% e a Anfis 80%. Através da Fig.13 podemos constatar que durante o treinamento a estrutura que atingiu menor erro de validação também foi a neural.

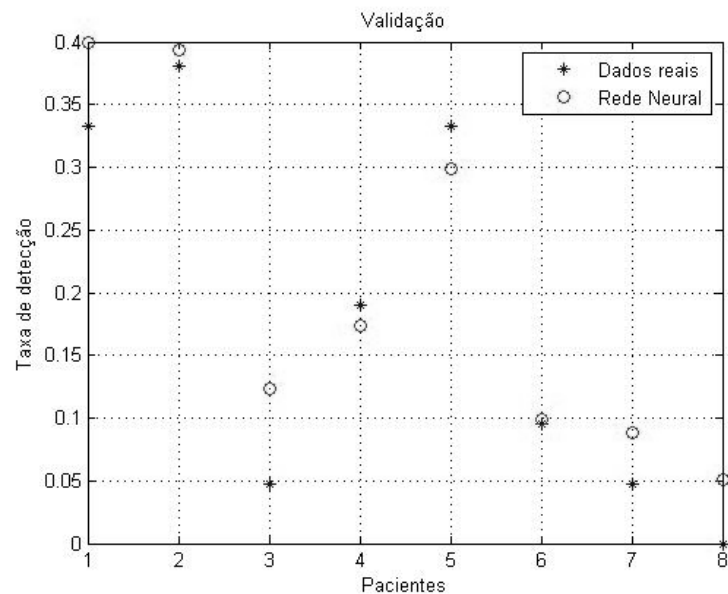


Figura 12 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a dois eletrodos (O1 e O2) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui uma camada oculta com 5 neurônios.

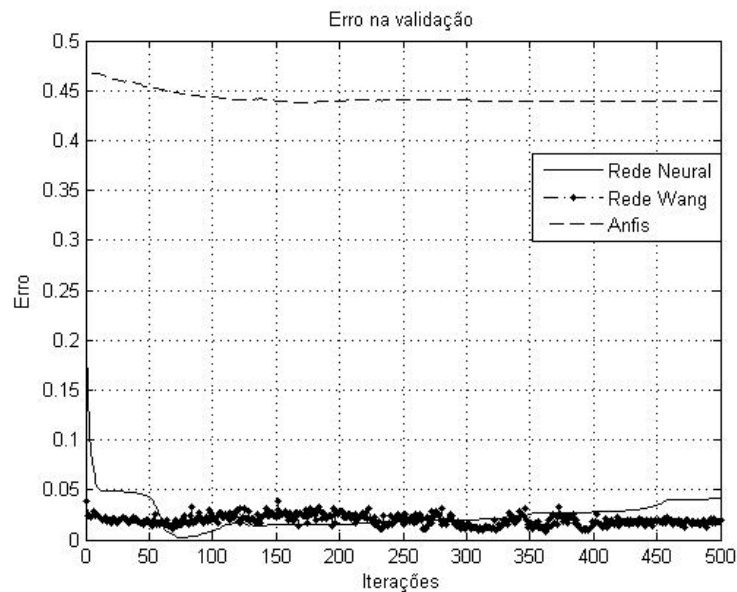


Figura 13 – Comparação do erro de validação das redes considerando 500 iterações. A coerência é referente aos eletrodos O1 e O2 e o ritmo alfa foi tomado como parâmetro para as redes. A resposta caracterizada pelo erro revela a maior eficácia da RNA.

Quando alfa não foi considerado, notamos um comportamento similar ao apresentado anteriormente, uma vez que a RNA apresentou-se hábil diante das técnicas avaliadas como ilustra a Fig.14. Neste caso o coeficiente de correlação da mesma foi 0,98 e, para a *neurofuzzy*, foi de 0,97 e 0,92, sendo Wang e Anfis, respectivamente. A rede neural, dessa vez, apresentou-se mais complexa, com três camadas ocultas (1, 3 e 9 neurônios, respectivamente), já a Wang necessitou de duas camadas (8 e 7 neurônios, consecutivamente) e a Anfis apresentou 64 regras.

O erro das três estruturas durante o treinamento pode ser observado na Fig.15. Nela percebe-se que o mesmo corrobora com o resultado expresso pelo coeficiente de correlação, uma vez que a MLP atingiu menor valor durante as iterações avaliadas. Mesmo em simulações com um número maior de épocas, o erro das estruturas *neurofuzzy* não decresceu de forma significativa, apresentando sempre o comportamento ilustrado.

Diante dessas apreciações, considerando as derivações O1 e O2, temos como resultado apresentado pelas técnicas conexionistas os valores especificados na tabela 3.




Figura 14 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a dois eletrodos (O1 e O2) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui três camadas ocultas com 1, 3 e 9 neurônios nas mesmas.




Figura 15 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a dois eletrodos (O1 e O2) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.

Tabela 3: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando duas derivações: O1 e O2. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.

Parâmetros	Com alfa			Sem alfa		
	Neural	Wang	Anfis	Neural	Wang	Anfis
Rede						
Número de camadas	1	2	1	3	2	1
Número de neurônios e regras	5	[2 9]	256	[1 3 9]	[8 7]	64
Coeficiente de correlação	0.97	0.96	0.80	0.98	0.97	0.92

Posteriormente, ao aumentarmos o número de canais dispostos para a coerência, obtivemos um resultado semelhante ao apresentado anteriormente. Para $N=4$, considerando a presença do ritmo alfa cerebral, a resposta corresponde fielmente ao resultado anterior, porém com um coeficiente de correlação inferior. Na Fig.16, temos a resolução apresentada pela MLP, que se demonstrou mais aplicável ao sistema.

Nesta configuração, a RNA obteve coeficiente de correlação de 0,94, ao passo que as redes *neurofuzzy* propuseram os valores de 0,91 e 0,81 (Wang e Anfis, consecutivamente). As redes neural e Wang tiveram em sua estrutura duas camadas ocultas com [2 8] e [6 7] neurônios, sucessivamente e a Anfis dispôs de 6 regras. É notória a melhor desenvoltura da MLP também quando se compara o comportamento do erro de validação desta com as demais (Fig.17).

Em conformidade com a resposta anterior temos a análise sem o ritmo alfa que também apresentou maior eficácia da rede neural (Fig.s 18 e 19). Nesse caso, a mesma necessitou de maior complexidade que a anterior: três camadas intermediárias, com 6, 3 e 9 neurônios, respectivamente. Já as redes *neurofuzzy* contaram com [2 6] neurônios e 9 regras (Wang e Anfis, consecutivamente) e obtiveram coeficientes de correlação de 0,96 e 0,83, ao passo que a outra metodologia alcançou um valor discretamente superior que a Wang: 0,97.

Mesmo diante da ínfima diferença entre os coeficientes de correlação, o erro da rede neural apresentou-se, na maioria das iterações, inferior ao das redes *neurofuzzy*, o que ratificou a maior eficiência da mesma.

O resultado apresentado pela configuração de quatro canais pode ser examinado na tabela 4. Os mesmos correspondem de forma confiável com a avaliação de dois eletrodos, porém é inegável a redução do coeficiente de correlação mesmo que discretamente.

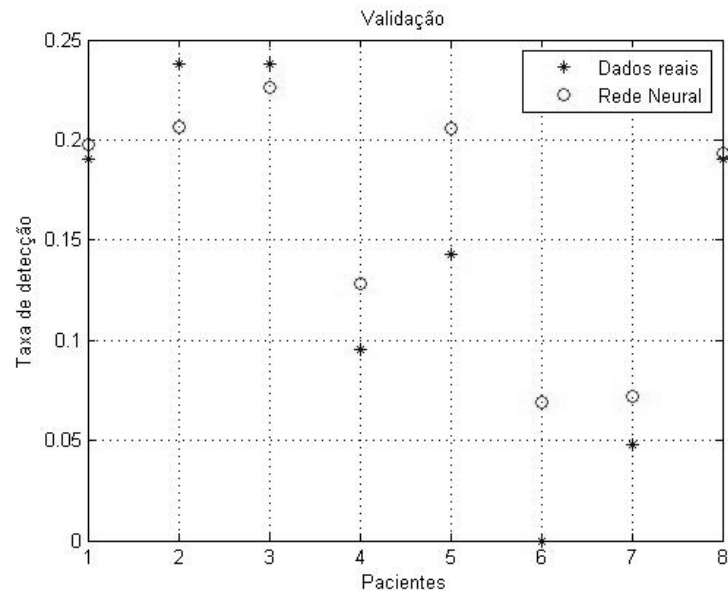


Figura 16 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a quatro eletrodos (O1, O2, P3 e P4) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.

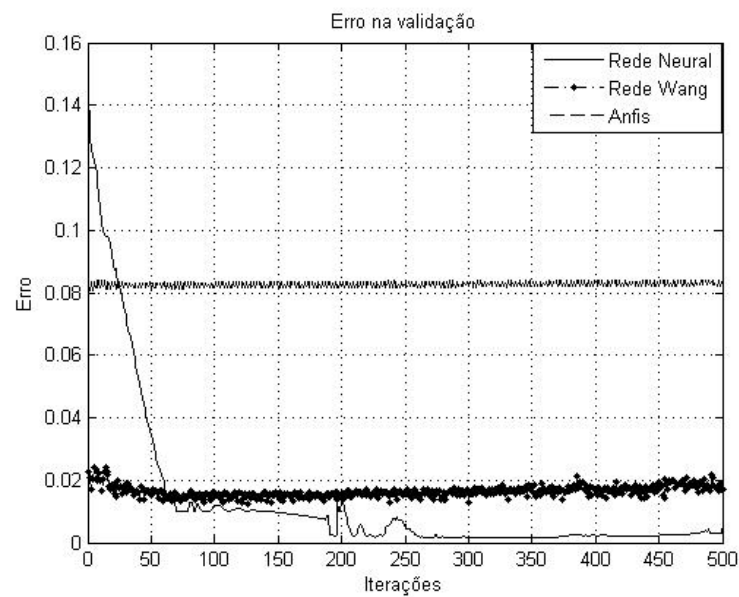


Figura 17 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a quatro derivações (O1, O2, P3 e P4) com a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.




Figura 18 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a quatro eletrodos (O1, O2, P3 e P4) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.

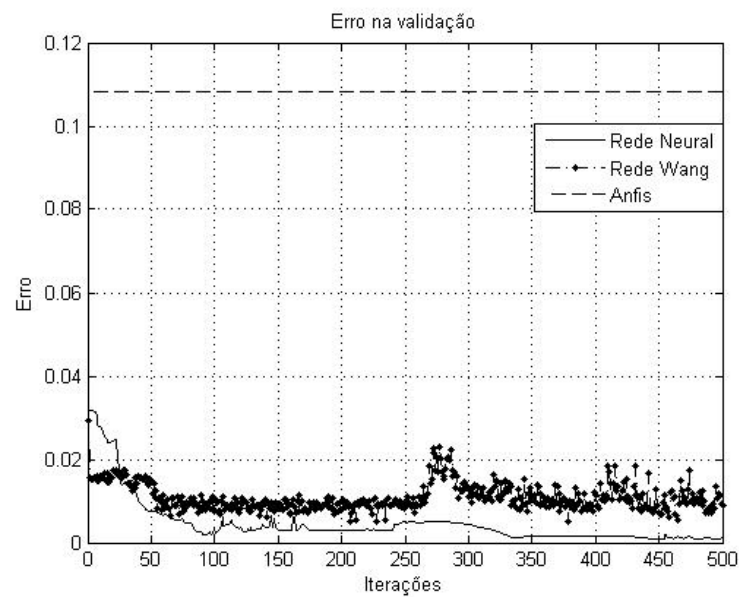


Figura 19 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a quatro derivações (O1, O2, P3 e P4) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.

Tabela 4: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando quatro derivações: O1, O2, P3 e P4. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.

Parâmetros	Com alfa			Sem alfa		
	Neural	Wang	Anfis	Neural	Wang	Anfis
Rede						
Número de camadas	2	2	1	3	2	1
Número de neurônios e regras	[2 8]	[6 7]	6	[6 3 9]	[2 6]	9
Coeficiente de correlação	0.94	0.91	0.81	0.97	0.96	0,83

Por fim, utilizando-se essas modalidades conexionistas, fez-se a análise com $N = 6$. A resposta das melhores estruturas está ilustrada nas Fig.s 20 (com alfa), e 22 (sem alfa) e, como pode ser observado, não contesta as respostas anteriores, uma vez que as MLPs tiveram melhor aplicabilidade. Tal afirmativa pode ser ratificada ao examinarmos a correlação entre a resposta do detector e a resposta esperada.

Na análise com a presença do ritmo alfa cerebral o retorno da RNA dispõe-se 92% correlacionado com a saída esperada ao passo que as estruturas *neurofuzzy* apresentaram-se 84% e 72% (Wang e Anfis, respectivamente) correlacionadas. Ao descartar-se o ritmo alfa dos parâmetros de análise, a resposta teve um acréscimo no coeficiente de correlação e a MLP manteve seu comportamento de maior eficiência neste quesito: 96% contra 94% e 90% da Wang e Anfis, consecutivamente.

O erro das estruturas pode ser observado nas Fig.s 21 (com alfa) e 23 (sem alfa). Nota-se que a resposta disposta pelo mesmo ratifica o resultado disponibilizado pelo coeficiente de correlação.

Mesmo diante do aumento no coeficiente de correlação, a resposta não foi melhor que a apresentada pela configuração com dois eletrodos. A estrutura das redes aqui analisadas, bem como o coeficiente de correlação disposto pelas mesmas podem ser examinados na tabela 5.

Na tabela 6, foi feita uma comparação entre os erros médios quadráticos das melhores respostas encontradas para as várias estruturas. Através dessa, podemos observar que, em todos os casos, as redes treinadas sem alfa apresentaram menor erro quadrático, bem como maior coeficiente de correlação. Observa-se ainda, que as redes neurais tiveram coeficiente de correlação maior que os das *neurofuzzy* e, além disso, nas análises com dois eletrodos, as redes tiveram uma resposta mais eficaz ao se analisar esses dois parâmetros (números em negrito na tabela 6).




Figura 20 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a seis eletrodos (O1, O2, P3, P4, C3 e C4) com a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.




Figura 21 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a seis derivações (O1, O2, P3, P4, C3 e C4) com a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.

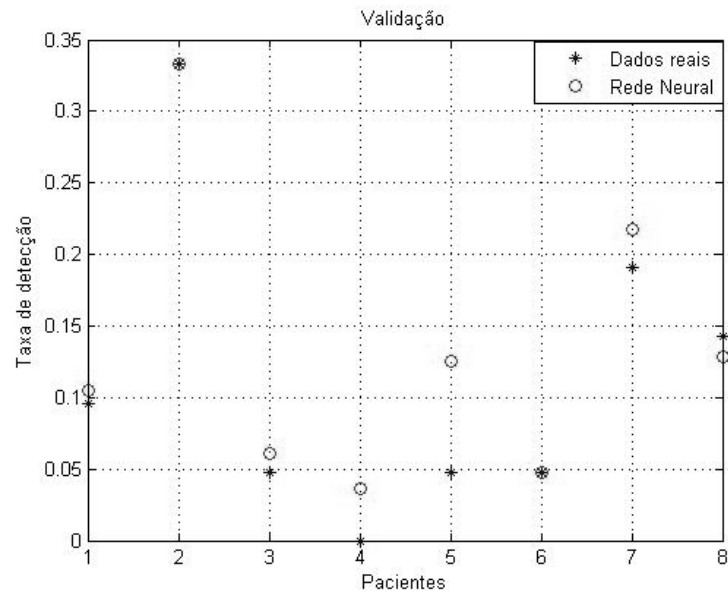


Figura 22 – Respostas apresentadas pelas redes para oito indivíduos escolhidos aleatoriamente e tomados como conjunto de validação, sendo as entradas referentes a seis eletrodos (O1, O2, P3, P4, C3 e C4) sem a presença do ritmo alfa. A rede MLP utilizada para o treinamento possui duas camadas ocultas com 2 e 8 neurônios nas mesmas.




Figura 23 – Comparação do erro apresentado nos três métodos durante 500 iterações. Para essa resposta a coerência analisada foi referente a seis derivações (O1, O2, P3, P4, C3 e C4) sem a presença do ritmo alfa na entrada das redes. A ilustração expressa a eficácia da RNA diante da análise do erro.

Tabela 5: Resultado apresentado pelas estruturas quando a função coerência foi calculada utilizando seis derivações: O1, O2, P3, P4, C3 e C4. São dispostas as estruturas das redes quanto ao número de camadas, neurônios e regras bem como o coeficiente de correlação atingido.

Parâmetros	Com alfa			Sem alfa		
	Neural	Wang	Anfis	Neural	Wang	Anfis
Rede						
Número de camadas	1	2	1	1	2	1
Número de neurônios e regras	9	[2 6]	21	9	[8 3]	21
Coeficiente de correlação	0.92	0.84	0.72	0.96	0.94	0.90

Tabela 6: Erros e coeficientes de correlação apresentado pelas estruturas treinadas com dois, quatro e seis eletrodos.

Parâmetros		Com alfa			Sem alfa		
		Neural	Wang	Anfis	Neural	Wang	Anfis
Dois eletrodos	Coeficiente de correlação	0.97	0.96	0.80	0.98	0.97	0.92
	Erro médio quadrático	0.002	0.0068	0.1966	0.0005	0.0011	0.0041
Quatro eletrodos	Coeficiente de correlação	0.94	0.91	0.81	0.97	0.96	0.83
	Erro médio quadrático	0.0014	0.0014	0.0070	0.0009	0.0017	0.0110
Seis eletrodos	Coeficiente de correlação	0.92	0.84	0.72	0.96	0.94	0.90
	Erro médio quadrático	0.0019	0.0028	0.0044	0.0011	0.0023	0.0027

Na Fig.24, temos graficamente a representação dos coeficientes de correlação de todas as estruturas, com ausência e presença do ritmo alfa, para as várias derivações. Com a mesma pudemos constatar a aplicabilidade da MLP para a detecção de respostas evocadas e, além disso, notamos que o melhor desempenho desta ferramenta ocorreu quando se utilizou apenas dois canais na ausência do ritmo alfa cerebral. Percebe-se ainda que ocorre uma redução (na maioria dos casos) do índice de correlação à medida que aumentava-se o número de canais.

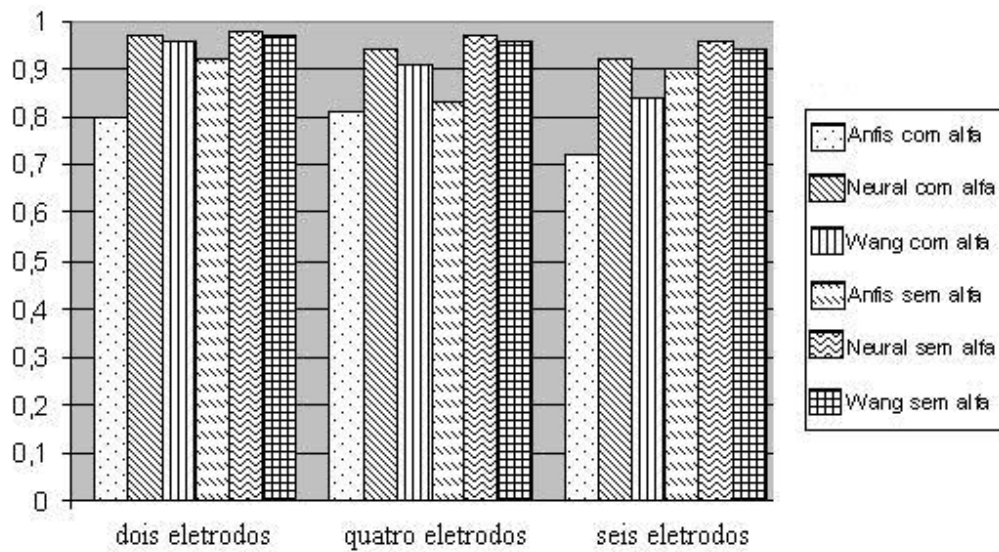


Figura 24 – Disposição gráfica de todos os coeficientes de correlação obtidos durante o desenvolvimento do projeto. O gráfico explicita a redução do coeficiente de correlação à medida que se aumenta o número de eletrodos a serem analisados.

5. CONCLUSÃO E DISCUSSÕES

Com o presente trabalho, concluímos que a estimativa da taxa de detecção dos indivíduos, pode ser identificada com o emprego de redes neurais, tornando o processo de análise do EEG mais rápido e não menos confiável ou mais dispendioso. A rapidez é ocasionada pelo fato de ser necessário analisar apenas algumas faixas do sinal e, além disso, não é preciso calcular a coerência, nem tão pouco a taxa de detecção, ou seja, os cálculos serão simplificados. Assim, só seriam necessários os dados do espectro do EEG o que não exige computação complexa e sim a investigação da função de densidade espectral.

Ressaltamos ainda, que o ritmo alfa cerebral não se demonstra significativo para o desempenho de detectores automáticos de respostas evocadas. A veracidade desta informação pode ser ratificada através do comportamento de todas as estruturas dispostas diante do erro e do coeficiente de correlação. As mesmas apresentaram menor erro médio quadrático, bem como maior coeficiente de correlação, quando tal parâmetro foi descartado.

Além disso, verificamos um melhor desempenho, em termos de coeficiente de correlação e complexidade da rede, quando a técnica utilizada foi a RNA. Observamos ainda, que é possível realizar o teste de detecção de respostas apenas com dois eletrodos, pois os resultados das redes tiveram um menor erro para esta situação. Tal ocorrência pode está relacionada com o fato de esses eletrodos estarem situados justamente sobre a região occipital, onde as respostas tendem a ser mais significativas diante do estímulo apresentado.

Outro fato a ser observado é o comportamento da estrutura *neurofuzzy*. Como essa proposta forneceu respostas com coeficientes de correlação menores que os apresentados pelas MLPs em todos os casos estudados, pode-se constatar que, com a estrutura utilizada, esta não é a melhor ferramenta. Neste caso, a associação das regras *fuzzy* com as redes neurais não trouxe benefícios significativos. Tal fato, possivelmente, está relacionado com a complexidade da estrutura utilizada (apenas duas camadas intermediárias no caso da Wang). Em experimentos futuros, seria interessante aumentar o número de camadas intermediárias da rede Wang para verificar se ocorrerá melhora na resposta, o que não foi realizado neste trabalho por limitações de tempo.

Verificamos ainda, que os resultados avaliados neste projeto podem acarretar benefícios imediatos à população quanto à rapidez da avaliação do EEG. De forma geral, o detector desenvolvido pode ser auxiliar para os profissionais clínicos nas análises do exame durante a FEI.

Além disso, tais estudos podem ser estendidos para outras classes de pacientes, uma vez que o EEG de crianças ou recém-nascidos tem comportamento diferente em relação aos adultos. Um exemplo a ser citado é a identificação de estágios do sono, como apresentado por Bosignolli *et al.* (2002), no qual a técnica aqui desenvolvida poderia auxiliar. Outra oportunidade de se aplicar tal metodologia é na identificação de Silêncio Elétrico Cerebral (SEC) em recém-nascidos, cuja detecção deve averiguar sinais com limiar em dois micro-Volts como discutido por Luccas *et al.* (1998).

De outro modo, o método disposto neste trabalho pode ser estendido para várias diretrizes da ciência em que a detecção de sinais é um problema. Dentre essas podemos citar a identificação de pequenos obstáculos por robôs através de eco de ondas sonoras (VIEIRA *et al.*) ou ainda em um sistema de vigilância para detectar seqüências de pulsos de radares, identificando a fonte (ZANANDREA *et al.*).

Por fim, conclui-se que o uso de técnicas conexionistas é de grande utilidade e podem auxiliar em vários campos da ciência, inclusive na identificação de taxas de detecção em EEG de indivíduos submetidos à FEI, que foi o trabalho aqui proposto.

6. SUGESTÕES PARA TRABALHOS FUTUROS

No presente trabalho, o passo utilizado no pré-processamento, para a obtenção dos espectros, foi de um. Tal fato permitiu que o vetor de frequência tivesse apenas valores inteiros, variando de 1Hz a 13Hz. Uma modificação que, eventualmente, melhoraria o desempenho dos detectores é a redução do passo para 0.5Hz, constituindo um vetor de frequência maior.

Além disso, implementações podem ser feitas na rede Wang de modo que a mesma possa atingir uma dinâmica mais eficiente que a obtida no presente trabalho. Isso pode ser feito utilizando redes com mais camadas.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ARGOUD, F. I. M.; AZEVEDO, F. M.; MARINO NETO, J. **Sistema de Detecção Automática de Paroxismos Epileptogênicos em Sinais de Eletroencefalograma**. Revista de Controle & Automação, vol. 15, n.4, p.467-475, 2004.
- BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. 2.ed. Florianópolis: Ed. da UFSC, p. 301-309, 2001.
- BOSIGNOLI, R.; INFANTOSI, A. F. C. **Redes Neurais Artificiais na classificação de estados do ciclo sono-vigília em Recém Nascidos**. Revista Brasileira de Engenharia Biomédica, vol.18, n.2, p. 75-87, 2002.
- BRAGA, A. P.; LUDERMIR, T.B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais – Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.
- DOBIE, R. A.; WILSON, M. J. **Analysis of Auditory Evoked Potentials by Magnitude-Squared Coherence**. *Ear and Hearing*, vol. 10, n. 1, p. 2-13, 1989.
- FERREIRA, D. D.; MIRANDA de SÁ, A. M. F. L. **Análise do EEG durante Estimulação Sensorial baseada nas Funções de Coerência Simples, Múltipla e Parcial**. Revista Brasileira de Engenharia Biomédica, vol.21, n.1, p.5-14, abril, 2005.
- FELIX, L. B.; MIRANDA DE SÁ, A. M. F. L.; INFANTOSI, A. F. C. **Detecção Objetiva de Respostas no EEG sob Fotoestimulação Intermitente – Uma Abordagem Multivariável**. *Anais de Trabalhos Completos do XVIII Congresso Brasileiro de Engenharia Biomédica*, vol. 5/5, p. 488-492. São José dos Campos, São Paulo, Brasil, 2002.
- FELIX, L. B.; MORAES, J. E.; MIRANDA DE SÁ, A. M. F. L.; YEHA, 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*, 144, p. 249-245, 2002.
- FONSECA, L. C. **Demência – Eletroencefalograma e Eletroencefalograma Quantitativo**. Sociedade Brasileira de Neurofisiologia Clínica. Projeto Diretrizes. Associação Médica Brasileira e Sociedade Brasileira de Medicina, 2002. Disponível em: <www.projetodiretrizes.org.br/projeto_diretrizes/035.pdf> Acesso em: 12 set. 2007.
- HAYKIN, S. **Redes Neurais: princípios e prática**. Trad. ENGEL, P. M.. 2.ed., Porto Alegre: Ed. Bookman, 2001.
- HAYKIN, S.; VEEN, B. V. **Sinais e Sistemas**. Trad. SANTOS, J. C. B.. Porto Alegre: Ed. Bookman, 2001.
- HUUPONEN, M.; LEHTOKANGAS, J.; SAARINEN, J.; VÄRRI, A.; SAASTAMOINEN, A.; HIMANEN, S.-L.; HASAN, J. **EEG Alpha Activity Detection by Fuzzy Reasoning**. *Proceedings of the Joint 9th IFSA World Congress and 20th NAFIPS International Conference*, p. 411-416, Vancouver, Canadá, 2001.
- INFANTOSI, A. F. C.; LAZAREV, V. V.; CAMPOS, D. V. **Detecção de resposta a fotoestimulação intermitente no eletroencefalograma utilizando o teste F-Espectral**. Revista Brasileira de Engenharia Biomédica, v. 21, n. 1, p. 25-36, SBEB - Sociedade Brasileira de Engenharia Biomédica, 2005.

JANG, J. S. R.; SUN, C. T.; MIZUTANI, E. **Neuro - Fuzzy and Soft Computing - A computational Approach to Learning and Machine Intelligence**. Prentice –Hall, 1997.

LUCCAS, F. J. C., BRAGA, N. I. O., SILVADO, C. E. S., 1998. **Recomendações técnicas para o registro do eletroencefalograma (EEG) na suspeita da morte encefálica**. Arq. Neuro-Psiquiatr., vol.56, n.3B, São Paulo. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0004-282X1998000400030>. Acesso em: 22 out. 2007.

MEDEIROS, A. V.; MAITELLI, A. L.; GABRIEL FILHO, O. **Otimização das Funções de Pertinência de um Controlador Nebuloso Utilizando Algoritmos Genéticos**. Anais do V Simpósio Brasileiro de Automação Inteligente, pp. 1-6, Canela, RS, nov. 2001.

MIRANDA DE SÁ, A. M. F. L.; FELIX, L. B. **Improving the Detection of Evoked Responses to Periodic Stimulation by using Multiple Coherence – Application to EEG during Photic Stimulation**. *Medical Engineering and Physics*, vol. 24, n. 4, p. 245-252, 2002.

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 and Physics*, vol. 27, p. 167-173, 2004.

MIRANDA DE SÁ, A. M. F. L.; SIMPSON, D. M.; INFANTOSI, A. F. C. **Coherence between one Random and one Periodic Signal for Measuring the Strength of Responses in the EEG during Sensory Stimulation**. *Med. Biol. Eng. Comput.*, vol. 40, n. 2, p. 99-104, 2002.

MIRANDA DE SÁ, A. M. F. L.; FELIX, L. B.; INFANTOSI, A. F. C. **A Matrix-Based Algorithm for Estimating Multiple Coherence of a Periodic Signal and Its Application to the Multichannel EEG During Sensory Stimulation**. *IEEE Transactions on Biomedical Engineering*, vol. 51, n. 7, July 2004.

MOUTINHO, A M. **Inteligência Computacional. Introdução ao uso de Redes Neurais com o Matlab**. 2004. Disponível em: <http://www.adrianomoutinho.com/trabalhos/introducao_ao_uso_de_redes_neurais_com_matlab_ic_2004.pdf>. Acesso em: 18 set. 2007.

RAMOS, E. G.; ZAYEN, E. J. B. **Detecção da Resposta Auditiva no EEG de Crianças utilizando Técnicas no Domínio da Frequência**. *Rev. Bras. Eng. Bioméd.*, vol. 16, n. 3, p. 125-137, 2000.

REDE MULTILAYER FEEDFORWARD. Disponível em: <<http://www.scielo.br/img/revistas/rem/v58n3/11f2.gif>>. Acesso: 22 out. 2007.

RODRIGUES, M. A. B.; AZEVEDO, F. M.; MARINO NETO, J. **Sistema para a identificação de padrões do sono com o auxílio de redes neurais dinâmicas**. *Proceedings of the IV Brazilian Conference on Neural Networks* – pp. 326-331, Julho 20-22, ITA, São José dos Campos, SP, 1999.

SANDRI, S. A.; CORREA, C. **V Escola de Redes Neurais**. Promoção: Conselho Nacional de Redes Neurais, pp. c073-c090, 19 de julho, ITA, São José dos Campos – SP, 1999.

SIMPSON, D. J.; TIERRA-CRIOLLO, C. J.; ZAYEN, E. J. B.; LEITE, R. T.; INFANTOSI, A. F. C. **Objective Response Detection in an Electroencefalogram during**

Somatosensorial Stimulation. *Annals of Biomedical Engineering*, vol. 28, n. 6, p. 691-698, 2000.

TAFNER, M. A. **Estagiamento automático do Sono utilizando um canal de EEG e uma rede Neural Artificial com Alta representação cortical.** Tese submetida à Universidade Federal de Santa Catarina. Florianópolis, SC, 1999.

WANG, L.-X. **Adaptive Fuzzy Systems and Control – Design and Stability Analysis.** *Englewood Cliffs*: Prentice Hall, 1994.

ZANANDREA, A.; SAOTOME, O.; FREITAS, S. V. **Detecção de sinais de pulso de radar através da transformada contínua da *wavelets*.** Divisão de Engenharia Eletrônica-IEE, Instituto Tecnológico da Aeronáutica – ITA, 12228-900, São José dos Campos, SP. Disponível em: <http://www.sbmac.org.br/eventos/cnmac/cd_xxviii_cnmac/resumosestendidos/ademilson_zanandrea_ST20.pdf>. Acesso em: 22 out. 2007.

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