



## REDE NEURAL ARTIFICIAL ARTMAP-FUZZY APLICADA NO RECONHECIMENTO DE FALHAS ESTRUTURAIS

JACQUELINE S. CHAVES<sup>1</sup>, MARA LÚCIA M. LOPES<sup>2</sup>, FÁBIO ROBERTO CHAVARETTE<sup>2</sup>, FERNANDO PARRA DOS ANJOS LIMA<sup>3</sup>

<sup>1</sup>Programa de Pós Graduação em Engenharia Mecânica  
Faculdade de Engenharia de Ilha Solteira (FEIS)

<sup>2</sup>Departamento de Matemática  
Faculdade de Engenharia de Ilha Solteira (FEIS)

Univ Estadual Paulista, Ilha Solteira, SP, Brazil

<sup>3</sup>Programa de Pós Graduação em Engenharia Elétrica  
Faculdade de Engenharia de Ilha Solteira (FEIS)

*(Recibido 18 de septiembre de 2015, revisado 6 de junio de 2016, para publicación 25 de julio de 2016)*

**Resumo** – A fim de desenvolver uma forma eficiente para a identificação e caracterização de falhas estruturais, este artigo teve por objetivo demonstrar uma aplicação de Redes Neurais Artificiais (RNAs) para tal problema. Portanto, através de um modelo dinâmico para a representação de uma estrutura predial, desenvolveu-se uma RNA ARTMAP-Fuzzy por ser uma rede flexível e estável em relação à sua habilidade em se adaptar às mudanças imprevistas do ambiente externo, para identificar tais falhas.

**Palavras chave** – Redes Neurais Artificiais, Reconhecimento de falhas, ARTMAP-Fuzzy.

### 1. INTRODUÇÃO

As falhas estruturais são danos na estrutura que implicam em mudanças nas suas propriedades físicas, e consequentemente nas características dinâmicas. Essas estruturas podem ser prédios, pontes, plataformas, etc., em que tais falhas podem influenciar no desempenho geral da estrutura, bem como causar consequências desastrosas, de acordo com [1]. Devido a isso, muitas empresas e indústrias aplicam a manutenção preventiva não apenas para evitar estas falhas, mas também para reduzir gastos e aumentar a confiabilidade e segurança destas estruturas, conforme [2].

A necessidade de desenvolver métodos eficazes para a detecção de falhas estruturais vem crescendo no decorrer dos anos. Segundo [3], estes métodos baseiam-se no fato de que os parâmetros modais (frequências, amortecimento e formas modais) representam funções das propriedades físicas da estrutura (massa, amortecimento e rigidez). Portanto, quando estas propriedades físicas sofrem alguma alteração, por exemplo, a redução de rigidez, as propriedades modais apresentarão alterações detectáveis.

Assim sendo, a aplicação de técnicas de monitoramento da integridade de estruturas em geral torna-se uma questão muito importante para a segurança da população, pois através destas técnicas, falhas podem ser detectadas em seu estágio inicial, auxiliando e promovendo a melhor forma de manutenção destas estruturas, garantindo que as mesmas continuem em pleno funcionamento.

Em [4] citam que o processo de implementação de estratégias na identificação destas falhas, seja na engenharia mecânica, civil ou no ambiente aeroespacial, é conhecido como Monitoramento da Saúde Estrutural (SHM). Em [5], são citadas algumas técnicas de SHM, como: emissão acústica, raios X, correntes de Eddy, métodos de campo magnético e outros. Os principais benefícios que os sistemas de SHM apresentam são: a diminuição dos custos com manutenção e a maior confiabilidade das estruturas projetadas, gerando uma maior segurança de vida.

De acordo com [2], apesar das técnicas tradicionais de SHM possuírem bons equipamentos e serem bem formuladas, elas não satisfazem as necessidades atuais das indústrias, principalmente quando se refe-

re à detecção de falhas em tempo real. Portanto, novas técnicas veem surgindo utilizando-se dos conceitos de redes neurais artificiais.

Em geral as Redes Neurais Artificiais (RNAs) são algoritmos computacionais utilizados na resolução de problemas complexos. Seu processamento baseia-se no funcionamento do sistema nervoso biológico. Segundo [6] as RNAs possuem uma habilidade natural em armazenar conhecimento experimental e disponibilizá-lo para uso posteriormente.

Uma das arquiteturas de redes neurais que vem se destacando na literatura são as redes neurais baseadas na teoria da ressonância adaptativa denominada redes ART (Adaptive Resonance Theory). Segundo [7,8] esta arquitetura preserva duas características fundamentais para o processamento da rede: a estabilidade e a plasticidade que proporcionam à rede uma aprendizagem estável e convergência rápida.

Este trabalho tem como objetivo utilizar a rede neural artificial ARTMAP *Fuzzy* como um sistema de detecção de falhas estruturais, sendo que os dados (com e sem falha) utilizados na fase de treinamento e diagnóstico da rede neural são gerados a partir de um modelo matemático de um edifício.

## 2. REDE NEURAL ARTIFICIAL ARTMAP FUZZY

Para [9] a rede neural ARTMAP *Fuzzy* é uma rede mais sofisticada, que emprega o treinamento supervisionado, ou seja, é baseado em estímulos de entrada-saída. É composta por dois módulos ART *fuzzy*: ARTa e ARTb interconectados através de módulo de memória associativa inter-ART, Fab, que possui um mecanismo auto-regulador denominado match tracking, que tem a incumbência de maximizar a generalização e minimizar o erro da rede.

A rede neural ARTMAP *Fuzzy* incorpora a teoria de conjuntos *fuzzy* em seus cálculos e, como tal, é capaz de aprender categorias estáveis em resposta a padrões de entradas analógicas ou binários.

A estrutura da rede neural ARTMAP *Fuzzy* é mostrada na Fig. 1.

O fluxograma do algoritmo da rede neural ARTMAP *Fuzzy* é ilustrado na Fig. 2. Através do Fluxograma é possível verificar os passos a serem executados para o funcionamento da rede.

## 3. METODOLOGIA

A metodologia proposta é baseada em três etapas:

1. Aquisição dos dados;

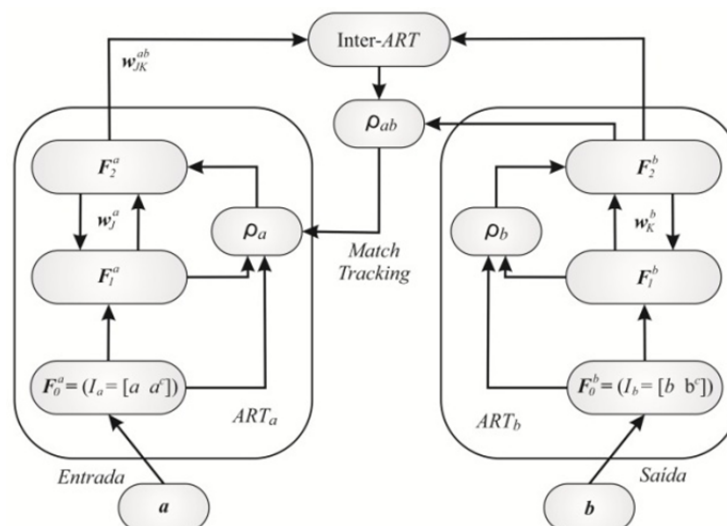


Fig. 1. Rede neural ARTMAP *Fuzzy* ([2]).

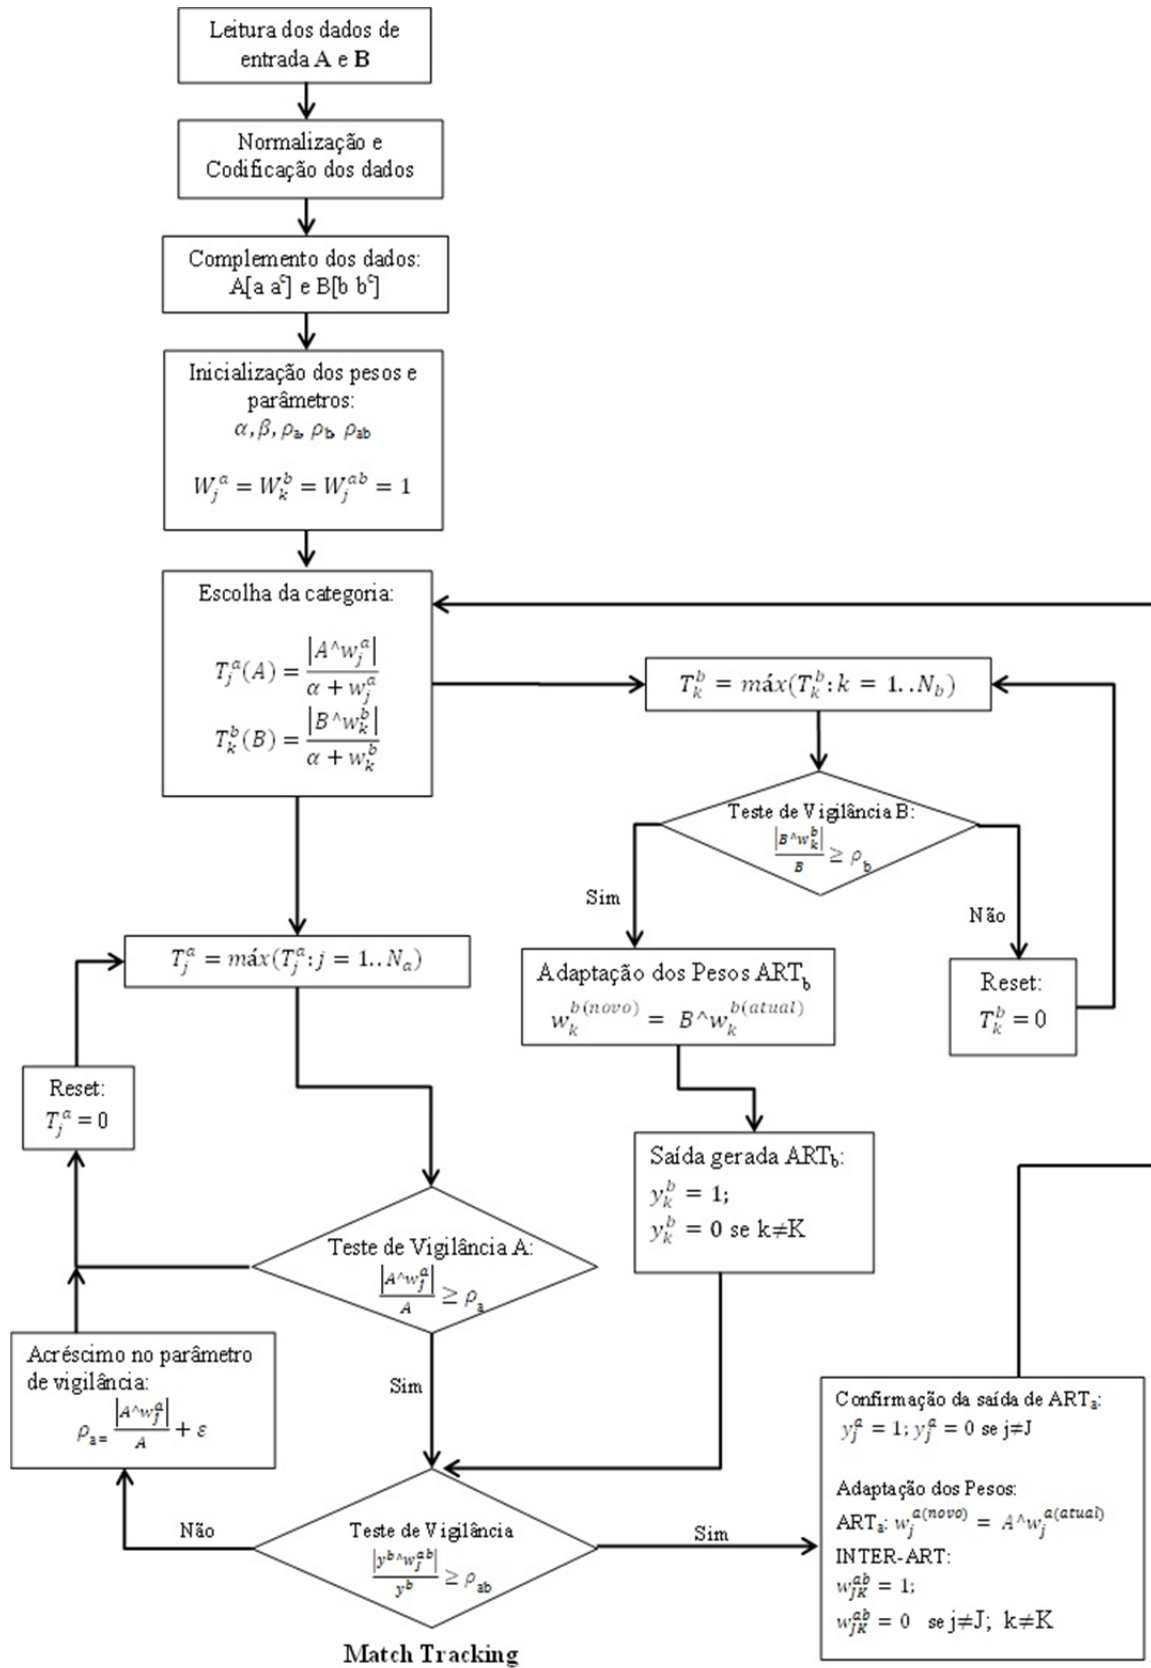


Fig. 2. Fluxograma da rede neural ARTMAP Fuzzy ([2]).

2. Treinamento da rede ARTMAP *Fuzzy*;
3. Diagnóstico da rede ARTMAP *Fuzzy*.

Para a execução do algoritmo da rede ARTMAP *Fuzzy*, tanto para o treinamento quanto para o diagnóstico, utilizou-se a plataforma Matlab®, por ser uma plataforma de fácil manuseio e por ser específica na resolução de problemas matemáticos.

### 3.1. Aquisição dos Dados

A aquisição dos dados foi feita por meio de um modelo matemático formado por um sistema de equações diferenciais modelando uma estrutura predial, sendo utilizado o integrador numérico *Runge Kutta* de quarta ordem. Para realizar as simulações das condições normais (*base-line*) e anormais (falha estrutural) no edifício, alteraram-se as massas ( $m_1$  e  $m_2$ ) dos andares na estrutura.

Conforme [10] a Fig. 3 ilustra o modelo que representa o comportamento dinâmico de um edifício, onde se derivam as equações do movimento para um pórtico plano simples, com consideração do encurtamento das barras devido à flexão das mesmas, sob excitação na direção vertical.

Os parâmetros utilizados neste modelo foram:

- $m_1, m_2$  - Massa da Estrutura
- $k_1, k_2$  - Coeficiente de Rigidez Elástica da Estrutura
- $c_1, c_2$  - Coeficiente de Amortecimento viscoso da Estrutura
- $q_1, q_2$  - Coordenadas Generalizadas
- $\dot{x}_1, \dot{x}_3$  - Velocidade
- $\ddot{x}_2, \ddot{x}_4$  - Aceleração
- $S$  - Excitação Externa
- $\dot{S}$  - Velocidade da ação do sismo
- $\ddot{S}$  - Acelerograma da ação do sismo
- $\omega_1, \omega_2$  - Frequência Natural
- $f$  - Frequência
- $\tau$  - Amplitude da Excitação Externa

em que:

$$x_1 = a + S + q_1$$




Fig. 3. Modelo Dinâmico ([10]).

$$x_2 = b + S + q_2$$

$$S = A \cos(\lambda t)$$

A energia cinética total (T) do sistema é:

$$T = \frac{1}{2} [m_1(\dot{S} + \dot{q}_1)^2 + m_2(\dot{S} + \dot{q}_2)^2] \quad (1)$$

A energia potencial total (V) do sistema é:

$$V = \frac{1}{2} [k_1 q_1^2 + k_2 (q_2 - q_1)^2] \quad (2)$$

O Lagrangeano (L=T-V) é:

$$L = \frac{1}{2} [m_1(\dot{S} + \dot{q}_1)^2 + m_2(\dot{S} + \dot{q}_2)^2 - k_1 q_1^2 - k_2 (q_2 - q_1)^2] \quad (3)$$

A equação de Lagrange para a coordenada generalizada  $q_1$  é:

$$m_1(\ddot{q}_1 + \ddot{S}) + k_1 q_1 - k_2 (q_2 - q_1) = -c_1 \dot{q}_1 \quad (4)$$

A equação de Lagrange para a coordenada generalizada  $q_2$  é:

$$m_2(\ddot{q}_2 + \ddot{S}) + k_2 (q_2 - q_1) = -c_2 (\dot{q}_2 - \dot{q}_1) \quad (5)$$

Assim, o sistema pode ser modelado pelo sistema de equações:

$$\begin{aligned} m_1 \ddot{q}_1 + k_1 q_1 - k_2 (q_2 - q_1) + c_1 \dot{q}_1 &= -m_1 \ddot{S} \\ m_2 \ddot{q}_2 + k_2 (q_2 - q_1) + c_2 (\dot{q}_2 - \dot{q}_1) &= -m_2 \ddot{S} \end{aligned} \quad (6)$$

ou

$$\begin{aligned} \ddot{q}_1 + \frac{k_1}{m_1} q_1 - \frac{k_2}{m_1} (q_2 - q_1) + \frac{c_1}{m_1} \dot{q}_1 &= -\ddot{S} \\ \ddot{q}_2 + \frac{k_2}{m_2} (q_2 - q_1) + \frac{c_2}{m_2} (\dot{q}_2 - \dot{q}_1) &= -\ddot{S} \end{aligned} \quad (7)$$

Tomando

$$\begin{aligned} \omega_1^2 &= \frac{k_1 + k_2}{m_1} \\ \omega_2^2 &= \frac{k_2}{m_2} \end{aligned}$$

Tem-se

$$\begin{aligned} \ddot{q}_1 + \omega_1^2 q_1 - \frac{k_2}{m_1} q_2 + \frac{c_1}{m_1} \dot{q}_1 &= -S \\ \ddot{q}_2 + \omega_2^2 (q_2 - q_1) + \frac{c_2}{m_2} (\dot{q}_2 - \dot{q}_1) &= -S \end{aligned} \quad (8)$$

E fazendo as seguintes considerações

$$x_1 = q_1$$

Tabela 1. Parâmetros do Modelo Matemático.

Parâmetros	Valores
$m_1$	7 kg
$m_2$	7 kg
$c_1$	0.6 N.s/m
$c_2$	0.7N.s/m
$x_1$	0.01 m
$x_2$	0.01 m
$x_3$	0.01 m
$x_4$	0.01 m
$\omega_1$	1 rad/s
$\omega_2$	2 rad/s
$K_2$	0.8 N/m
S	$A\cos(\tau t)$
A	$10^{-5}$
$\tau$	1

$$x_2 = \dot{q}_1$$

$$x_3 = q_2$$

$$x_4 = \dot{q}_2$$

Tem-se o sistema de equações descrito pela Equação (9).

$$\dot{x}_1 = x_2 \quad (9)$$

$$\dot{x}_2 = -\omega_1^2 x_1 + \frac{k_2}{m_1} x_3 - \frac{c_1}{m_1} x_2 - S$$

$$\dot{x}_3 = x_4$$

$$\dot{x}_4 = \omega_2^2 (x_1 - x_3) + \frac{c_2}{m_2} (x_2 - x_4) - S$$

sendo S uma excitação periódica.

Os valores dos parâmetros iniciais utilizados no modelo matemático estão descritos na tabela 1, sendo aplicado o integrador Runge-Kutta de quarta ordem na equação (9) e para as condições iniciais  $x_1=0$ ;  $x_2=0$ ;  $x_3=0$  e  $x_4=0$  no tempo considerando amostras de 0 a 200, sendo A uma constante e  $\tau$  é a frequência de excitação.

### 3.2. Treinamento da Rede ARTMAP Fuzzy

O treinamento de uma rede neural artificial é feito através do ajuste ou adaptação dos pesos sinápticos.

A arquitetura da ARTMAP Fuzzy é composta por um par de redes ART, também chamadas de módulo ARTa e ARTb. Durante o treinamento, o módulo ARTa recebe padrões de entrada ( $a^{(p)}$ ) e ARTb, padrões de entrada ( $b^{(p)}$ ), onde  $b^{(p)}$  é a previsão correta dada aos padrões de entrada  $a^{(p)}$ .

Os módulos ARTa ARTb estão ligados por um terceiro módulo denominado inter-ART, que corresponde ao módulo de memória associativa.

Se as duas entradas no módulo inter-ART combinam, ou seja, se o prognóstico da rede é confirmado pela categoria selecionada, a rede aprenderá modificando os protótipos das categorias escolhidas em ARTa e ARTb, segundo um critério de treinamento.

Se as duas entradas não combinam, um sinal de *reset* é gerado e um processo denominado *match tracking* que ativará uma nova busca na qual escolherá uma nova categoria no módulo ARTa, cujo prognóstico será combinado novamente com a categoria atual do ARTb.

Todos os pesos relacionados ao ARTa, ARTb e ao inter-ART inicialmente possuem valor “1” indicando que as categorias não estão ativas, ou seja, inicialmente nenhuma categoria foi selecionada. Após a seleção das categorias elas tornam-se ativas.

Além do vetor de pesos sinápticos para cada módulo ( $w_a$ ,  $w_b$  e  $w_{ab}$ ), de acordo com [2] para o treinamento da rede ARTMAP *Fuzzy* os seguintes parâmetros são utilizados:

- Parâmetro de escolha;
- Taxa de Treinamento;
- Parâmetro de vigilância (P.V.) de ARTa;
- Parâmetro de vigilância (P.V.) de ARTb;
- Parâmetro de vigilância (P.V.) de ARTab.

Os padrões de entrada da rede neural são representados pelos deslocamentos,  $x_2$ , avaliado no tempo,  $t$ , e os padrões de saída da rede neural são representados pelo estado do sistema, ou seja, sistema normal ou sistema com falha. Matematicamente, tem-se:

$$X(h) = [x_2]$$

$$Y(h) = \begin{cases} 1 & \text{sistema normal} \\ 0 & \text{sistema com falha} \end{cases}$$

sendo:

$X(h)$  : entrada da rede ARTMAP *Fuzzy*;

$Y(h)$  : saída da rede ARTMAP *Fuzzy*;

$h$  : quantidade de padrões.

### 3.3. Diagnóstico da Rede ARTMAP *Fuzzy*

Para realizar o diagnóstico da rede, foi apresentado um novo conjunto de dados, diferente do conjunto utilizado no treinamento, pois, uma vez treinada, a rede neural ARTMAP *Fuzzy* deve ser capaz de através do reconhecimento de uma categoria, classificar os dados não treinados, identificando assim, um sinal de condição normal ou anormal.

Durante o diagnóstico é realizado apenas o processo do módulo ARTa. A saída gerada por este módulo é então, comparada com o conhecimento adquirido durante o treinamento e é feito o reconhecimento e, conseqüentemente, encontrada a saída desejada.

## 4. RESULTADOS

Para a realização do treinamento e diagnóstico da rede ARTMAP *Fuzzy*, obteve-se 221 sinais, sendo que, 9 sinais representavam a condição normal e os outros 212 sinais representavam a condição de falha, sendo 170 sinais representando falha no 1º andar e 42 representando falha no 2º andar. A quantidade de sinais gerada foi obtida ao alterar a massa da estrutura  $m_1$  de 8 até 9 com variação de 0,5 e a  $m_2$  de 1 a 7 com variação de 0,5.

Portanto, o teste realizado consistiu em classificar os sinais em sinal normal, sinal com falha no primeiro andar e sinal com falha no segundo andar. E para realizar a identificação desta falha, ou seja, se a falha se encontra no primeiro ou segundo andar, adotou-se a seguinte estratégia:

- Os sinais que representavam a condição normal do edifício (*base-line*) tiveram uma saída desejada com uma representação binária composta por dois “bits”, ou seja, 0 0;
- Para os sinais que representam a condição de falha no 1º andar, a saída desejada é representada pelos “bits”, 0 1;
- Para os sinais que representam a condição de falha no 2º andar, a saída desejada é representada pelos “bits”, 1 0;

Tabela 2. Parâmetros do Treinamento da rede ARTMAP *Fuzzy*.

Parâmetro de Escolha	Taxa de Treinamento	P. V.1 ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0

Tabela 3. Parâmetros da ARTMAP *Fuzzy* para o melhor resultado.

Treinamento	
Parâmetro de Escolha	0,1
Taxa de Treinamento	1,0
P. V. ARTa	0,7
P. V. ARTb	1,0
P. V. ARTab	1,0
Diagnóstico	
P. V. ARTa	0,7
Acertos (%)	100

O conjunto de dados para o treinamento foi formado por 80% dos sinais normais e 80% dos sinais com falha selecionados aleatoriamente. Os valores dos parâmetros da rede ARTMAP *Fuzzy* utilizados na fase de treinamento são mostrados na tabela 2.

O conjunto de dados para o diagnóstico foi composto por 20% dos sinais normal e 20% dos sinais com falha que não foram utilizados na fase de treinamento. Os parâmetros utilizados na fase de treinamento e diagnóstico da rede ARTMAP *Fuzzy* que geraram o melhor resultado é ilustrado na tabela 3.

A partir do resultado mostrado na tabela 3, realizou-se um teste cruzado no qual o treinamento da rede neural ARTMAP *Fuzzy* foi realizado 100 vezes e, observou-se que a rede neural apresentou uma média de porcentagem de acerto de 93,89% como melhor resultado.

Observou-se que apesar da quantidade pequena de sinais (padrões) a rede neural mostrou um ótimo desempenho. O melhor resultado obtido no primeiro teste foi de 100% de acerto, ou seja, a rede neural ARTMAP *Fuzzy* conseguiu identificar um sistema normal e um sistema com falha, além de classificar onde a falha se encontrava.

## 5. DISCUSSÕES E CONCLUSÕES

Este trabalho expôs a importância da detecção de falhas em estruturas prediais e apresentou um método utilizando uma rede neural ARTMAP *Fuzzy* como uma forma de realizar o Monitoramento da Saúde Estrutural para um modelo matemático de um edifício.

Observou-se através dos testes realizados que a rede neural comportou-se de forma esperada, apresentando um resultado positivo em relação ao reconhecimento e classificação de sinais.

Em relação ao teste em que a rede deveria classificar os sinais em sinal normal, sinal de falha no 1º andar e sinal de falha no 2º andar, a rede neural ARTMAP *Fuzzy* demonstrou um ótimo desempenho ao obter 100% de acerto. Outro ponto positivo observado foi o resultado do teste cruzado, que apresentou uma porcentagem de acerto de 93,89% de acerto.

## AGRADECIMENTOS

Os autores agradecem o suporte financeiro a CAPES, a Fundação de Amparo a Pesquisa do Estado de São Paulo (FAPESP Proc. No. 2014/16807-3) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq Proc. No. 301769/2012-5).

## REFERÊNCIAS

- [1] Chen, B., Nagarajaiah, S., "Structural Damage Detection using decentralized controller design method", *Smart Structures and Systems*, 4(6), 779-794 (2008)



- [2] Lima, F.P., A Monitoramento e identificação de falhas em estruturas aeronáuticas e mecânicas utilizando técnicas de computação inteligente. Tese apresentada em cumprimento parcial dos Requisitos da Faculdade de Engenharia de Ilha Solteira para obtenção do título de Mestre em Engenharia Mecânica. Ilha Solteira (2014)
- [3] Sasmal, S., Ramanjaneyulu, K., “Detection and Quantification of Structural Damage of a Beam-Like Structure Using Natural Frequencies”, *Engineering*, 1, 167-176 (2009)
- [4] Farrar, C., Worden, K., “An introduction to structural health monitoring”, *Phil. Trans. R. Soc. A*, 303-315 (2006)
- [5] Carrillo, O.J.B., Algoritmo híbrido para avaliação da integridade estrutural: uma abordagem heurística. Tese apresentada em cumprimento parcial dos Requisitos da Escola de Engenharia de São Carlos da Universidade de São Paulo para obtenção do título de Doutor em Engenharia Civil, São Carlos (2007)
- [6] Haykin, S., *Introdução. In Redes Neurais: princípios e práticas*, Porto Alegre: Bookman (2001)
- [7] Carpenter, G.A., Grossberg, S., Rosen, D.B., “Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system”, *Neural Network*, 4(1), 759-771 (1991)
- [8] Carpenter, G.A., Grossberg, S., “A self-organizing neural network for supervised learning, recognition and prediction”, *IEEE Communications Magazine*, 30(9), 38-49 (1992)
- [9] Carpenter, G.A. et al., “Fuzzy ARTMAP: An Adaptive Resonance Architecture for Incremental Learning of Analog Maps”, *International Joint Conference on Neural Networks*, 3, 309-314 (1992)
- [10] Pegaiane, M.G.R. dos Reis, Minimizando vibrações de um sistema dinâmico através de controle híbrido. Tese apresentada em cumprimento parcial dos Requisitos da Faculdade de Engenharia de Ilha Solteira para obtenção do título de Mestre em Engenharia Mecânica. Ilha Solteira (2014)

## **ARTMAP-FUZZY ARTIFICIAL NEURAL NETWORK APPLIED IN RECOGNITION OF STRUCTURAL FAULTS**

**Abstract** – In order to develop an efficient way to identify and characterize structural faults, this paper aimed to demonstrate an application of Artificial Neural Networks (ANNs) for this problem. Therefore, through a dynamic model for the representation of a building structure, an ARTMAP-Fuzzy RNA has been developed because it is a flexible and stable network in relation to its ability to adapt to unforeseen changes in the external environment to identify such failures.

**Keywords** – Artificial Neural Networks, Fault Recognition, ARTMAP-Fuzzy.