



LOCALIZAÇÃO DE FALHAS ESTRUTURAIS USANDO SENSORES E ATUADORES PIEZOELÉTRICOS E REDES NEURAIIS ARTIFICIAIS

Rogério Mendonça Furtado

E-mail: furtado@dem.feis.unesp.br

Vicente Lopes Júnior

Departamento de Engenharia Mecânica

Av. Brasil Centro, 56 – CEP 15.385.000 – Fone (018) 3743 8138 – FAX (018) 3742 2992

www.dem.feis.unesp.br E-mail: vicente@dem.feis.unesp.br

Resumo. Neste trabalho combina-se o método da impedância elétrica e de redes neurais artificiais para serem aplicados em sistemas de monitoramento das condições de máquinas. O conceito básico de manutenção preditiva é monitorar as variações da impedância mecânica da estrutura causada pela presença de falhas. No entanto as medidas de impedância mecânica podem ser difíceis de serem obtidas para estruturas complexas, ou sistema onde as excitações não são conhecidas. Neste artigo é proposta uma técnica não destrutiva, NDE, onde se utiliza a impedância elétrica dos materiais cerâmicos (PZT), que é mais facilmente obtida e pode ser diretamente correlacionada a impedância estrutural, para se determinar a localização da falha. Portanto, através do monitoramento da medida de impedância elétrica e comparando-se a uma medida padrão, pode-se, qualitativamente, determinar a ocorrência de falhas na estrutura, mesmo em sua fase inicial. No segundo passo desta metodologia é utilizada a técnica de redes neurais artificiais para quantificar a severidade da falha. Uma das principais vantagens desta metodologia é que tanto o passo 1 quanto o passo 2 não são baseados em modelos matemáticos.

Palavras Chaves: Detecção de Falhas, Sistemas Inteligentes, Impedância Elétrica, Redes Neurais Artificiais e Manutenção Preditiva.

1. INTRODUÇÃO

A detecção e o monitoramento de falha é um assunto de considerável interesse para muitos campos. Aplicações da detecção e monitoramento de falha são encontradas em muitas faces da engenharia. Alguns exemplos incluem engenharia aeroespacial, engenharia civil, engenharia mecânica, engenharia nuclear, engenharia de materiais, engenharia química e engenharia automotiva. A confiabilidade do monitoramento é um assunto essencial, fornecendo informações para a segurança de estruturas e aeronaves modernas. Um dos métodos mais comuns de identificação de falhas na indústria aeronáutica é a inspeção visual. Mesmo com a ajuda de circuito interno de televisão, a inspeção visual requer muito tempo. Existem outros métodos não destrutivos convencionais de identificação de falhas baseado na evolução/teste (NDE/T), como, por exemplo, radiografia, ultra-som, emissão acústica, método óptico, método térmico, método magnético e outros. Com o avanço da tecnologia e dos computadores científicos, a integração da NDE/T com instrumentos de microprocessadores têm aumentado a capacidade de processamento do sinal e armazenamento dos dados rapidamente, tornando muito desses métodos tradicionais eficientes ferramentas para a identificação de falha. Apesar dos sucessos bem documentados de muitos dos

métodos de NDE/T convencionais, tem-se observado desvantagens e limitações quando aplicados no monitoramento em tempo real.

Recentemente, muita atenção é dada à pesquisa de novas técnicas de monitoramento de falha usando a resposta dinâmica medida e o uso de modelos matemáticos. Métodos baseados em modelos têm um fundo matemático rigoroso, mas eles sofrem de algumas desvantagens. Por exemplo, uma representação numérica precisa da estrutura é difícil de se alcançar e os significados físicos dos resultados detectados são vagos, devido às complicadas operações inversas.

Devido à complexidade e o alto nível de exigência das estruturas aeroespaciais, um novo conceito está sendo introduzido no sistema de monitoramento estrutural. Este conceito inclui a concepção de estruturas com adaptação/inteligente, aquisição da informação global, processamento do sinal em tempo real e tomada de decisões automaticamente. Usualmente, emprega-se o termo de sistemas de materiais inteligentes a aqueles compostos que apresentam características extraordinárias, não encontradas em materiais convencionais. Como exemplo deste tipo de materiais se pode citar os piezelétricos, eletroresistivo e magneto-resistivo, fluidos e sólidos electro-reológico, ligas de memória de forma e fibras óticas. Os materiais piezelétricos são os mais utilizados em sistemas adaptativos (Banks et al., 1996). Eles possuem a propriedade de sofrer polarização (surgimento de cargas elétricas) quando são deformados por esforços mecânicos externos (efeito piezelétrico direto). Inversamente estes materiais têm sua forma alterada quando seus dipolos se alinham espontaneamente sob ação de um campo elétrico externo, causando deformação da estrutura cristalina (efeito piezelétrico inverso).

Os efeitos de falhas em estruturas podem ser classificados como lineares ou não lineares. Uma situação de falha linear é definida como o caso no qual uma estrutura inicialmente elasto-linear permanece elasto-linear após o dano. As mudanças nas propriedades modais são resultados de mudanças na geometria e/ou nas propriedades da estrutura, mas a resposta estrutural pode ainda ser modelada usando equações lineares de movimento, quando isto não ocorre dizemos que a falha é não linear. Métodos lineares podem ainda ser classificados como métodos baseados em modelos matemáticos ou métodos que não utilizam modelos matemáticos. Um outro sistema de classificação, que define níveis de identificação de falhas, pode ser especificado como:

- Nível 1 – Determinação de que a falha está presente na estrutura.
- Nível 2 – Nível 1 mais a determinação da localização geométrica da falha.
- Nível 3 – Nível 2 mais a quantificação da severidade da falha.
- Nível 4 – Nível 3 mais predição da vida de serviço da estrutura que ainda resta.
- Nível 5 – Nível 3 mais o auto reparo (*self-healing systems*) durante o funcionamento.

Métodos convencionais baseados em medidas de vibrações, geralmente, proporcionam apenas os níveis 1 e 2 de identificação de falhas. Quando métodos baseados em vibração são combinados com um modelo estrutural, nível 3 de identificação de falha pode ser obtido em alguns casos. O nível 4 de predição é geralmente associado com o campo da mecânica da fratura ou análise de vida em fadiga. Centros avançados de pesquisa já trabalham com a possibilidade de auto-reparo em serviço, atingindo assim o nível 5 de identificação. Neste contexto, os materiais inteligentes têm assumido papel de destaque nesta linha de pesquisa.

2. TÉCNICAS DE IMPEDÂNCIA ELÉTRICA E REDES NEURAS ARTIFICIAIS

Esta seção descreve a técnica em que o atuador e sensor são combinados num simples elemento piezelétrico, chamado auto-sensor-atuador. Auto-sensor-atuador tem um número de propriedades desejáveis, para sistemas de controle, não facilmente obtidos com sensores e atuadores separados (Inman, 1990). O atuador é parte integrante da estrutura e a tensão, deformação, campo elétrico e deslocamento elétrico, dentro do material piezelétrico, podem ser completamente descritos por um par de equações eletromecânica. Existem vários pares de equações eletromecânicas e a melhor escolha depende do problema. O material piezocerâmico (PZT) exibe um efeito direcional. Piezeletricidade descreve o fenômeno da geração de um campo elétrico num material quando submetido a uma tensão mecânica. Usando a notação padrão IEEE 176-1987, a tensão, deformação,

deslocamento elétrico de um material piezolétrico pode ser descrito pelas Eq. (1) e (2). As letras nos colchetes indicam as unidades das variáveis no Sistema Internacional de Unidades, com Newton (N), metro (m), voltagem (V) e Coulomb (C).

$$S_{ij} = s_{ijkl}^E T_{kl} + d_{kij}^t E_k \quad (1)$$

$$D_i = d_{ikl} T_{kl} + \varepsilon_{ik}^T E_k \quad (2)$$

onde o superescrito t indica matriz transposta,

i, j, k, l representam os valores 1, 2, 3 (ou x, y, z)

S_{ij} = tensor deformação [m/m]

T_{kl} = tensor de tensão [N/m²]

E_k = campo elétrico [V/m; N/C]

d_{kij} = constante piezolétrica [C/N]

D_i = deslocamento elétrico ou indução [C/m²]

s_{ijkl} = tensor de compliança [m²/N]

ε_{ik}^T = permissividade dielétrica [C²/Nm²]

A impedância elétrica é definida como a razão entre a voltagem de entrada e a corrente resultante. A impedância mecânica é definida como a razão da força aplicada e a velocidade resultante (Ewins, 1991). O transdutor eletromecânico fornece uma maneira de se acoplar as impedâncias elétrica e mecânica. Sendo mais fácil medir a impedância elétrica do que a mecânica, esta característica pode ser utilizada com vantagens para muitas aplicações, onde a FRF poderia ser de difícil obtenção.

Um modelo simples, como mostrado na Fig. (1), pode descrever a interação entre um PZT e a estrutura base. O PZT é considerado como uma barra fina exposta a uma vibração axial em resposta a aplicação de voltagem alternada aplicada. Uma extremidade é fixada e a outra é conectada na estrutura, representada por um sistema de um grau de liberdade.

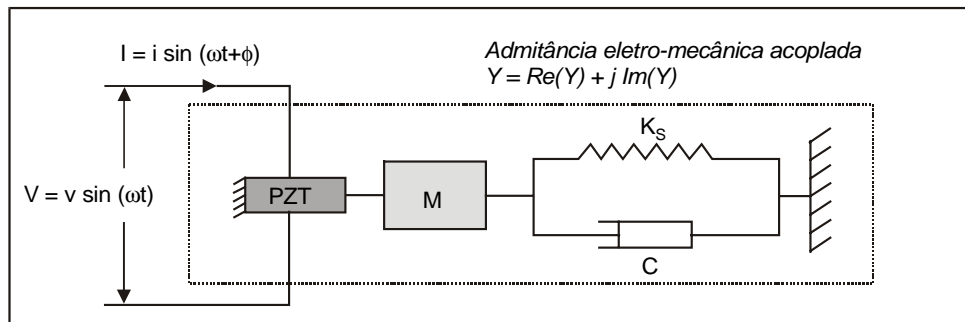


Figura 1. Modelo usado para representar o acoplamento de um PZT com a estrutura base.

$$Z(\omega) = \frac{F(\omega)}{\dot{x}(\omega)} \quad (3)$$

$$Y(\omega) = \frac{1}{Z(\omega)} \quad (4)$$

onde $Z(\omega)$ é a impedância mecânica, $F(\omega)$ é a força de entrada, $\dot{x}(\omega)$ é a velocidade e $Y(\omega)$ é a admitância, a qual é o inverso da impedância. A impedância da estrutura depende da frequência de excitação, ω . A relação força-deslocamento para o sensor/atuator PZT e a estrutura é dado por:

$$F = k_A (x - x_{in}) \ ; \quad k_A = \frac{\bar{Y}_{22}^E w_A h_A}{l_A} \quad (5)$$

$$x_{in} = d_{32} E l_A \ ; \quad \bar{Y}_{22}^E = Y_{22}^E (1 + i\eta) \quad (6)$$

onde x é o deslocamento, F é a força exercida pelo atuador, k_A é a rigidez estática do PZT, w_A , h_A e l_A são largura, espessura e comprimento do PZT respectivamente, x_{in} é o deslocamento do atuador sem indução, \bar{Y}_{22}^E é modulo complexo do PZT para campo elétrico zero, η é o fator de perda mecânica do PZT, E é o campo elétrico e d_{32} é a constante piezoeétrica. Para aplicações dinâmicas, como no caso do monitoramento de condição baseado na impedância, a relação força-deslocamento é baseada no conceito da impedância mecânica. Assumindo um estado harmônico de excitação constante temos,

$$F = -Z \dot{x} = -\left(C + M \frac{\omega^2 - \omega_n^2}{\omega} i \right) (i\omega x) \quad (7)$$

$$F = -k_D x = -\left(iC\omega - M (\omega^2 - \omega_n^2) \right) x \quad (8)$$

onde k_D é a rigidez dinâmica. A relação força-deslocamento dinâmico pode agora ser determinada como:

$$F = -\frac{k_D k_A}{k_D + k_A} x_{in} \quad (9)$$

Redes Neurais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neuronal de organismos inteligentes e que adquirem conhecimento através da experiência. Uma Rede Neural Artificial, considerada grande, pode ter centenas ou milhares de unidades de processamento, já o cérebro de um mamífero pode ter muitos bilhões de neurônios. Redes Neurais tem sido utilizadas na resolução de uma grande classe de problemas encontrados em várias áreas aplicadas: classificação, identificação, diagnóstico, análise de sinais e de imagens, otimização e controle. As Redes Neurais tem se mostrado de fácil implementação, robusta no tratamento de dados com ruído e eficientes, especialmente nos problemas em que não temos formulação analítica ou não temos um conhecimento explícito dos dados ou nos casos onde o próprio problema modifica-se com o tempo. O emprego de uma Rede Neural depende da habilidade em adaptá-la ao problema considerado, por meio de mudanças nos pesos sinápticos (aprendizagem), de modo a aumentar sua eficiência. Uma rede neural compõe-se, basicamente, das seguintes entidades:

- Um conjunto de unidades de processamento, também chamadas de células ou neurônios, agrupados em camadas;
- Uma regra de propagação que determinará como as informações provenientes da camada anterior se propagarão numa entrada efetiva i para os neurônios;
- Uma função de ativação, f , que produzirá o nível de ativação do neurônio, a partir da entrada efetiva i ,
- Uma entrada externa ou um erro sistemático, θ , para cada neurônio e ,
- Um método de armazenamento de informações.

Uma rede unidirecional obrigatoriamente é estruturada em camadas. Neste caso cada camada recebe os sinais provenientes da camada anterior, processa-os e fornece sinais de saída para a camada subsequente, estabelecendo assim o fluxo de informações. Não existem ligações entre neurônios de uma mesma camada. A Figura (2) mostra esquematicamente a estrutura desta rede.

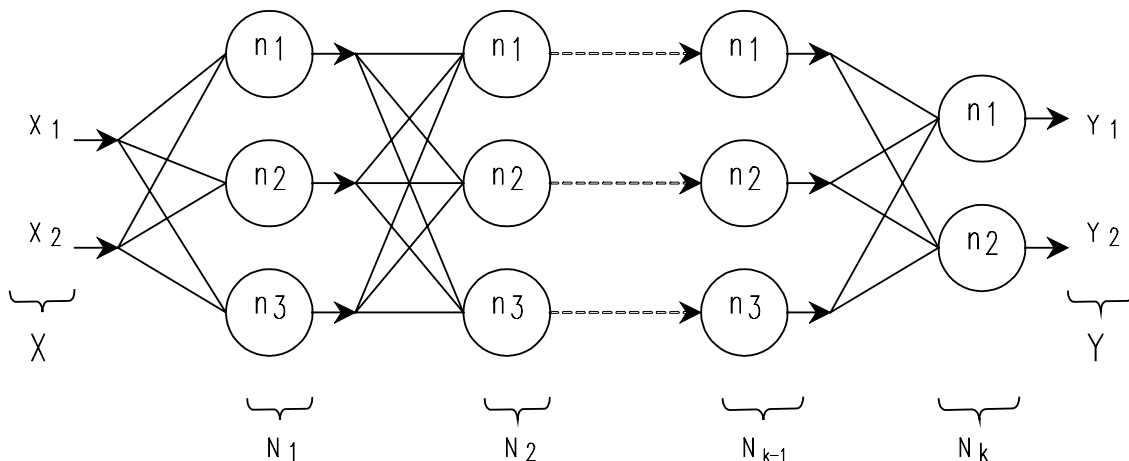


Figura 2. Rede unidirecional multicamadas.

A principal característica de redes neurais é a capacidade de aprender. Neste contexto, a aprendizagem é definida como a variação dos pesos das ligações, de modo a armazenar implicitamente uma dada informação, que poderá ser facilmente recuperada. A regra de propagação utilizada neste trabalho foi retropropagação, ou *back-propagation*. A idéia central desse algoritmo é que o erro de cada camada intermediária é determinado retrocedendo os erros a partir da camada de saída.

3. METODOLOGIA PROPOSTA PARA TÉCNICA DE IDENTIFICAÇÃO DE FALHA

A proposta do esquema de identificação da falha consiste em dois passos, conforme descreve a Fig. (3). No primeiro passo, o método da impedância é utilizado para detectar e localizar a falha estrutural. Se a falha é detectada, as redes neurais são acionadas, as quais são treinadas para cada falha específica, obtendo-se assim uma estimativa da severidade da falha. Este compreende o segundo passo. A técnica de impedância elétrica localiza as falhas na região de influência de cada PZT. Portanto, neste passo o número de redes neurais necessárias deve ser igual ao número de PZT colados à estrutura.

A impedância elétrica é medida em altas faixas de frequências, o que garante grande sensibilidade ao método e a possibilidade de detecção de falhas incipientes. Depois da aquisição da impedância elétrica, os sinais devem ser processados e normalizados, para que representem todas as condições de falhas que se deseja monitorar. Uma das maiores vantagens deste método é que a variação do sinal é local e não afeta os outros sensores (PZT). Portanto, falhas simultâneas que são dificilmente identificadas por métodos convencionais, podem ser tratadas como se ocorressem independentemente.

Teoricamente pode-se usar uma infinidade de dados como entrada para o treinamento da rede. Entretanto, a exatidão e a capacidade de generalização da rede neural é fortemente dependente da escolha do tipo de entrada. Nos exemplos apresentados a seguir se utilizou o algoritmo da retropropagação para o processo de treinamento. O esquema de identificação de falha aqui proposto é baseado na sensibilidade da impedância elétrica e no uso de redes neurais para quantificar a severidade do defeito.

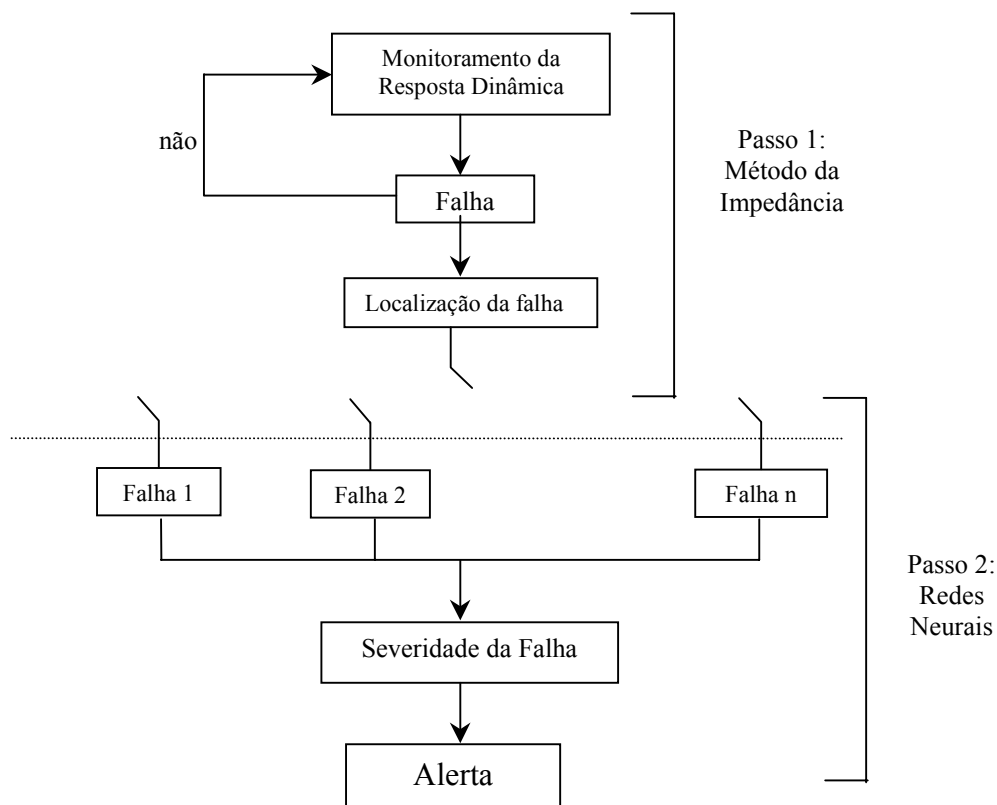


Figura 3. Diagrama do esquema de identificação da falha.

4. RESULTADOS

Neste trabalho realizamos o estudo numérico de uma viga de alumínio com 30 milímetros de largura, 5 mm de espessura e 500 mm de comprimento, para isto modelamos esta viga em elementos finitos através do programa “Smart Beam”, implementado por outros membros do grupo de Materiais e Sistemas Inteligentes do DEM. As matrizes de massa, rigidez e amortecimento foram obtidas deste programa e então todas as falhas puderam ser simuladas e analisadas. A viga foi discretizada com vinte elementos do tipo “BEAM”, com dois graus de liberdade por nó, deslocamento no sentido vertical e rotação em torno do eixo z. Modelamos a viga com uma de suas extremidades engastada e a outra livre, com a força de excitação variável. A Função de Resposta em Frequência (FRF) do sistema foi considerada para diferentes situações de defeitos e de carregamento.

Na montagem da viga simulamos uma falha no elemento cinco, diminuindo os parâmetros da matriz de rigidez para 90, 80, 70, 60, 50 e 40% de seu valor inicial. A massa do elemento também foi modificada, onde para cada caso de diminuição da rigidez ela decresceu em 1%, assim a massa desse elemento foi diminuída para 99, 98, 97, 96, 95 e 94% de seu valor inicial. Em resumo, podemos dizer que temos sete condições para o sistema: a situação sem falha e as outras com seis diferentes tipos de falhas, essas condições foram denominadas de curva 1, 2, 3, 4, 5, 6 e 7 respectivamente. A viga estudada e o elemento cinco onde foi simulado a falha podem ser observados através da Fig. (4).




Figura 4. Viga engastada destacando-se o elemento 5, o qual foi simulada a falha.

4.1. Treinamento da Rede

Para treinarmos a rede e verificarmos sua capacidade de generalização foram utilizados diferentes dados de entrada. Para cada tipo de dado alteramos a configuração da rede de forma a manter uma certa coerência com a quantidade de informações de entrada. No treinamento o valor 0 (zero) foi atribuído a curva sem falha, já o valor 1 (um) correspondia a curva com o máximo defeito. Assim, após o treinamento, quando qualquer uma das curvas simuladas fosse verificada, o valor de saída da rede deverá estar entre os limites 0 e 1 e o resultado indicará a severidade da falha. Uma outra forma de treinamento utilizando os mesmos dados de entrada foi feito variando a configuração da rede. Neste caso para a curva sem defeito foi atribuído a saída 0 (zero), para o defeito intermediário (variação de rigidez no elemento 5 em 30%) o valor 0,3 e para o máximo defeito (variação da rigidez do elemento 5 em 60%) o valor 1. Em suma, para cada tipo de entrada e configuração da rede foi modificado a saída, sendo o primeiro treinamento com as saídas 0 e 1, e o segundo com as saídas 0, 0,3 e 1. O valor 0,3 para o defeito intermediário foi adotado após vários testes e a constatação da variação tipo exponencial, em função do aumento da severidade da falha. Para que a rede apresente boa capacidade de generalização os dados devem ser condensados de forma adequada. Diferentes critérios de condensação de dados foram verificados. Abaixo, apresenta-se, para comparação, os resultados obtidos para dois diferentes tipos de tratamento de dados de entrada.

4.1.1. Treinamento Utilizando Todos os Pontos da FRF

Neste treinamento se utilizou como entrada o logaritmo do valor absoluto da FRF do sistema. No total foram fornecidos 4000 pontos no treinamento para redes com configuração de 20, 30, 50 e 80 neurônios na camada intermediária. Para todos os exemplos, mostrados a seguir, a rede foi mantida com a mesma configuração básica, ou seja: algoritmo de retropropagação, uma camada intermediária e função de ativação sigmoideal. Utilizou-se dois tipos de entrada de dados: no primeiro caso eram fornecidos apenas os pontos extremos, ou seja, dados da estrutura sem defeito e com defeito máximo; no segundo caso era fornecido, a condição intermediária. As Figuras (5) e (6) apresentam os gráficos correspondentes aos dois casos citados.

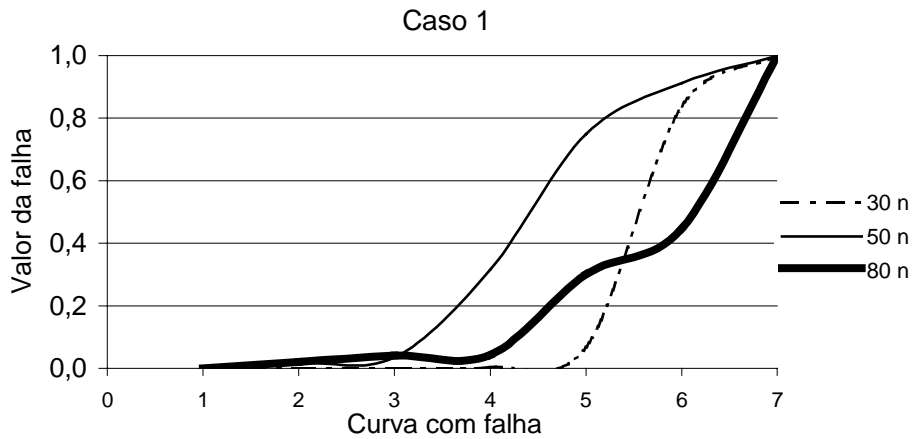


Figura 5. Gráfico do caso 1, treinamento com todos os pontos da FRF

No caso 1, para 20 neurônios na camada intermediária a rede não convergiu para um total de 100.000 interações. Este foi o limite máximo estipulado em todos os treinamentos. Na figura, o símbolo 30n significa 30 neurônios na camada intermediária. A mesma nomenclatura é adotada em todas as figuras.




Figura 6. Gráfico do caso 2, treinamento com todos os pontos da FRF

4.1.2. Treinamento Utilizando a Variação das Freqüências Naturais

Aqui o tipo de entrada utilizada foi a variação percentual das freqüências naturais de cada modo para cada condição de falha. Esta variação é obtida através da Eq. (10). Para este tipo de entrada realizou-se o treinamento para os casos 1 e 2, com 1, 2, 3, 4, 5, 6 e 7 neurônios na camada intermediária. No intervalo de freqüência estudado, 2000Hz, o sistema apresenta sete freqüências naturais. Assim, tivemos sete variações de freqüências que foram utilizadas como entrada. As Figuras (7) e (8) apresentam os resultados obtidos para que se determine a configuração da rede com maior capacidade de generalização.

$$\Delta F = \frac{F_{sem\,falha} - F_{com\,falha}}{F_{sem\,falha}} * 100 \quad (10)$$

onde: $F_{sem\,falha}$ = Valor da freqüência natural sem falha
 $F_{com\,falha}$ = Valor da freqüência natural com falha, para cada situação.

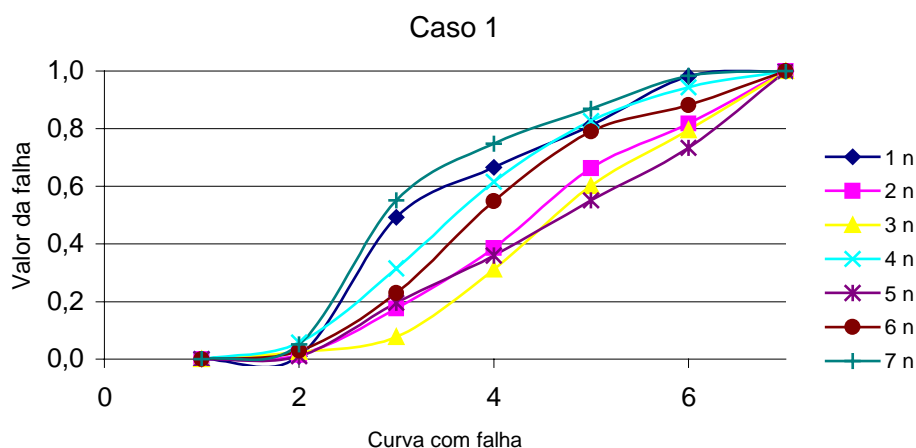


Figura 7. Gráfico do caso 1. Variação percentual das frequências naturais




Figura 8. Gráfico do caso 2. Variação percentual das frequências naturais.

5. CONCLUSÃO

A quantidade de neurônios utilizados na camada intermediária foi escolhida em função da quantidade de dados de entrada. Para o treinamento com todos os pontos da FRF, onde se utilizou 4000 pontos, a quantidade de neurônios foi de 20, 30, 50 e 80, enquanto para o treinamento com a variação percentual da frequência a quantidade de neurônios foi bem menor. Esta escolha apresentou bons resultados uma vez que, quando se utilizou um número pequeno de neurônios no treinamento com todos os pontos ou um número grande no treinamento com a variação percentual das frequências, a rede não convergiu. Isto é devido ao sobreajuste. Para os exemplos mostrados, o caso 2 de treinamento apresentou melhores resultados quando comparado com o caso 1. São considerados resultados satisfatórios, os casos onde a rede apresenta boa capacidade de generalização, isto é, mantém uma evolução exponencial das curvas para os dados que não foram utilizados durante o treinamento.

Embora não mostrados neste artigo, a técnica de impedância elétrica permite localizar a ocorrência de danos simultâneos, pois que o sinal é considerado para altas faixas de frequência e, assim, os defeitos são avaliados segundo a variação dos modos locais. Isto faz com que a variação do sinal de um PZT não interfira significativamente nos outros e as redes possam avaliar cada sinal como se ocorressem isoladamente. De uma maneira geral, podemos afirmar que a rede demonstrou grande capacidade de generalização e, portanto, a adição destas características positivas da rede junto à técnica de impedância elétrica pode fornecer métodos confiáveis e robustos para a localização e identificação de falhas.

6. AGRADECIMENTOS

À Fundação de Amparo a Pesquisa do Estado de São Paulo (FAPESP) pela concessão de bolsa de iniciação científica para o desenvolvimento deste trabalho.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- Ayres, J.W. *Qualitative Health Monitoring and Incipient Damage Inspection/ Evaluation*, Master Thesis, Virginia Polytechnic Institute and State University – CIMSS, 1996.
- Banks, H.T., Inman, D.J., Leo, D.J., and Wang, Y., “An Experimentally Validated Damage Detection Theory in Smart Structures”, *Journal of Sound and Vibrations*, Vol.191, pp. 859-880, 1996.
- Ewins, D.J., *Modal Testing: Theory and Practice*, John Wiley & Sons inc. 1991.
- Inman, D.J., “Control/Structure Interaction: Effects of Actuator Dynamics,” J.L. Junkins, ed. *Mechanics and Control of Large Flexible Structures*, Progress in Astronauts and Aeronautics, 129, pp.507 – 533, 1990.
- Inman, D.J., “engineering Vibration” - Prentice Hall, N. J. ISBN 0-13-518531-9, 1996.
- Kaminski, P.C. Um Sistema de Diagnóstico de Falhas Estruturais Baseado em Redes Neurais Artificiais e Frequências Naturais – Tese de Livre Docência – Escola Politécnica da USP, 1997.
- Lopes Jr., V. and Inman, D. J. Neural Network for Damage and Fault Detection Using Piezoceramic Material as a Sensor And Actuador, Blacksburg, April 1999.
- Lopes Jr., V., Park, G., Cudney, H. H., and Inman, D. J. Impedance –Based Structural Health Monitoring with Artificial Neural Network. *Journal of Intelligent Material Systems and Structures*, USA ,pp 206-214, Vol.11, N.13 March 2000.

STRUCTURAL DAMAGE LOCALIZATION USING PIEZOELECTRIC SENSORS AND ACTUATORS AND ARTIFICIAL NEURAL NETWORKS

Rogério Mendonça Furtado

E-mail: furtado@dem.feis.unesp.br

Vicente Lopes Júnior

Departamento de Engenharia Mecânica

Av. Brasil Centro, 56 – CEP 15.385.000 – Fone (018) 3743 8138 – FAX (018) 3742 2992

www.dem.feis.unesp.br E-mail: vicente@dem.feis.unesp.br

***Abstract.** This work combines electric impedance technique and artificial neural networks to be applied in monitoring systems of machine conditions. The basic concept of predictive maintenance is to monitor the variations of the structural mechanical impedance caused by presence of faults. However the measures of mechanical impedance can be difficultly obtained for complex structures, or systems where the excitation forces are unknown. In this article a non-destructive technique, NDE, using piezoceramic material is proposed. Electric impedance is more easily obtained and it can be correlated to structural mechanical impedance directly. Therefore, by monitoring and comparing it with a reference signal, the structural fault location can be determined. The second step of this methodology uses artificial neural networks to quantify the faults severity. One of the main advantages of this methodology is that so much the step 1 as the step 2 is not set in mathematical model, and, hence it can be applied to complex structure with non-linearity.*

Keywords: *Damage Detection, Smart Systems, Electric Impedance Technique, Neural Networks, Predictive Maintenance.*