

TÉCNICAS NÃO DESTRUTIVAS DE MONITORAMENTO E DETECÇÃO DE FALHAS ESTRUTURAIS UTILIZANDO REDES NEURAIS

Daniela Demarchi

João Antonio Pereira

Vicente Lopes Júnior

UNESP - Ilha Solteira, Departamento de Engenharia Mecânica

Cx. P. 31 – 15 385-000 – Ilha Solteira, SP, Brasil.

Resumo. *A utilização de Redes Neurais como ferramentas não destrutivas vem ocupando espaço na área de manutenção e monitoramento do comportamento vibratório de estruturas e equipamentos mecânicos. O método consiste em monitorar as vibrações da estrutura a ser analisada, e obter dados que a identifique e que sejam adequados para o processo de treinamento da rede. No entanto, existe a necessidade da geração de uma base de dados que contenha todas as diferentes condições de falha (padrões de reconhecimento) para alimentar o treinamento da rede. Este trabalho estuda a capacidade de generalização de Redes Neurais utilizando o método da retropropagação “backpropagation” para classificar sistemas com diferentes razões de rigidez. Isso permitirá definir uma rede que utilize um número limitado de dados para o treinamento e uma vez treinada, a rede poderá ser usada para identificar falhas intermediárias. Várias condições e intensidade de falhas foram estudadas utilizando dados numéricos. A rede mostrou uma boa capacidade de generalização a qual será testada numa próxima etapa com dados reais.*

Palavras-chave: Backpropagation, Identificação de falhas, Redes neurais, Generalização.

1. INTRODUÇÃO

Os equipamentos mecânicos tornam-se, a cada dia, mais complexos para atender as exigências do mercado que demandam equipamentos funcionais e mais flexíveis. Consequentemente, rotinas e ferramentas mais adequadas para o monitoramento e controle das condições de operação e diagnóstico de falhas destes equipamentos são fundamentais visto que, a ocorrência de falha é uma condição provável durante a utilização dos mesmos. A pressão para reduzir o custo de produção tem levado a uma redução do número de pessoas ligadas a manutenção aumentando também a necessidade de sistemas automáticos e confiáveis. Isto tem levado à procura por novos métodos e técnicas, diferentes das técnicas tradicionais de manutenção planejada, capazes de prever o estado de funcionamento dos sistemas.

Os componentes estruturais das máquinas e equipamentos são constantemente submetidos a grandes esforços, em muitos casos esforços dinâmicos de grande intensidade, o que po-

derá levar à deterioração do seu funcionamento e conseqüentemente a uma falha. A propagação destas falhas poderá colocar em risco a utilização do equipamento. Tendo em vista os problemas que podem ocorrer, inclusive catastróficos, com a propagação das falhas torna-se necessário a utilização de métodos eficientes para realizar a detecção e posteriormente a localização de falhas incipientes.

Uma metodologia eficiente para a detecção de falhas estruturais deve ser capaz de acompanhar a evolução da falha, reconhecer padrões de comportamento da estrutura com defeitos em comparação com o comportamento da estrutura sem defeitos. Deve incluir ainda uma capacidade de localizar e quantificar a extensão da falha. Estes requisitos parecem ir de encontro as características de reconhecimento de padrões de sistemas baseados em redes neurais artificiais, RNA (Bernieri, 1994).

Um sistema efetivo de condição básica de manutenção (CBM) deve detectar falhas em uma máquina em um estágio incipiente antes que a mesma atinja um estágio avançado e comprometa ou provoque a falha do equipamento. Desta maneira, os sistemas de monitoramento devem ser projetados para medir e monitorar as variáveis de interesse no controle das condições de operação de máquinas e equipamentos. Algoritmos de diagnóstico devem ser avaliados para converter os dados obtidos do sistema de monitoramento em variáveis que demonstrem o real estado de funcionamento dos equipamentos, com uma interferência mínima do pessoal de manutenção. Portanto, existe uma considerável motivação para o desenvolvimento de sistemas robustos capazes de avaliar automaticamente as condições de funcionamento das máquinas em tempo real. Trabalhos recentes (Kim and Li, 1995) tem mostrado que RN pode responder satisfatoriamente aos requisitos de um sistema efetivo de condição de manutenção básica.

Redes Neurais tem emergido recentemente como uma boa ferramenta para reconhecer alterações nos padrões, tornando-se uma ferramenta promissora para monitoramento e classificação de falhas de máquinas e equipamentos. Neste caso, a rede neural deve ser designada para classificar os padrões de entrada em classes pré-definidas ou criar categorias de grupos padrões de acordo com as suas similaridades (Uh1, 1994; Pereira, Lopes Jr. e Weber, 1999).

Além disso, a rede neural pode responder em tempo real às mudanças na condição do sistema a partir de entradas contínuas produzidas pelos sensores. Um outro aspecto importante é a sua habilidade inerente para operar com ruído, dados incompletos ou esparso e atuar a partir de parâmetros reais. Conseqüentemente, esta técnica deve facilitar a detecção de falhas em tempo real, produzindo uma Técnica não Destrutiva de Detecção para monitorar a condição de operação do sistema baseado nos dados de vibração medidos.

Este trabalho discute a utilização de redes neurais para classificar diferentes estados de operação de um sistema, utilizando o método de retropropagação (backpropagation) para treinamento e classificação dos vários estados do sistema. Diferentes tipos de falhas serão simulados numericamente variando a intensidade e a posição da falha na estrutura. A característica de generalização da rede será avaliada para os diferentes dados obtidos na simulação numérica.

2. CARACTERÍSTICAS GERAIS DA REDE NEURAL MULTI-CAMADAS

Uma rede neural multi-camadas usualmente tem três a quatro camadas de elementos, chamados neurônios, que são classificados como camada de entrada, camadas intermediárias ou ocultas (uma ou mais) e camada de saída (Lucifredi & Hou, 1994). Como ilustrado na figura 1.

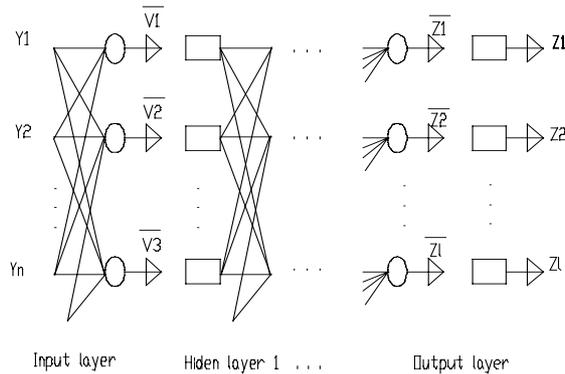


Figura 1- Esboço de uma rede neural multi-camadas.

Cada neurônio em uma camada é ligado a todos os neurônios da camada seguinte. Essas ligações são ponderadas e os valores passam de um neurônio para o próximo. Os dados de entrada são ponderados e passados para a primeira camada oculta e os neurônios da camada oculta são ativados e produzem saídas, as quais são baseadas na somatória dos valores passados a elas, devidamente ponderados pelos pesos, e sobre a função de ativação.

Da mesma forma a primeira camada intermediária passa os valores à segunda camada (se ela existir) e assim sucessivamente. No final os valores são passados para a camada de saída que produzem as saídas da rede.

O primeiro estágio, e o mais importante, de uma rede neural é chamado de “treinamento” ou “aprendizado”. O treinamento faz uso de ajustes de entrada da rede para cada saída desejada. A rede aprende através de ajustagem dos pesos de interconexão entre as camadas, (Wasserman, 1993; Lopes Jr. & Demarchi, 1998). As saídas que a rede está produzindo são repetidamente comparadas com as saídas desejadas e a cada iteração os pesos de conexão são ajustados na direção das saídas desejadas. Um dos algoritmos mais utilizados no treinamento de redes neurais multi-camadas é a retropropagação. A rede é treinada de forma iterativa e os erros de comparação dos padrões são calculados a cada iteração, e o treinamento é considerado satisfatório quando se atinge um valor suficientemente pequeno para o erro.

Se uma rede é bem treinada, isto é, se ela tem uma boa capacidade de generalização, ela pode fazer o trabalho de classificação corretamente para novos dados de entrada que não foram utilizados no treinamento. Ou seja, após o treinamento, a rede está apta à avaliar o comportamento do equipamento, inclusive em condições intermediárias àquelas usadas no treinamento da rede. Isso permite um acompanhamento das condições de operação e a detecção de possíveis mudanças (falhas) do sistema, fornecendo assim subsídios suficientes para decidir sobre a necessidade ou não de uma intervenção no sistema. A intervenção no momento correto evita que o problema detectado afete de forma irreversível a estrutura ou o equipamento.

2.1 Treinamento da rede

Uma rede é treinada para aplicações de grupos de entradas produzirem um grupo de saída desejada. Cada grupo de entrada (ou saída) é referenciado como um vetor. O treinamento é executado seqüencialmente aplicando os vetores de entrada, durante o ajuste dos pesos da rede de acordo com um procedimento pré determinado. Durante o treinamento, os pesos da rede gradualmente convergem para valores de modo que um vetor de entrada produza um vetor de saída desejável. Os algoritmos de treinamento possuem duas categorias: supervisionado que requer o pareamento de cada vetor de entrada com o vetor alvo representando a saída desejada (juntos eles formam um par de treinamento) e o não supervisionado que não requer um vetor alvo para as saídas e, conseqüentemente, sem comparações pré-determinadas.

O algoritmo de treinamento da retropropagação foi criado para generalizar o controle instruído Widrow-Hoff para redes de múltiplas camadas e diferenciar funções de transferência não lineares. Os vetores de entrada e os correspondentes vetores de saída são usados para treinar a rede até ela poder aproximar uma função, associando vetores de entrada com os vetores específicos de saída, ou classificando vetores de entrada em um modo apropriado já definido. O treinamento da retropropagação é usado para ajustar os pesos e o erro sistemático, “bias”, da rede com o objetivo de minimizar a soma dos erros quadráticos (Rumelhart, Hinton, and Williams, 1986). Isto é feito pela mudança contínua dos valores dos pesos e “bias” da rede na direção do menor erro. Este treinamento pode conduzir a um mínimo local. O mínimo local encontrado pode ser satisfatório. Caso contrário, uma rede com mais camadas e neurônios deve ser testada podendo executar uma melhor tarefa. De qualquer modo, o número de neurônios ou camadas a aumentar pode não ser óbvio.

Para treinar uma rede, vetores são apresentados à ela e os seus vetores de saída são calculados e posteriormente, a soma dos erros quadrados é então calculada. Se a soma dos erros quadrados de todos os vetores for menor que o erro meta, o treinamento termina. Se os erros da rede for pequeno o bastante, os vetores podem ser apresentados para a rede e ela responderá com um vetor de saída correto. A topologia e o tamanho da rede dependem da sua aplicação específica e, a definição de uma possível mudança ótima é um caso dependente. Para o problema em estudo utilizou-se o algoritmo *backpropagation* com uma camada intermediária de 3 neurônios e uma camada de saída com apenas 1 neurônio. Utilizou-se a função tangig juntamente com a pureling como funções de transferências no treinamento da rede.

3. PROCEDIMENTOS E GERAÇÃO DOS DADOS PARA O TREINAMENTO

Para se trabalhar com redes é necessário primeiramente definir que estrutura será analisada e definir, através de testes, ou a partir do seu histórico de funcionamento, os dados referentes às várias condições de falha que se pretende controlar. Neste caso, o objetivo maior foi estudar a capacidade de generalização da rede portanto, utilizou-se um conjunto de dados simulados visto que isso permite comparar os resultados obtidos com os valores exatos pois os erros introduzidos são bem definidos.

Os dados foram obtidos utilizando uma viga engastada de seção quadrada de uma polegada e comprimento de 676mm, inicialmente sem falha. Posteriormente, introduziu-se na estrutura dois tipos de falha, uma localizada a 100mm da extremidade engastada e a outra localizada a 608mm, ou seja, próxima a extremidade livre. Em ambos os casos, a intensidade da falha foi variada de 10 em 10% até uma falha máxima de 50% da altura “ a ” da barra, fig. 2. Os efeitos destas falhas são diferentes e apresentam uma variação não linear. Adicionalmente, o comportamento da estrutura varia para cada posição da falha, o que permite estudar como a rede responde a situações críticas (mais sensível) e situações menos severas.

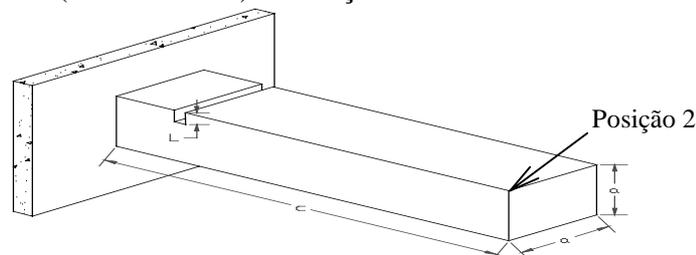


Figura 2 - Representação da estrutura utilizada na medição.

Os dados foram obtidos utilizando um software de simulação desenvolvido pelos autores que permite extrair as frequências, modos próprios e funções de resposta em frequência

FRF(s) da estrutura. Os dados foram calculados para as diferentes condições e intensidade de falhas e comparados com os dados originais calculados para a estrutura sem falha.

O programa permite várias formas de comparação dos dados, o que possibilitou a definição de vários “set” de dados, baseados nas frequências, modos e funções de resposta. Maior atenção foi dada neste caso para a variação das frequências visto que este é um parâmetro global, sensível a falha, e relativamente fácil de ser identificado em situações práticas. Para se escolher o padrão de entrada adequado foram realizados vários testes, pois este é um processo fundamental dentro desta metodologia. Para a entrada de dados foram apresentadas duas condições, a primeira condição (sem defeito) tendo como saída 0 e a segunda condição (com defeito máximo) tendo como saída 1.

Primeiramente, usou-se como dados de entrada para o treinamento da rede a diferença de frequência em porcentagem para situações intermediárias e posteriormente, utilizou-se apenas as condições extremas, falha máxima e sem falha. Como foi possível treinar a rede com estes dados tornou-se interessante então avaliar a capacidade de generalização desta rede, ou seja, apresentar a ela dados não treinados e observar qual a resposta por ela apresentada.

Isto também foi feito para outros dados de entrada tais como, a diferença de frequência ou, uma máscara retangular dos dados. Todo esse processo de treinamento e verificação da capacidade de generalização da rede foi realizado igualmente para a falha localizada próxima da extremidade livre da viga como para a localizada próxima a extremidade engastada. Os dados obtidos estão apresentados a seguir.

4. RESULTADOS

Realizadas todas as etapas descritas anteriormente foi possível então obter os dados utilizados para o treinamento da rede bem como as respostas por ela gerada. A tabelas 1 e 2 apresentam os dados utilizados no treinamento da rede para falhas localizadas próxima do engaste e da extremidade livre respectivamente.

Tabela 1- Dados utilizados no treinamento da rede.

% de Falha	Frequências do 1º ao 5º modo					Diferença de Frequência em Porcentagem do 1º ao 5º modo				
	1º	2º	3º	4º	5º	1º	2º	3º	4º	5º
0%	46.6	291.4	813.8	1588.8	1919.4	0	0	0	0	0
10%	46.3	291.2	814.1	1578.0	1916.6	-0.67	-0.07	0.04	-0.11	-0.15
20%	45.8	290.9	814.3	1583.5	1913.1	-1.70	-0.17	0.06	-0.34	0.33
30%	45.0	290.4	814.4	1576.9	1908.5	-3.33	-0.35	0.07	-0.75	-0.57
40%	43.8	289.6	814.2	1565.1	1902.4	-6.05	-0.63	0.04	-1.49	-0.88
50%	41.5	288.1	813.5	1544.2	1894.0	-10.7	-1.12	-0.04	-2.81	-1.32

Tabela 2- Dados utilizados no treinamento da rede.

% de Falha	Frequências do 1º ao 5º modo					Diferença de Frequência em Porcentagem do 1º ao 5º modo ($\times 10^{-2}$)				
	1º	2º	3º	4º	5º	1º	2º	3º	4º	5º
0%	46.6	291.4	813.8	1588.9	1919.5	0	0	0	0	0
10%	46.6	291.4	813.8	1588.6	1919.8	2.21	0.75	-0.37	-1.56	1.41
20%	46.6	291.5	813.8	1588.2	1920.0	2.20	0.69	-0.70	-2.51	1.40
30%	46.6	291.5	813.7	1587.6	1920.3	2.20	0.59	-1.30	-4.22	1.38
40%	46.6	291.5	813.5	1586.4	1920.6	3.30	0.67	-3.23	-9.99	2.05
50%	46.6	291.5	813.0	1584.0	1920.8	2.18	-0.03	-5.07	-15.08	1.33

Os dados apresentados nas tabela 1 e 2 foram utilizados para o treinamento da rede com diferentes situações de falha. Primeiro, a rede foi treinada para condições de falhas próximas do engaste, utilizando todos os dados referentes às várias intensidade da falha. Os dados apresentados à rede foram as diferenças de frequências, em porcentagem, para a falha localizada próxima a extremidade engastada da viga. Uma vez treinada com sucesso, a mesma foi utilizada para a confirmação do reconhecimento dos dados treinados. A figura 3 mostra a resposta da rede treinada para as várias intensidade de falha testadas.

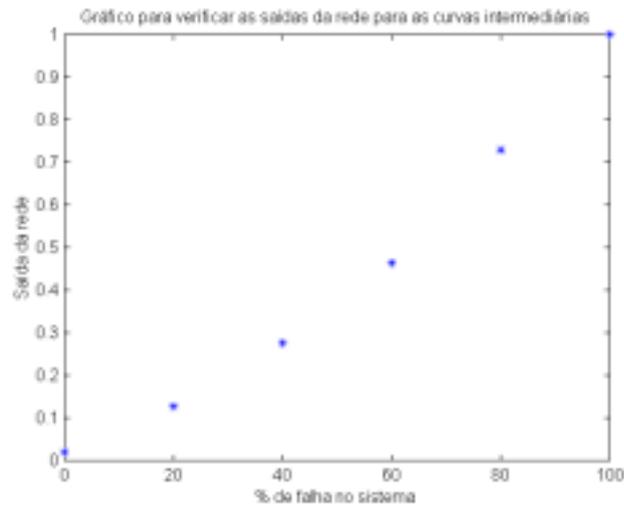


Figura 3- Valores intermediários apresentados pela rede para falha na extremidade engastada.

Uma vez testada a capacidade de reconhecimento da rede utilizando todos os dados, a mesma foi treinada novamente apenas com os dados extremos, para uma avaliação da sua capacidade de generalização. Neste caso, foi utilizado um conjunto “reduzido” de dados, isto é, condição de falha nula e falha máxima, durante o treinamento da rede. Os dados apresentados à rede foram as diferenças de frequência, como no caso anterior. Uma vez treinada com sucesso, a mesma foi utilizada para o reconhecimento de padrões intermediários. A figura 4 mostra os resultados de reconhecimento para situações intermediárias de falha de intensidade igual 20%, 40% Como pode ser observado, neste caso, a rede identifica todas as condições de falhas testadas.

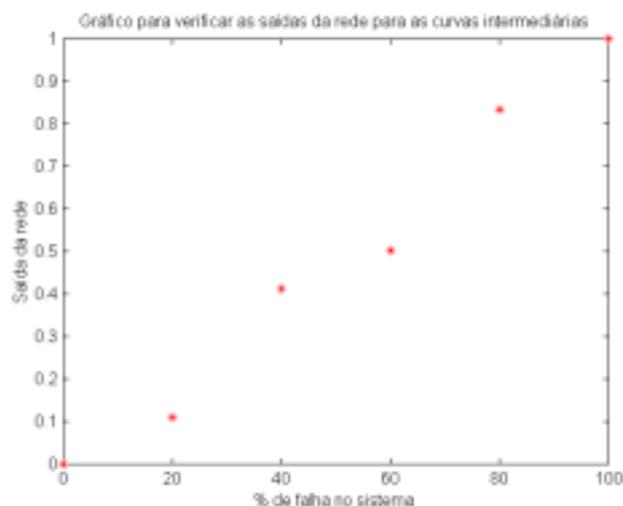


Figura 4- Valores intermediários apresentados pela rede para falha na extremidade engastada.

Numa Segunda etapa, a rede foi treinada para condições de falhas próximas da extremidade livre, utilizando todos os dados referentes às várias intensidade da falha. Os dados apresentados à rede foram as diferenças de frequência, em porcentagem, para a falha localizada próxima a extremidade livre da viga. Uma vez treinada com sucesso, a mesma foi utilizada para a confirmação do reconhecimento dos dados treinados. A figura 5 mostra a resposta da rede treinada para as várias intensidade de falha testadas.

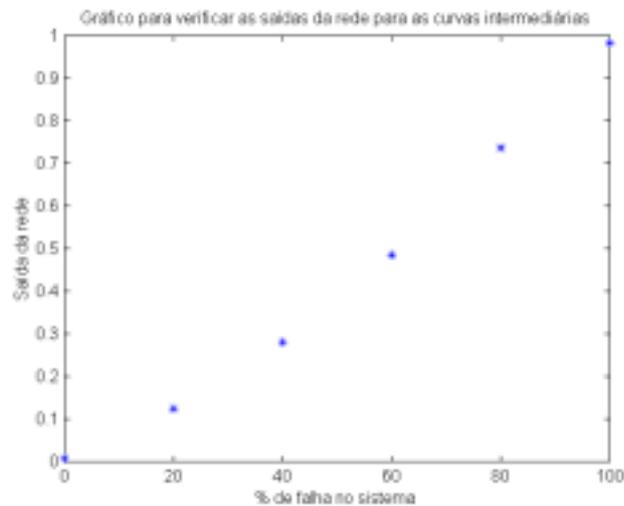


Figura 5- Valores intermediários apresentados pela rede para falha na extremidade livre.

Uma vez testada a capacidade de reconhecimento da rede utilizando todos os dados, a mesma foi treinada novamente apenas com os dados extremos, para uma avaliação da sua capacidade de generalização. Neste caso, foi utilizado um conjunto “reduzido” de dados, isto é, condição de falha nula e falha máxima, durante o treinamento da rede. Os dados apresentados à rede foram as diferenças de frequência, como no caso anterior. Uma vez treinada com sucesso, a mesma foi utilizada para o reconhecimento de padrões intermediários. A figura 6 mostra os resultados de reconhecimento para situações intermediárias de falha de intensidade igual 20%, 40% Como pode ser observado, neste caso, a rede identifica todas as condições de falhas testadas.

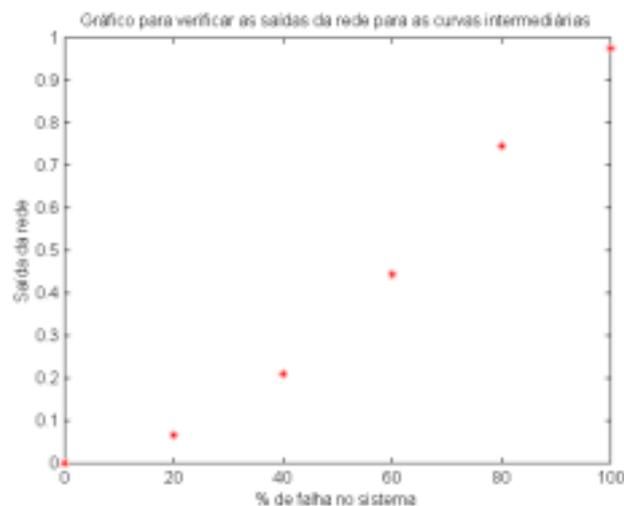


Figura 6- Valores intermediários apresentados pela rede para falha na extremidade livre.

Testes adicionais foram realizados utilizando outras informações extraídas dos dados mostrados nas tabelas 1 e 2, diferença absoluta das frequências, amplitude e frequência obtidas a partir das funções de resposta e frequência. Estes testes visaram observar a resposta da rede para uma mesma situação de falha utilizando outras formas de informações. A seguir será apresentado apenas os resultados utilizando diferenças absolutas de frequência, para o caso 2, devido às limitações de espaço. Os demais casos apresentaram resultados similares. Como nos casos anteriores, a rede foi treinada com todos os dados e, posteriormente, após a comprovação da sua capacidade de reconhecimento, foi treinada apenas com os dados extremos. Os resultados são mostrados nas fig. 7 e 8.

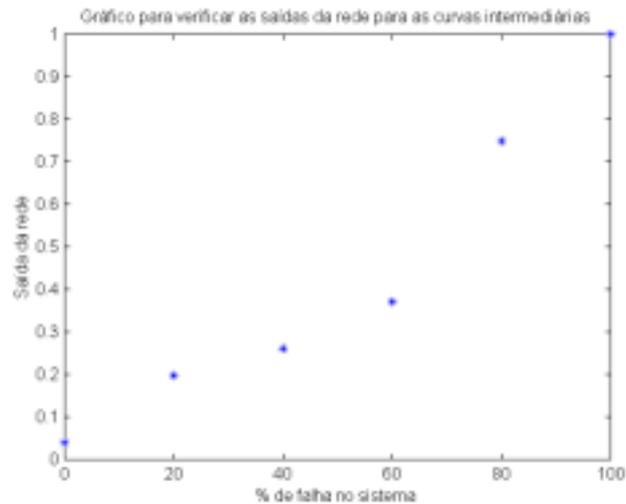


Figura 7- Valores intermediários apresentados pela rede para falha na extremidade livre.

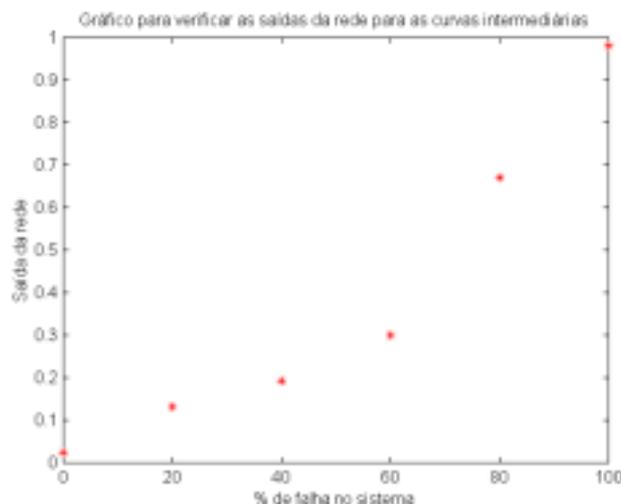


Figura 8- Valores intermediários apresentados pela rede para falha na extremidade livre.

As respostas produzidas pela rede mostram que a influência da falha na estrutura varia de forma não linear com o aumento da sua severidade e que a influência da intensidade da falha tem um comportamento que se aproxima de uma exponencial. Este comportamento foi posteriormente comprovado simulando incrementos na intensidade da falha e calculando as variações das frequências do novo modelo alterado.

Os resultados obtidos mostram que as redes treinadas identificaram corretamente as várias condições de falha e ainda apresenta uma boa capacidade de generalização. Todas as redes

que obtiveram convergência no treinamento utilizando dados reduzidos responderam adequadamente para valores diferentes aos a ela apresentados no treinamento. Esta característica mostra que a sua utilização em situações reais pode representar um grande avanço uma vez que a mesma não necessita de um grande número de padrões de falhas previamente definidos para todas as diferentes condições de falha. Neste caso, a rede pode ser treinada com um conjunto específico (reduzido) de dados, e ser utilizada para a identificação de condições de falhas distintas daquelas usadas no treinamento.

5. CONCLUSÃO

Uma descrição da aplicação de redes neurais como ferramenta não destrutiva para avaliação de falha estrutural foi apresentada neste artigo. Os conceitos e fundamentos básicos envolvidos em redes neurais são apresentados de forma sucinta. Discutiu-se também a capacidade de generalização das redes treinadas com base no método da retroalimentação bem como a sua potencialidade para identificar diferentes mudanças de rigidez estrutural.

A potencialidade da rede neural para quantificar falhas estruturais foi demonstrado com dados numéricos. Em todos os exemplos testados a rede treinada foi capaz de quantificar as falhas introduzidas na estrutura. Resultados positivos foram obtidos também naquelas situações onde o número de padrões utilizados no treinamento da rede continha apenas as informações referentes as falhas de intensidade máxima e mínima.

Os resultados mostraram-se promissores, e a próxima etapa do trabalho será estudar a capacidade de generalização da rede para localizar diferentes posições de falhas e posteriormente utilizar dados experimentais para o treinamento e avaliação do desempenho da rede.

Agradecimentos

Os autores agradecem ao apoio financeiro dado pela Fundação de Amparo à Pesquisa do Estado de São Paulo para o desenvolvimento da pesquisa em nível de mestrado.

REFERÊNCIAS

Bernieri, A. et al (1994); "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems," *IEEE Trans. On Instrumentation and Meas.*, vol. 43, nº 6 pp. 867-873, Dec./94.

Kim, T., & Li, C. J., (1995); "Feedforward neural networks for fault diagnosis and severity assessment of a screw compressor," *Mechanical Systems and Signal Processing*, pp. 485-496.

Lopes Jr., V. & Demarchi, D. (1998); "Identificação de rigidez bilinear em sistemas mecânicos através de redes neurais," *V Congresso de Engenharia Mecânica - Norte Nordeste*.

Lucifredi, A., & Hou, Z., (1994); The construction of neural networks for bilinear systems identification a possible use to crack detection, in: *Proceedings ISMA19- Belgium Leuven*, September, pp. 1139-1149.

Pereira, J. A., Lopes Jr. V. e Weber, H. I., (1999); "Automation in Fault Detection Using Neural Network and Modal Updating", *Journal of the Brazilian Society of Mechanical Sciences*, Vol. XXI.

Rumelhart, D. E., Hinton, G. E., Williams, R. J., (1986); *Learning Internal representation by error propagation*, **Parallel distributing processing: Explorations in the microstructures of cognition V. 1**, MIT Press, Cambridge – M.A., E.U.A..

Uhl, T. (1994); "Automation of monitoring and diagnostic process for rotating machinery using neural networks," *ISMA – Intern. Seminar of Modal Analysis*, Sept./94.

Wasserman, P. D., (1993); **Neural computing – Theory and practice**, Van Nostrand Reinhold, Nova Iorque – N.Y., E.U.A..

NON-DESTRUCTIVE EVALUATION TOOL FOR MONITORING AND DETECTION OF STRUCTURAL DAMAGE BY USING NEURAL NETWORK

Abstract: The use of Neural Network as Non-Destructive Evaluation tool for fault detection based on vibration measurement is gaining more importance in the context of operation condition and health monitoring of mechanical systems. The propose consist in the monitoring of the vibration condition of the structure that will be evaluated in order to define a set of data able to identify it and suitable for the training process. However, there exist the necessity of generation of a large set of data containing the different patterns representing all failure condition that is likely to occur in the structure. This work studies the capability of generalization of Neural Network using the backpropagation algorithm to classify the input patters of a system with different stiffness ratio. This will bring to definition of Neural Networks capable to use a reduced set of data during training phase and, once it is successfully trained, it could identify intermediate failure condition. Several condition and intensity of fault has been studied by using numerical data. The Neural Network demonstrated a good capacity of generalization for all case studied. In a next step this generalization capability will be tested with experimental data.

Keywords: Neural Network, Backpropagation, Generalization, Fault Detection.