



2º CONGRESSO BRASILEIRO DE P&D EM PETRÓLEO & GÁS

DETECÇÃO DE FALHAS UTILIZANDO REDES NEURAIAS ARTIFICIAIS EM ESTRUTURAS PARA A INDÚSTRIA DO PETRÓLEO

José Guilherme C. da Guia, Azevedo L. de Araújo, Antonio Almeida Silva

Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, Departamento
de Engenharia Mecânica, Av. Aprígio Veloso, 882, Bodocongó, C.P. 10.069,
CEP 58109-970, Campina Grande-PB, Brasil

e-mails: guilherme@dem.ufpb.br, azevedo@bol.com.br, almeida@dem.ufpb.br

Resumo – O monitoramento e diagnóstico de falhas em estruturas em geral é um problema de grande interesse em engenharia, pois está presente tanto na fase de fabricação de um componente (avaliação por ensaios não destrutivos), durante sua operação (avaliação da integridade estrutural) e manutenção (monitoramento da condição). Neste trabalho, é analisado um modelo estrutural contendo falhas simuladas ao longo de seu comprimento, onde estas falhas são identificadas através de Redes Neurais Artificiais (RNA). É analisada a eficiência de 15 arquiteturas de redes neurais baseadas no algoritmo *backpropagation* disponível no MATLAB, com treinamento obtido de simulação numérica pelo Método dos Elementos Finitos, a partir do uso das 5 primeiras frequências naturais. Os resultados comprovam que o procedimento adotado permite identificar com bastante precisão a localização de falhas simuladas ao longo da estrutura, apresentando erro máximo da ordem de 2,7%, o que sugere a sua utilização no processo de detecção e previsão da vida útil residual de estruturas.

Palavras-Chave: Método dos Elementos Finitos; Modelagem de Falhas; Redes Neurais Artificiais; Estruturas

Abstract – The monitoring and diagnosis of faults in structures are a problem of great interest in engineering, because it can be present in the stage of a component production (evaluation for non destructive tests), during its operation (evaluation of the structural integrity) and maintenance (condition monitoring). In this work, a structural model containing simulated faults along its length is analyzed, and identified using Artificial Neural Networks (ANN). The efficiency of 15 architectures of neural networks is analyzed based on the backpropagation algorithm (available in MATLAB), with obtained training from numeric simulation by Finite Elements Methods, using the first 5 natural frequencies. The results confirm that the used procedure allows to identify with a good accuracy the location of simulated faults along the structure, with a maximum error of the order of 2,7%, suggesting its use in the detection and prevision process of the residual useful life of structures, based on the location and growth of the faults.

Keywords: Finite Elements Methods, Modeling of Faults, Artificial Neural Network, Mechanical Structures

1. Introdução

Em grande parte das estruturas e equipamentos, que devem garantir alta confiabilidade e segurança operacional (pontes, aeronaves, máquinas rotativas, tubulações industriais, etc.), vêm sendo utilizados, de forma bastante satisfatória, os métodos de ensaios não-destrutivos visando o monitoramento do comportamento mecânico do material e/ou condição de trabalho, podendo-se até em alguns casos se prever a vida útil residual de alguns componentes e com isso planejar paradas estratégicas para a realização de manutenção com segurança e custos adequados.

No caso de estruturas em instalações de grande responsabilidade como na indústria do petróleo, a questão da integridade estrutural vem exigindo cada vez mais um monitoramento rigoroso das condições operacionais, principalmente em estruturas *offshore*, onde uma falha é uma fonte potencial de riscos operacionais e de prejuízos financeiros e ambientais. Uma falha em uma estrutura pode surgir devido à fadiga, à corrosão ou a uma solicitação elevada. Normalmente essas falhas se iniciam com o surgimento de uma pequena trinca localizada em regiões sujeitas a tensões elevadas da junta ou estrutura e, em seguida, vai aumentando, podendo comprometer a integridade da estrutura como um todo, levando-a ao rompimento. Tendo em vista os prejuízos que uma falha estrutural pode causar, é de interesse comum que se desenvolvam sistemas supervisórios de detecção e previsão de falhas nas estruturas que são utilizadas na exploração e produção de petróleo e gás.

Dentre as várias técnicas de detecção de falhas estruturais, pode-se utilizar a análise modal clássica que é baseada na mudança da resposta dinâmica com a variação de parâmetros modais. Nesta análise, as propriedades físicas e geométricas de estruturas sujeitas a forças e excitações externas podem sofrer variações relativas (massa, rigidez, frequências naturais, amortecimento, etc.) e utilizadas como indicadores de parâmetros de condição (McConnell, 1995). Hartnett (2000) e Mangal et al. (2001), concluíram, que as frequências naturais são uma importante ferramenta para o monitoramento de estruturas *offshore* e diagnóstico de falhas.

Nos últimos anos, a busca por um meio de se realizar uma rápida identificação das falhas estruturais com objetivo de detectar uma falha antes que ela cause um colapso, tem levado muitos pesquisadores a verificar a eficiência de redes neurais artificiais. Uma rede neural pode ser definida como um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples (neurônios) capazes de armazenar conhecimento experimental e torná-lo disponível para uso futuro (Haykin, 1999). Vários trabalhos sobre a aplicação de Redes Neurais Artificiais (RNA) na detecção e diagnósticos de falhas são encontrados na literatura (Wu et al., 1992; Alves Jr. et al., 2001; Santiago et al., 2002), sendo as RNA recomendadas para o monitoramento on-line (Lopes et al., 1998), em especial, da integridade estrutural de plataformas *offshore* (Mangal et al., 1996).

Este trabalho se propõe a investigar os efeitos da mudança de posição e tamanho de uma falha introduzida, artificialmente sobre as frequências naturais de uma estrutura simulada via método dos elementos finitos, bem como o treinamento e teste de redes neurais desenvolvidas para localizar este defeito na estrutura, visando dar suporte a investigações experimentais futuras para validação em estruturas de dutos.

2. Modelagem da Estrutura

A estrutura que foi considerada neste estudo consiste de uma barra de aço biengastada submetida a um carregamento transversal de 10KN, distribuído ao longo da barra. Foi adotada uma barra de seção transversal quadrada devido ao fato de que estruturas como esta são utilizadas em plataformas *onshore* e *offshore* variando as dimensões e o carregamento. Esta barra é mostrada na Figura 1.




Figura 1 – Esquema ilustrativo da barra em estudo

Os dados desta barra são os seguintes:

- ✓ Comprimento – $L = 800$ mm;
- ✓ Altura – $H = 30$ mm;
- ✓ Largura – $H = 30$ mm;
- ✓ Módulo de Young – $E = 210,0 \cdot 10^9$ N/m²;
- ✓ Coeficiente de Poisson – $\nu = 0,3$;
- ✓ Densidade – $\rho = 7860$ kg/m³.

O software utilizado para modelar esta barra pelo método dos elementos finitos foi o ADINA System 7.4.0 900 Nodes[®] (Licensed from ADINA R&D, Inc.). Esta barra foi modelada através de um modelo unidimensional empregando elementos de viga. Foi utilizada uma malha, totalizando 897 elementos. Com isso cada elemento possui

0,89mm de comprimento. Este modelo é mostrado na Figura 2, onde pode-se observar o carregamento de 10KN representado pela cor magenta.

A introdução do defeito neste modelo foi realizada considerando um entalhe na seção transversal da barra. Esta consideração foi feita pelo fato de que estruturas semelhantes foram ensaiadas e simuladas (Gomes e Silva, 1990; Alves, 1997), possibilitando a calibração do modelo. Este entalhe foi simulado por um elemento com a altura da sua seção transversal diferente do restante da barra.

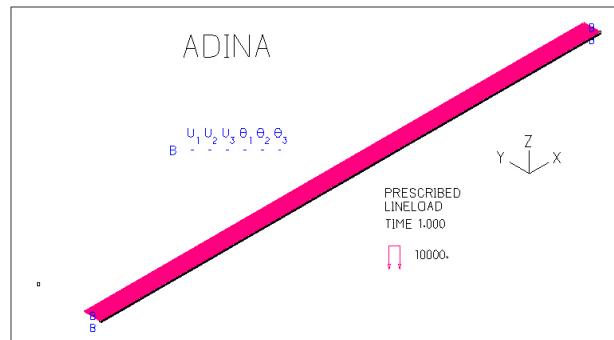


Figura 2 – Modelo da barra em elementos finitos

Foram simulados entalhes para várias posições e profundidades, ilustradas na Figura 3. Com isso cada entalhe é identificado por dois valores numéricos. As posições relativas são descritas pela Equação 1.

$$\frac{L_i}{L} = \{0,0625; 0,1250; 0,1875; 0,2500; 0,3125; 0,3750; 0,4375; 0,5000\} \quad (1)$$

Da mesma forma, as profundidades relativas utilizadas são descritas pela Equação 2.

$$\frac{H_i}{H} = \{0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7\} \quad (2)$$

onde os valores da Equação 2 representam as porcentagens relativas de redução da área transversal.




Figura 3 – Esquema ilustrativo da barra com o entalhe

Logo após a modelagem foram realizadas as simulações, obtendo-se as cinco primeiras frequências naturais da barra sem defeito e da barra com cada entalhe simulado, totalizando 57 simulações. Estas frequências foram armazenadas em um banco de dados. Para ilustrar os efeitos do entalhe sobre as frequências naturais da barra, a Tabela 1 mostra parte deste banco de dados (as frequências obtidas sem defeito e com defeito em uma dada posição), onde se pode observar que as frequências naturais são influenciadas pela presença de um defeito e pela severidade do mesmo.

Tabela 1. Frequências naturais e o efeito do entalhe sobre elas.

Li/L	Hi/H	ω_1 (Hz)	ω_2 (Hz)	ω_3 (Hz)	ω_4 (Hz)	ω_5 (Hz)	
Sem defeito	-	248,878	684,69	1338,15	2202,78	3230,57	
	0,1	248,878	684,673	1337,89	2202,28	3230,40	
	0,2	248,876	684,619	1337,40	2201,37	3230,17	
	0,3	248,869	684,498	1336,48	2199,72	3229,84	
	0,1875	0,4	248,854	684,246	1334,74	2196,65	3229,37
		0,5	248,821	683,709	1331,21	2190,56	3228,66
		0,6	248,742	682,462	1323,32	2177,37	3227,54
0,7		248,525	679,077	1302,77	2145,45	3225,60	

3. Processamento dos Dados

3.1. Pré-Processamento dos Dados

A utilização das frequências naturais diretamente nas redes neurais não é recomendada, pois pode levar a problemas de saturação no processo de treinamento da rede. Para contornar este problema, deve-se realizar um pré-processamento dos dados para adaptá-los às características da RNA.

A partir das frequências naturais do sistema, Alves (1997) realizou um pré-processamento dando origem a dois parâmetros mais eficazes para o a localização e diagnóstico de defeitos. O primeiro parâmetro foi denominado de nfr_i e consiste na média ponderada entre as frequências naturais da barra sem e com defeito. Segundo Alves, este parâmetro depende da localização de um defeito e da variação de rigidez que ele causa. Este parâmetro é dado pela Equação 3.

$$nfr_i = \frac{\omega_{0i} - \omega_i}{\omega_{0i}} \quad (3)$$

onde, ω_{0i} é a frequência natural da barra sem defeito e ω_i é a frequência natural da barra com o defeito.

Já o segundo parâmetro foi denominado de nfm_i e consiste em uma normalização do parâmetro nfr_i . Kaminski (1995) mostrou que o parâmetro nfm_i só depende da localização do defeito. Este parâmetro é dado pela Equação 4.

$$nfm_i = \frac{nfr_i}{\sum_i nfr_i} \quad (4)$$

O parâmetro utilizado em nossas análises foi o nfm_i . Assim foi gerado um novo banco de dados que é o *banco dos dados pré-processados* composto pelo nfm_i das 56 simulações de falhas realizadas.

3.2. Redes Neurais Utilizadas

As Redes Neurais Artificiais são sistemas que possuem a capacidade de aprendizado a partir de um conjunto de informações. O uso de redes neurais é comumente aplicado ao reconhecimento de padrões dado o potencial de aprendizado de funções do sistema. Uma de suas grandes vantagens com relação a outras técnicas de análise é a sua capacidade de tratar sistemas complexos sem a necessidade de utilizar um algoritmo complexo, bastando apenas um conjunto de exemplos para ela aprender como associar esses dados. Na Figura 4 está a representação de uma RNA.




Figura 4. Representação de uma Rede Neural

Em nossas análises foram utilizadas redes neurais do tipo *backpropagation* para processar os dados, com o objetivo de identificar a posição do entalhe na barra. O parâmetro nfm_i depende apenas da localização do entalhe, por isso ele será utilizado como parâmetro de entrada das redes. As arquiteturas das redes foram divididas em dois grupos: redes com uma camada oculta (denominadas $5 \times Y \times 1$, onde Y é o n° de neurônios) e redes com duas camadas ocultas (denominadas $5 \times Y \times Z \times 1$, onde Y é o n° de neurônios na 1ª camada oculta e Z é o n° de neurônios na 2ª camada oculta)

Foi utilizado o Toolbox de Redes Neurais do Software Matlab 6.0[®] (The MathWorks, Inc) para realizar o processamento dos dados a fim de obter a localização do entalhe. As redes neurais utilizadas possuem os seguintes parâmetros:

- ✓ As camadas ocultas são ativadas pela função de ativação *Tangente Hiperbólica*;
- ✓ A camada de saída é ativada pela função de ativação *Linear*;
- ✓ O método de otimização adotado é o método de *Levenberg-Marquardt*;
- ✓ O número máximo de épocas utilizado é *3500 Épocas*;
- ✓ O erro total admissível: *1e-8*.

Para a utilização das RNA, foi necessário dividir o banco dos dados pré-processados em dois novos bancos: o *banco de treinamento* e o *banco de teste*. Sendo o banco de teste composto pelo nfm_i de 12 das simulações retiradas aleatoriamente do banco dos dados pré-processados e o banco de treinamento sendo composto pelo nfm_i das 44

simulações que restaram. Cada rede é treinada com os dados do banco de treinamento e quando o erro de treinamento fica inferior a $1e-8$, a rede é considerada treinada e então é submetida ao teste para verificar a sua capacidade de generalização.

4. Resultados e Discussões

Foram avaliadas várias arquiteturas de redes neurais, variando o número de camadas ocultas e o número de neurônios por camada, para se determinar qual é a configuração mais adequada para o problema da localização do entalhe. Foi utilizado um total de 15 configurações de RNAs. Após essas simulações das redes foi calculado o erro quadrático médio (EQM) para avaliar qual foi a configuração mais eficiente na determinação da posição do entalhe na barra. Estes resultados são apresentados na Tabela 2 juntamente com o erro máximo que foi obtido em cada rede.

Tabela 2. Arquiteturas das Redes Neurais utilizadas, seus EQM e erros máximos obtidos

Arquitetura da Rede	Erro quadrático médio	Erro máximo (%)
5x4x1	6.2303e-4	5,68
5x6x1	5.6120e-4	6,72
5x8x1	5.7068e-4	6,47
5x10x1	5.9235e-4	4,44
5x20x1	0.0014	10,66
5x4x4x1	1.8834e-4	4,68
5x6x4x1	2.7843e-4	4,86
5x6x6x1	1.4642e-4	3,34
5x8x4x1	1.2074e-4	2,71
5x8x6x1	1.8863e-4	3,67
5x8x8x1	2.1179e-4	3,81
5x10x4x1	3.3635e-4	5,83
5x10x6x1	1.4935e-4	3,76
5x10x8x1	2.6124e-4	3,50
5x10x10x1	3.0587e-4	3,83

Pode-se observar da Tabela 2 que as redes de desempenho mais fraco na localização do entalhe foram as redes que possuem apenas uma camada oculta, sendo a rede 5x20x1 a de pior desempenho. Pode-se ainda observar que a rede de melhor desempenho na localização do entalhe foi a rede designada por 5x8x4x1, apresentando um erro máximo de 2,71% (equivalente a 2,17mm) na determinação da posição do entalhe. Os resultados desta rede são mostrados na Figura 5.




Figura 5. Resultados da RNA para a posição do entalhe

Observando a Figura 5 pode-se verificar a boa concordância entre os resultados da saída da rede e os dados do banco de teste. Isso nos permite concluir que a mesma se mostrou eficiente para identificação da posição do defeito, comprovando que a utilização de RNA é uma técnica bastante promissora na análise de integridade estrutural. Vale

ressaltar que a utilização de outras arquiteturas de rede que não foram testadas, outros valores nos parâmetros da rede, outras funções de ativação e um maior banco de treinamento podem levar a resultados ainda mais precisos.

Novos testes estão sendo realizados no sentido de se obter uma rede que, além de identificar a posição do defeito, também realize o diagnóstico do defeito, ou seja, que determine qual a profundidade do defeito, permitindo a simulação do crescimento de uma trinca numa estrutura real. Também serão realizados testes com outros tipos de redes neurais além do *backpropagation*, para se determinar qual é o tipo de rede mais eficaz para a análise estrutural.

5. Conclusões

A partir dos resultados obtidos é possível afirmar que as redes neurais artificiais demonstram ser uma boa ferramenta computacional em relação a outros métodos de identificação, baseados nas variações das frequências naturais de estruturas, para a detecção de falhas nas mesmas, conforme Alves (1997).

Em relação às arquiteturas das redes utilizadas pode-se observar que as redes com duas camadas ocultas apresentaram erros relativos bastante pequenos, especialmente na configuração 5x8x4x1 (erro da ordem de 2,71%), o que leva a concluir que a mesma apresenta boa capacidade de generalização.

Porém, deve-se ressaltar que se fazem necessários estudos mais elaborados no que se refere ao desempenho das redes neurais artificiais aplicadas a problemas mais complexos (ex. estruturas de plataformas *onshore* e *offshore*) sujeitas a solicitações diversas. Estudos neste sentido estão sendo desenvolvidos, onde se procura aplicar testes de desempenho com modelos mais realistas aplicados em um duto de gás e petróleo.

6. Agradecimentos

À Agência Nacional de Petróleo-ANP, à FINEP, ao CTPetro e ao Ministério de Ciências e Tecnologia do Brasil pelo apoio financeiro concedido que viabilizou a realização deste trabalho.

À UFCG/CCT/DEM.

7. Referências

- ALVES JR. M. A., NÓBREGA E. G., PAVANELLO R. Detecção de falha por redes neurais em uma viga flexível. *V Congresso Brasileiro de Redes Neurais*, Rio de Janeiro, RJ, Brasil, p. 61-66, 2001.
- ALVES M. A. L. Utilização de frequências naturais e redes neurais artificiais para detecção de defeitos em estruturas. *Dissertação de mestrado, EPUSP*, São Paulo, SP, Brasil, 1997.
- GOMES A. J. M. A., MONTALVÃO E SILVA J. M. Experimental determination of the influence of the cross-section size in the dynamic behaviour of cracked beams. *Proceedings of the IMMDC2*, Los Angeles, USA, p. 414-423, 1990.
- HARTNETT M. The application of a spectral response model to fixed offshore structures. *Computers and Structures* 78, p. 355-364, 2000.
- HAYKIN S., *Redes Neurais – Princípios e Prática*, Prentice Hall, 1999.
- KAMINSKI, P. C. The approximate location of damage through the analysis of natural frequencies with artificial neural networks. *Proc. Inst. Of Mech. Engrs. – Journal of Process Mechanical Engineering*, 209, 1995.
- LOPES A. P., ANDRADE O. P., VIANNA A. L. Sistemas inteligentes na manutenção preditiva, *T&N Petróleo*, p. 53-55, 1998.
- MANGAL L., IDICHANDY V. G., GANAPATHY C. ART-based multiple neural networks for monitoring offshore platforms. *Applied Ocean Research* 18, p. 137-143, 1996.
- MANGAL L., IDICHANDY V. G., GANAPATHY C. Structural monitoring of offshore platforms using impulse and relaxation response. *Ocean Engineering* 28, p. 689-705, 2001.
- MCCONNELL, K. G., *Vibration Testing - Theory and Practice*, John Wiley & Sons, 1995.
- SANTIAGO D. F. de A., BRITO J. N., PEDERIVA R. Diagnóstico de falhas em máquinas rotativas utilizando redes neurais. *II Congresso Nacional de Engenharia Mecânica*, João Pessoa, PB, Brasil, 2002.
- WU X., GHABOUSSI J., GARRET-JR J. H. Use of neural networks in detection of structural damage. *Computers & Structures*, 42:(4), p. 649-659, 1992.