

08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

IDENTIFICAÇÃO DE DANOS ESTRUTURAIS USANDO REDES NEURAIS ARTIFICIAIS BASEADA EM UM MODELO DE DANO CONTÍNUO

Rosilene Abreu Portella Corrêa¹ - rosileneportella@id.uff.br

Cleber de Almeida Corrêa Junior¹ - cleberacj@id.uff.br

Jorge Luiz Pereira¹ - jorge8000@yahoo.com.br

¹Pós Graduação em Modelagem Computacional em Ciência e Tecnologia - Universidade Federal Fluminense - Santo Antônio de Pádua, RJ, Brazil

Resumo. Danos estruturais, além de comprometer o desempenho da estrutura, ainda podem colocar vidas humanas em risco e causar grandes prejuízos financeiros. O monitoramento contínuo da mesma visa que danos em estágio inicial sejam identificados, aumentando a confiabilidade e a segurança daqueles que a utilizam. Neste trabalho, utiliza-se um modelo de identificação de danos baseado na matriz de flexibilidade estrutural onde o campo de danos para a viga de Euler-Bernoulli simplesmente apoiada é descrito via Método dos Elemento finitos (Stutz, 2005). Apresenta-se uma revisão do desempenho dos modelos de localização de danos analisados por Corrêa, 2013 Corrêa (2013) e apresenta-se resultados da utilização de redes neurais artificiais (RNA) para lidar com os problemas de identificar danos quando dados incompletos são utilizados e quando há presença de sinais corrompidos por ruído.

Keywords: Identificação de danos, Matriz de Flexibilidade, Dados Ruidosos, Rede Neural Artificial

1. Introdução

Estruturas de pequeno ou de grande porte - tais como residências, edifícios, pontes, barragens - desfrutam hoje em dia de avanços tecnológicos ligados a processos construtivos e uso de materiais mais elaborados que aumentam a segurança e a resistência da estrutura. Porém, apesar da sofisticação, as estruturas podem apresentar falhas mesmo em condições normais de uso. Danos estruturais podem prejudicar a performance e a integridade de uma estrutura, podendo colocar em risco vidas humanas. Inserida nesse contexto, a identificação de danos em estruturas é um tópico relevante tanto para o meio acadêmico quanto para a indústria (Cunha (2014)). Por isso, as pesquisas sobre identificação de danos, em uma determinada estrutura, bem no seu início e, o seu contínuo monitoramento, têm chamado a atenção de estudiosos de diversas áreas como: Engenharia Civil, Engenharia Mecânica, Engenharia Naval, Engenharia Aeronáutica, e assim por diante. A identificação do dano na fase inicial permite a redução de custos de

manutenção e reparação, possibilitando um aumento da vida útil da estrutura analisada, além de fornecer segurança e conforto ao ser humano (Carrillo (2007)).

A minimização do funcional criado com base na diferença entre a matriz de flexibilidade numérica e a do experimento sintético do problema de identificação de danos em vigas via métodos de otimização estocásticos apresentou resultados satisfatórios, conforme pode ser visto no trabalho de Corrêa (2013) no qual o dano é continuamente descrito por um parâmetro de coesão via Método dos Elementos Finitos (MEF). Corrêa (2013) apresentou os resultados da identificação de danos em uma viga biapoiada, em uma viga engastada em uma de suas extremidades e em uma placa. No entanto, estruturas mais complexas, onde um grande número de variáveis precisam ser atualizados, podem gerar um grande custo computacional ao se utilizar tais métodos, o que dificulta a sua utilização para um monitoramento contínuo estrutural. Corrêa (2013) fez um estudo sobre diversos métodos de localização de danos, visando utilizá-los a fim de diminuir o número de parâmetros a serem atualizados pelos métodos de otimização. O objetivo era fazer o processo de identificação de danos em duas etapas, onde na primeira etapa se utilizaria um método de localização para determinar a região afetada pelo dano estrutural e, em uma segunda etapa, um método de otimização atualizaria os parâmetros apenas dessa região, diminuindo assim a dimensão do problema. Infelizmente, nenhum dos métodos utilizados apresentou bons resultados quando um número reduzido de graus de liberdade foram medidos, e ainda, foi impossível distinguir a posição do dano na presença de sinais ruidosos. Os métodos de localização de danos analisados foram: Variação na matriz de flexibilidade; Método da curvatura dos modos; Índice de danos baseados na flexibilidade e na curvatura dos modos; Variação na curvatura da flexibilidade; Multiplicação da diferença na curvatura dos modos (MDCM); Critério de confiança modal – MAC; Vetor de localização de dano baseado na matriz de flexibilidade.

Constatada estas deficiências dos métodos de localização estudados, optou-se no presente trabalho, pela utilização de redes neurais artificiais (RNA) para substituir tais métodos nessa primeira etapa do processo de identificação de danos. Diversos autores tem apontado o uso de Redes Neurais Artificiais (RNA) como uma alternativa para lidar com problemas de identificação de danos, devido à sua robutez, adaptabilidade e capacidade de lidar com dados incompletos. A pesquisa e os resultados sobre a utilização de RNA no processo de identificação de danos baseado em um modelo de dano contínuo serão apresentados neste trabalho. Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações). São um conjunto de unidades de processamento que são interligados por um grande número de interconexões (sinapses artificiais).

2. Modelo de Identificação de danos via matriz de flexibilidade estrutural

As frequências naturais e as formas modais não-amortecidas da estrutura podem ser obtidas a partir do problema de autovalores-autovetores

$$(\mathbf{K} - \omega_i^2 \mathbf{M})_i = \mathbf{0}, \quad (1)$$

onde \mathbf{M} e \mathbf{K} são, respectivamente, as matrizes de massa e rigidez, de dimensão $n \times n$, ω_i e i referem-se, respectivamente, à i -ésima frequência natural e à i -ésima forma modal da estrutura.

De forma geral, tem-se

$$\mathbf{K} = \mathbf{M}, \quad (2)$$

onde \mathbf{M} é a matriz modal da estrutura, de dimensão $n \times n$, cuja i -ésima coluna corresponde à forma modal i e $\mathbf{\Lambda}$ é uma matriz diagonal, $n \times n$, formada pelos valores quadráticos das frequências naturais, ou seja, $\lambda_{ii} = \omega_i^2$.

Para as formas modais da estrutura, normalizadas em relação à matriz de massa, tem-se

$${}^T\mathbf{M} = \mathbf{I}; \quad (3)$$

$${}^T\mathbf{K} =, \quad (4)$$

onde \mathbf{I} é a matriz identidade e T representa a transposição de uma matriz.

Partindo da Equação (4) e do fato de a matriz de flexibilidade de uma estrutura ser definida como a inversa da matriz de rigidez, tem-se

$$\mathbf{G} = ({}^{-1}T) = \sum_{i=1}^n \frac{1}{\omega_i^2} \mathbf{m}_i \mathbf{m}_i^T. \quad (5)$$

Na prática, devido a limitações experimentais, tem-se a seguinte aproximação para a matriz de flexibilidade experimental \mathbf{G}_{exp} da estrutura,

$$\mathbf{G}_{exp} = \sum_{i=1}^{n_{exp}} \frac{1}{\omega_{i,exp}^2} \mathbf{m}_{i,exp} \otimes \mathbf{m}_{i,exp} \quad (6)$$

onde $n_{exp} < n$ é o número de modos obtidos do ensaio experimental, $\omega_{i,exp}$ e $\mathbf{m}_{i,exp}$ são, respectivamente, a i -ésima frequência natural não-amortecida e forma modal obtidas experimentalmente.

Da Equação (6), observa-se que, devido à relação inversa com o quadrado da frequência natural, uma boa estimativa para a matriz de flexibilidade pode ser obtida experimentalmente a partir de modos de mais baixa frequência da estrutura, que, na prática, são os modos que podem ser mais facilmente obtidos.

Da Equação (6), deve-se notar que a dimensão da matriz \mathbf{G}_{exp} depende apenas do número m de GDL medidos no ensaio de vibrações, que é equivalente ao número de componentes dos modos experimentais $\mathbf{m}_{i,exp}$. Sendo assim, a matriz de flexibilidade possui dimensão $m \times m$. Portanto, para se definir um problema de identificação de danos estruturais baseado na matriz de flexibilidade, torna-se necessária a determinação de uma matriz de flexibilidade analítica reduzida $\bar{\mathbf{G}}$ — relacionada apenas aos m GDL medidos no ensaio de vibrações — que contenha informações a respeito das propriedades de rigidez da estrutura como um todo. Para tal, a matriz de rigidez original deve ser particionada na forma

$$\mathbf{K} = \begin{bmatrix} \mathbf{K}_{mm} & \mathbf{K}_{mo} \\ \mathbf{K}_{mo}^T & \mathbf{K}_{oo} \end{bmatrix}, \quad (7)$$

onde os índices m e o referem-se, respectivamente, aos GDL *medidos* e *omitidos*. Pode-se mostrar, Alvin et al. (1995), que a matriz de flexibilidade analítica $\bar{\mathbf{G}}$ é igual à inversa da matriz de rigidez reduzida, obtida pela redução estática de Guyan, Guyan (1965), ou seja,

$$\bar{\mathbf{G}} = [\mathbf{K}_{mm} - \mathbf{K}_{mo} \mathbf{K}_{oo}^{-1} \mathbf{K}_{mo}^T]^{-1}. \quad (8)$$

No presente trabalho será considerada uma viga de alumínio simplesmente apoiada com 1,0 m de comprimento, 0,005 m de espessura, 0,05 m de largura, módulo de elasticidade nominal $E_0 = 7,2582 \times 10^{10}$ Pa e momento de inércia de área nominal $I_0 = 5,2083 \times 10^{-10}$ m⁴. A viga

em questão foi discretizada pelo método dos elementos finitos (MEF) em 20 elementos bidimensionais do tipo Euler-Bernoulli. Nos casos considerados neste trabalho, a mesma malha de elementos foi utilizada para aproximar o campo de deslocamentos e também o campo de coesão (dano). Foram adotados elementos com dois nós, onde cada ponto nodal possui dois GDL de deslocamento, um transversal e outro de rotação, e um parâmetro de coesão. A estrutura possui, portanto, um total de 21 nós, 40 GDL, devido às condições de contorno abordadas, e 21 parâmetros nodais de coesão. No entanto, apenas 10 GDL transversais, igualmente espaçados, são considerados medidos.

A imposição do defeito à viga é realizada através de uma redução na altura relativa da seção transversal $h(x)/h_0$, nos nós contidos no interior das regiões defeituosas. Portanto, nos nós defeituosos tem-se $h(x)/h_0 < 1$, e nos nós onde não há danos, tem-se $h(x)/h_0 = 1$.

O MEF, com os valores nodais do parâmetro de coesão prescritos de acordo com os cenários de dano considerados, é utilizado para gerar as frequências e modos de vibração da estrutura danificada, representando assim os dados experimentais sintéticos utilizados no processo de identificação de danos.

3. Definição de Parâmetros - Rede Neural Artificial

Utilizam-se duas funções de ativação que são totalmente diferenciáveis, ou seja, são funções cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de definição.

A primeira delas é a função Tangente Hiperbólica, também conhecida como Função de Transferência Tan-Sigmoid ou *tansig*. O seu gráfico é mostrado na Figura 1.




Figura 1- Função de ativação Tangente Hiperbólica (*tansig*). Fonte: Matlab, Toolbox.

A função de ativação Tangente Hiperbólica (*tansig*) é dada pela Equação (9):

$$g(u) = \frac{1 - e^{-\theta \cdot u}}{1 + e^{-\theta \cdot u}} \quad (9)$$

A outra função de ativação é a Função Logística, também conhecida como Função de Transferência Log-Sigmoid ou *logsig*. O seu gráfico é mostrado na Figura 2.

A função de ativação Logística (*logsig*) é dada pela Equação (10):

$$g(u) = \frac{1}{1 + e^{-\theta \cdot u}} \quad (10)$$




Figura 2- Função de ativação Logística (*logsig*). Fonte: Matlab, Toolbox.

Onde θ é uma constante real associada ao nível de inclinação da função de ativação Tangente Hiperbólica ou Logística em relação ao seu ponto de inflexão.

A arquitetura de RNA adotada, neste trabalho, é a *feedforward* de camadas múltiplas, ou mais especificamente uma rede *Perceptron* de Múltiplas Camadas (PMC). Utiliza-se para o processo de treinamento supervisionado da rede PMC o algoritmo *backpropagation* com *momentum*. A topologia para o PMC deste trabalho é composta pelos seguintes itens:

- 100 sinais ou amostras de entrada;
- 100 neurônios na primeira camada neural escondida, cada neurônio utilizando a função de ativação *tansig*;
- 100 neurônios na segunda camada neural escondida, cada neurônio utilizando a função de ativação *tansig*;
- 100 neurônios na terceira camada neural escondida, cada neurônio utilizando a função de ativação *tansig*;
- 21 sinais associados à camada neural de saída, cada neurônio utilizando a função de ativação *logsig*.

A imposição do dano é realizado escolhendo-se um nó ou posição e um valor para o parâmetro de coesão β . Neste estudo, na fase de treinamento, o valor do β varia no intervalo $[0,4;0,6]$. Porém, na fase de teste, o β assume valores fora desse intervalo para demonstrar a capacidade de generalização das RNA. Nos gráficos dos resultados computacionais, o valor do parâmetro de coesão β é sempre convertido, por conveniência, para $\frac{h(x)}{h_0}$ através da utilização da Equação (11):

$$\beta(x) = \left(\frac{h(x)}{h_0} \right)^3 \Rightarrow \frac{h(x)}{h_0} = \sqrt[3]{\beta(x)} \quad (11)$$

Durante a realização deste trabalho, utilizou-se a fórmula $\|\mathbf{G}_{mm} - \mathbf{G}_{exp}\|$ para gerar os dados de entrada para a RNA. Os resultados encontrados não foram satisfatórios. A partir de então buscou-se um modo alternativo para gerar os dados de entrada. Após algumas tentativas e erros, o meio utilizado para gerar cada padrão de entrada da Rede Neural Artificial foi através da Equação (12).

$$\frac{\|\mathbf{G}_{mm} - \mathbf{G}_{exp}\|}{\|\mathbf{G}_{mm}\|} \cdot 100 \quad (12)$$

A rede PMC foi treinada sem a presença de dados ruidosos, ou seja, com ruídos de 0%. Mas, na fase de teste, foram incluídos dados ruidosos de 3%, como também os de 0%.

3.1 Definição dos Parâmetros de Treinamento da RNA

Os parâmetros de treinamento que produziram os melhores resultados, após a implementação do código criado para a RNA, são os mostrados nos itens abaixo:

- Possui 100 sinais de entrada;
- Três camadas neurais escondidas com 100 neurônios cada uma;
- Uma camada neural de saída com 21 neurônios;
- Funções de ativação: *tansig* nas camadas neurais escondidas e *logsig* na camada neural de saída.
- Algoritmo de treinamento *Gradient descent backpropagation* com *momentum* e taxa adaptativa (*traingdx*);
- Número de épocas ou iterações estabelecidas = 2000000;
- Número de épocas atingido pela RNA após treinamento = 676756;
- Erro final desejado ou estabelecido = 0,0000001 = $1 \cdot 10^{-7}$;
- Taxa de aprendizagem = 0,4;
- Taxa ou coeficiente de *momentum* = 0,6;
- A rede foi treinada atingindo-se o erro estabelecido.

4. Resultados Computacionais

A seguir, serão apresentados e discutidos os resultados obtidos a partir de simulações numéricas com as RNA para identificação de danos em uma viga simplesmente apoiada de Euler-Bernoulli, após o treinamento e teste da rede. A Tabela 1 exibe as 4 posições escolhidas para testar a rede neural após o treinamento. Na primeira coluna da Tabela 1 há a posição ou nó onde o dano foi imposto, na segunda coluna colocou-se o valor do parâmetro de coesão β e na terceira coluna o valor do $\frac{h(x)}{h_0} = \sqrt[3]{\beta(x)}$.

A RNA treinada será avaliada em relação à sua capacidade de localizar e quantificar o dano imposto na viga em estudo mesmo quando os sinais estão corrompidos por ruído.

Com o objetivo de simular de forma mais realística os dados experimentais, a simulação da presença de ruído nas medições foi abordada, adicionando-se às formas modais de vibração uma perturbação aleatória com distribuição uniforme. Os modos de vibração, com imposição de ruído, são então fornecidos através da seguinte formulação (Equação 13),

Posição para Teste	β	$h(x)/h_0$	
4	0,512	0,8	Caso 1
10	0,512	0,8	Caso 2
13	0,512	0,8	Caso 3
16	0,6	0,84	Caso 4

Tabela 1- Posições escolhidas para testar a RNA após o treinamento.

$$\Phi_r(ij) = \Phi(ij)(1 + \frac{p}{100}\text{rand}(-1, 1)), \quad (13)$$

onde Φ_r corresponde aos modos de vibração contaminados por ruído e Φ aos modos de vibração originais; p é o nível de ruído acrescentado; e $\text{rand}(-1, 1)$ é uma função geradora de números aleatórios no intervalo $(-1, 1)$.

4.1 Caso 1 - Com Ruído de 0% e 3%

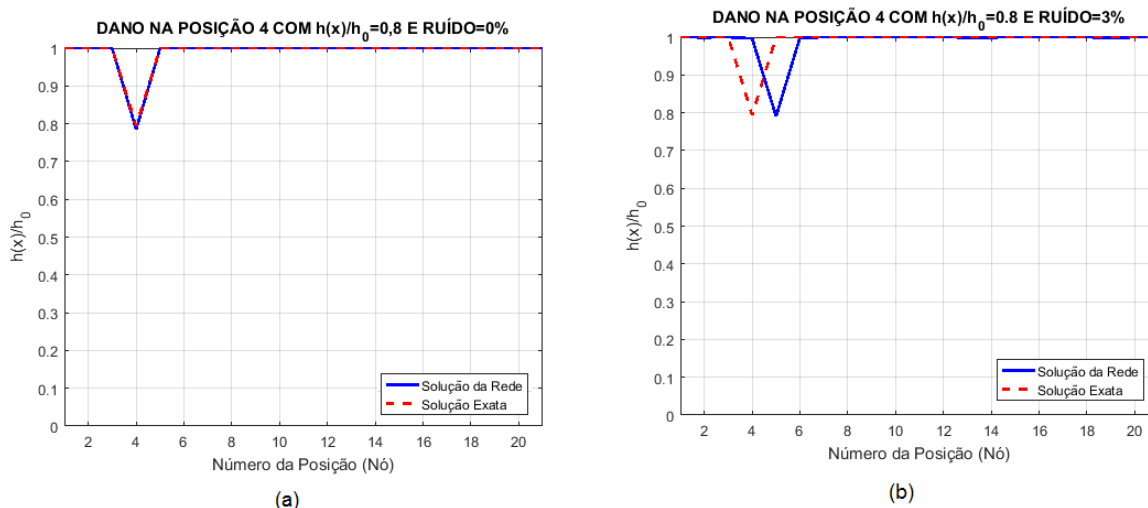


Figura 3- Dano na posição 4 da discretização da viga.

Os resultados obtidos considerando medições sem interferência de ruído nos sinais, representam uma situação ideal. Utilizamos esses resultados para mostrar a capacidade do método proposto em identificar danos caso fosse realizado algum tratamento nos sinais obtidos de forma a eliminar tais perturbações. Como pode ser visto nas Figura 3, para um dano considerado na posição 4 da discretização da viga, o método proposto conseguiu localizar e quantificar o dano com bastante exatidão, quando não foram considerados ruídos de medição (Figura 3(a)). Com a adição de ruído igual a 3% nos modos de vibração, o modelo de identificação de danos apresentado não conseguiu localizar o dano, mas, conseguiu indicar a região do dano (Figura 3(b)).

4.2 Caso 2 - Com Ruído de 0% e 3%

Novamente, pode-se verificar pela Figura 4 que o modelo de identificação de danos proposto usando RNA conseguiu localizar e quantificar satisfatoriamente o dano, quando não foram considerados ruído de medição (Figura 4(a)).

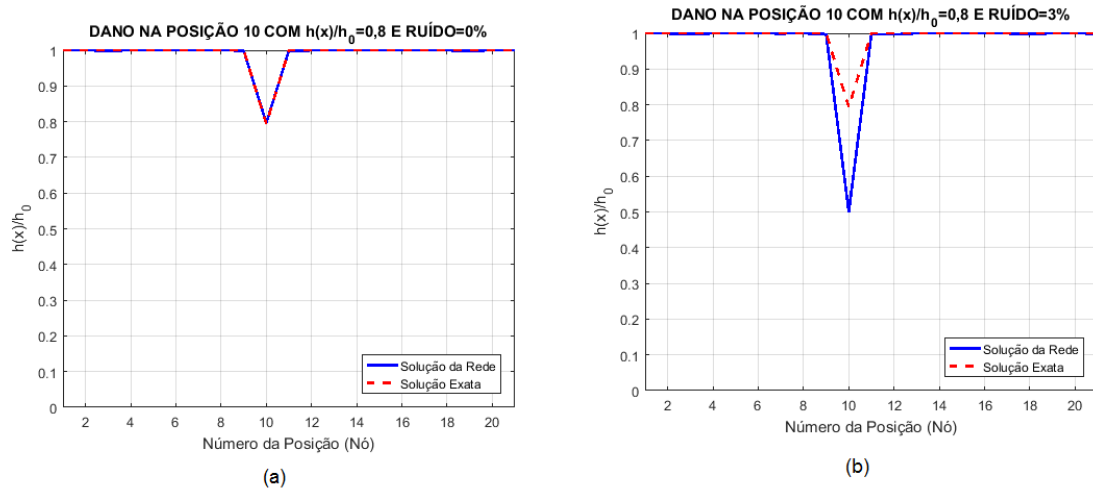


Figura 4- Dano na posição 10 da discretização da viga.

Considerando a posição 10 da discretização da viga e os dados contaminados com ruído de 3%, o método utilizado conseguiu localizar a posição do dano com exatidão, mas não quantificou o dano corretamente (Figura 4(b)).

4.3 Caso 3 - Com Ruído de 0% e 3%

Considera-se, agora, um dano próximo da região central da viga, sem a adição de ruído aos modos de vibração. Pode-se verificar que o método utilizado neste trabalho conseguiu localizar e quantificar o dano com bastante exatidão (Figura 5(a)).




Figura 5- Dano na posição 13 da discretização da viga.

Considerando-se os dados contaminados com ruído de 3%, percebe-se que a região onde a estrutura encontra-se danificada foi localizada, mas em uma posição adjacente ao nó onde foi imposto o dano (Figura 5(b)). Mostra-se que o método conseguiu localizar e quantificar o dano satisfatoriamente mesmo considerando-se dados ruidosos.

4.4 Caso 4 - Com Ruído de 0% e 3%

Para o caso considerado onde um dano é imposto na posição 16 da discretização da viga de Euler-Bernoulli, o modelo de identificação de danos apresentado conseguiu localizar e quantificar o dano com bastante exatidão (Figura 6(a)). Vale ressaltar que não foram considerados dados contaminados por ruído.

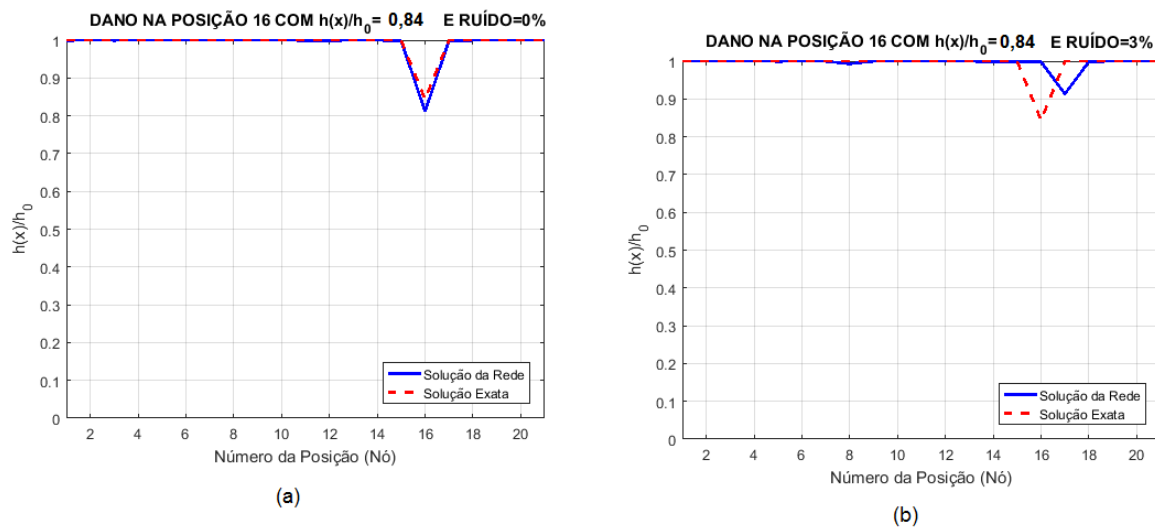


Figura 6- Dano na posição 16 da discretização da viga.

Considerando-se os dados contaminados com ruído de 3%, percebe-se que a região onde a estrutura encontra-se danificada foi localizada, mas em uma posição adjacente ao nó onde foi imposto o dano (Figura 6(b)).

5. CONCLUSÕES

A presença de dano foi descrita através de um parâmetro estrutural denominado parâmetro de coesão, utilizando-se para isso a modelagem do campo de danos através do método de elementos finitos. A utilização do parâmetro de coesão para simulação e identificação de danos difere da maioria das abordagens de identificação de danos encontradas na literatura, possibilitando a simulação de danos em estágio inicial de forma mais suave e realística. Por meio desta formulação é possível representar diferentes perfis de dano, assim como simular uma malha de danos diferente da malha de deslocamentos utilizadas.

Foram analisados os resultados obtidos de diversas simulações de dano na ausência de ruído e na presença de sinal ruidoso. Na presença de ruído de (3%), considerado um nível de ruído elevado segundo a literatura, os resultados foram bastante satisfatórios, pois em todos os casos considerados a região do dano foi encontrada e uma estimativa para a intensidade do dano

foi fornecida. Sendo assim, o método proposto é promissor na substituição dos métodos de localização apresentados por Corrêa (2013), na tentativa de diminuir o número de parâmetros a serem atualizados pelos métodos de otimização quando estruturas mais complexas forem estudadas. Cabe salientar que, diferentemente dos métodos de localização citados, o presente método apresentou resultados satisfatórios na presença de dados ruidosos e com um número reduzido de informação modal. Além disso, o método tem potencial para, sozinho, localizar e quantificar danos em estruturas mais complexas. Por serem as Redes Neurais Artificiais, após a fase de treinamento da mesma, uma ferramenta que fornece os resultados dos testes solicitados de forma rápida, acredita-se, diante dos casos de danos analisados, que a mesma é uma boa opção para diminuir o tempo gasto com a geração de resultados usando métodos de otimização estocásticos, facilitando assim o monitoramento contínuo da estrutura.

REFERÊNCIAS

- Alvin, K.F.; Peterson, L.D, Park, K.D. (1995), “Method for determining minimum-order mass and stiffness matrices from modal test data, *AIAA Journal*, Vol. 1, n. 33, pp. 128–135.
- Corrêa, R.A.P. (2013), “*Identificação de danos em estruturas bi-dimensionais via matriz de flexibilidade baseada em um modelo de danos contínuos*”, Tese de Doutorado, IPRJ/UERJ, Nova Friburgo.
- Cunha, L.N.M. (2014), “*Identificação de danos em placas utilizando a matriz de flexibilidade*”, Tese de Doutorado, UFRJ, Rio de Janeiro.
- Carrillo, O.J.B.; LAIER, J.E. (2007), “*Algoritmo híbrido para avaliação da integridade estrutural: uma abordagem heurística*”, Tese de Doutorado, UFSCar, São Carlos.
- Guyan, R.J.(1965), “*Reduction of stiffness and mass matrices.*”, *American Institute of Aeronautics and Astronautics Journal*, Vol. 3, n. 2, pp. 380.
- Stutz L.T., Castello, D.A., Rochinha, F.A. (2005), “*A flexibility-based continuum damage identification approach*”, in *Journal of Sound and Vibration*, Vol. 279, pp. 641–667.

ESTRUCTURAL DAMAGE IDENTIFICATION VIA ARTIFICIAL NEURAL NETWORK BASED ON CONTINUOS DAMAGE MODEL

Resumo. *Structural damage, as well as compromising the performance of the structure, you can still put lives at risk and cause major financial losses. The continuous monitoring of the same aims that damage in the initial stage are identified, increasing the reliability and security of those who use it. In this study, it uses a model of identification of damage based on the matrix of structural flexibility where the field of damage to Euler-Bernoulli beam simply supported is described via the Finite Element Method (Stutz et al (2005)). It presents a review of the performance of the models of location of damage analyzed by Corrêa (2013) and suggests the use of artificial neural networks (ANN) to deal with the problems of identifying damage when incomplete data are used and when there is presence of signals corrupted by noise. In this work, numerical results for a Euler-Bernoulli beam are presented.*

Keywords: *Damage Identification, Flexibility Matrix, Noise data, Artificial Neural Network*