



XXXVII IBERIAN LATIN AMERICAN CONGRESS
ON COMPUTATIONAL METHODS IN ENGINEERING
BRASÍLIA - DF - BRAZIL

DETECÇÃO DE DANO ESTRUTURAL EM PÓRTICOS PLANOS UTILIZANDO REDES NEURAIS ARTIFICIAIS

Renato A. Maia

Graciela N. Doz

renatomaia06@gmail.com

graciela@unb.br

UnB – Universidade de Brasília

Programa de Pós-graduação em Estruturas e Construção Civil, Prédio SG-12, 1º andar,
Campus Darcy Ribeiro, Universidade de Brasília, CEP 70910-900, Brasília - DF, Brasil.

Resumo. *Conforme as tecnologias de projeto e construção avançam, as estruturas tendem a surgir cada vez mais esbeltas, o que as torna mais vulneráveis a vibrações excessivas. Aliado a isso, a possível degradação estrutural de construções antigas tem gerado um crescimento no desenvolvimento e aprimoramento de técnicas de monitoramento de integridade estrutural, em especial ferramentas que fazem uso das propriedades dinâmicas das estruturas (frequências naturais e modos de vibração), visto que estas sofrem alterações quando há mudanças nas propriedades físicas da estrutura. Neste sentido, métodos capazes de identificar alterações nas propriedades dinâmicas e utilizá-las para localizar e quantificar possíveis danos estruturais tornam-se de suma importância para o bom funcionamento de um sistema de monitoramento de integridade estrutural, como é o caso da técnica de Redes Neurais Artificiais (RNAs). Esta é uma técnica matemática que, quando utilizada juntamente com as características dinâmicas, mostra-se capaz de indicar até as menores alterações na integridade de elementos estruturais. Neste contexto, cinco RNAs com o algoritmo Backpropagation foram treinadas e testadas utilizando, para cada uma, um dos cinco primeiros modos de vibração de vários modelos numéricos de um pórtico plano, visando a localização de danos. Após o processamento, os resultados foram analisados tanto na fase de treinamento quanto na fase de teste, o que permitiu avaliar o desempenho das RNAs no que diz respeito à detecção de danos estruturais.*

Palavras-chave: *Redes Neurais Artificiais, Propriedades dinâmicas, Identificação de danos estruturais.*

1 INTRODUÇÃO

Atualmente no Brasil e no mundo tem-se optado por estruturas cada vez mais esbeltas, a fim de otimizar o custo e o desempenho das construções. Isto as deixa mais vulneráveis às ações estáticas e dinâmicas que podem causar problemas como corrosão, vibração excessiva e, em casos mais graves, o colapso estrutural.

Tendo isso em mente, faz-se necessário o monitoramento e controle de estruturas a fim de encontrar possíveis falhas estruturais em seus estágios iniciais e poder assim manter os padrões de conforto e segurança.

Existem hoje várias metodologias de detecção de dano, desde métodos puramente qualitativos como simples identificação visual, até métodos mais precisos como raios-x e ultrassons; porém, nestes é necessário conhecer de antemão a provável localização do dano, visto que seu uso em toda a estrutura seria muito custoso.

Uma alternativa interessante na avaliação da integridade estrutural é o uso das características dinâmicas (frequências naturais e modos de vibração) já que elas dependem, fundamentalmente, da massa e rigidez da estrutura. Assim, a comparação entre as características dinâmicas de uma estrutura intacta e outra danificada pode ser útil na avaliação de danos.

Para poder fazer esse tipo de comparação é necessário o monitoramento periódico ou contínuo da estrutura em estudo, e isso significa trabalhar com um conjunto grande de dados. Nesse sentido, as Redes Neurais Artificiais (RNAs) mostram-se ótimas ferramentas por sua capacidade de tratar dados ainda que estejam incompletos e com ruídos.

Em um trabalho recente, Paulraj *et al.* (2012) realizaram testes dinâmicos de vibração a fim de obter os modos de vibração de placas de aço intactas e danificadas e utilizá-los para treinar uma RNA capaz de localizar e classificar o dano presente nas placas. Os resultados foram satisfatórios, apresentando um erro máximo de 7% na localização do dano.

Outro trabalho recente, realizado por Hakim *et al.* (2012), utilizou a técnica de RNAs na localização e quantificação de danos vigas de aço de perfil tipo I, baseando-se no comportamento dinâmico das mesmas. A rede foi treinada e testada utilizando frequências naturais e modos de vibração obtidos através de análises numérica e experimental de vigas intactas e danificadas. Verificou-se que os resultados obtidos foram satisfatórios tanto para localização quanto para quantificação dos danos.

Como mostrado acima, pesquisas atuais tem mostrado que a utilização de RNAs em conjunto com a resposta dinâmica de uma estrutura possibilita a detecção, localização e até a avaliação da intensidade de dano que a mesma possa ter sofrido.

Neste trabalho são estudados numericamente pórticos planos de iguais características físicas e geométricas, sendo um intacto e os outros contendo uma redução local na rigidez de alguns de seus elementos de modo a simular diferentes cenários de dano. Os modos de vibração destes modelos são utilizados no treinamento de uma RNA a fim de detectar e localizar o dano inserido. A partir da rede treinada, pórticos com outros cenários de dano são avaliados e os resultados analisados criticamente.

2 REDES NEURAIS ARTIFICIAIS (RNAs)

Redes neurais são sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios) que calculam determinadas funções matemáticas (normalmente não lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Na maioria das redes estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado na rede e servem para ponderar a entrada recebida por cada neurônio. O funcionamento destas redes é inspirado em uma estrutura física concebida pela natureza: o cérebro humano (Braga *et al*, 2000).

O sistema neural humano, através de sua rede de neurônios, tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência e, ainda, interpretar observações. Deste modo, inspirada no funcionamento deste sistema, a RNA simula essa estrutura em que o cálculo é processado através de unidades simples, chamadas de neurônios artificiais, os quais são conectados entre si de modo a formar uma rede.

Neste trabalho foram utilizadas RNAs de múltiplas camadas com algoritmo de treinamento do tipo *Backpropagation* e formadas por neurônios artificiais agrupados em camadas. Estes neurônios são interligados de modo que os cálculos são processados entre as camadas que compõem a rede (camada de entrada, camadas intermediárias e camada de saída), como é mostrado na Fig. 1.

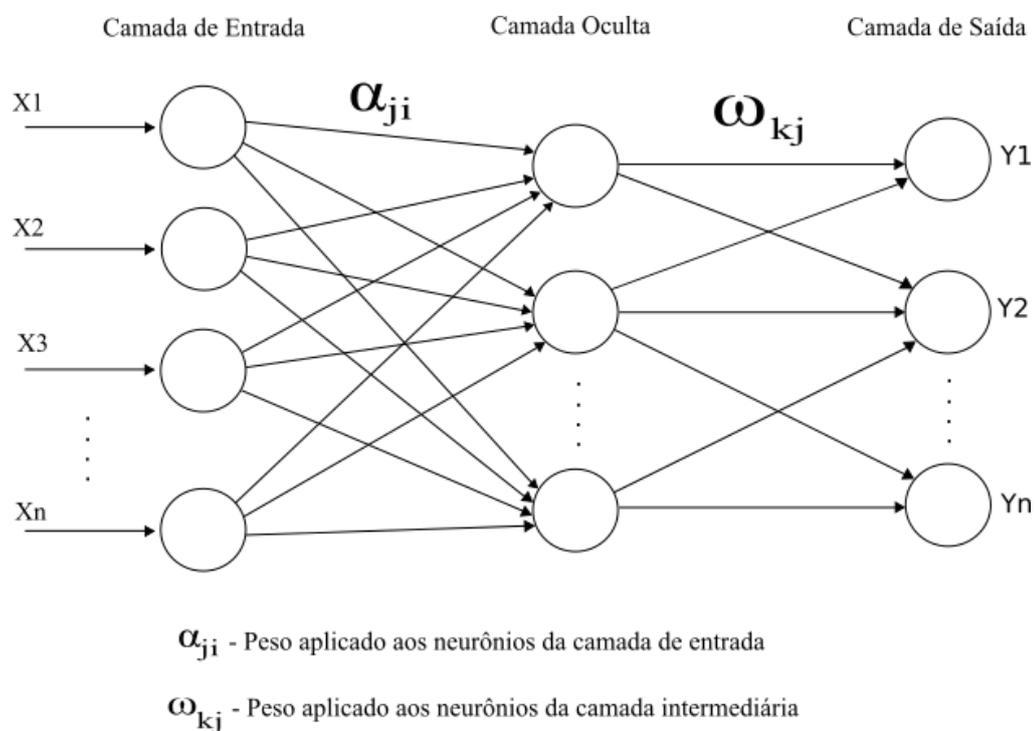


Figura 1 – Estrutura da RNA de múltiplas camadas.

O número de camadas intermediárias existentes na rede varia de acordo com o problema a ser resolvido, uma vez que o aumento de camadas melhora o desempenho da RNA, muito

embora aumente significativamente o tempo de processamento e a quantidade de memória para o armazenamento de informações.

A principal característica das RNAs é a sua capacidade de aprender a partir de exemplos e generalizar tal aprendizado. Para tal, a rede precisa passar por um processo de treinamento ou aprendizado, que consiste, basicamente, no ajuste de pesos das ligações entre os neurônios de camadas diferentes, através de um processo iterativo, no qual a rede recebe um conjunto de dados conhecidos (dados de entradas com respostas conhecidas) para que seja possível estabelecer uma relação entre as informações de entrada e saída.

Inicialmente os dados de entrada (X_1, X_2, X_3, X_n) são fornecidos à camada de entrada. Os valores iniciais dos pesos são determinados aleatoriamente (α_{ji} e ω_{kj}) e, juntamente com as funções de ativação (f_1 e f_2), são utilizados para relacionar os dados de entrada e saída, processando as respostas de cada camada e chegando ao resultado final da RNA (Y_1, Y_2, Y_n), dado pela Eq. 1.

$$Y_k = f_1\left(\sum_{j=1}^S \omega_{kj} \cdot f_2\left(\sum_{j=1}^S \alpha_{ji} X_i + 1\right) + 1\right) \quad (1)$$

O resultado da rede é então comparado com o resultado esperado, obtendo assim uma diferença. Os pesos então devem ser corrigidos a fim de diminuir este erro. Quando o valor deste erro for satisfatório para o usuário, a rede pode ser considerada treinada. Em seguida é realizada a validação da rede, na qual são simulados dados com valores de saída conhecidos utilizados no treinamento. Por fim é feita a generalização da rede, simulando dados diferentes daqueles utilizados no treinamento e na validação. Caso o usuário esteja satisfeito com os resultados, o processo de treinamento da rede é encerrado e esta está pronta para ser utilizada.

3 MODELOS ANALISADOS

A estrutura estudada neste trabalho é um pórtico plano metálico como ilustrado na Fig. 2, tendo suas propriedades físicas e geométricas mostradas na Tabela 1.

Tabela 1 – Propriedades do pórtico estudado.

Propriedades	Vigas	Pilares
Material	Alumínio	Aço
Momento de Inércia - I	$1.83 \times 10^{-9} \text{ m}^4$	$6.48 \times 10^{-12} \text{ m}^4$
Área da Seção Transversal - A	$2.42 \times 10^{-4} \text{ m}^2$	$3.72 \times 10^{-5} \text{ m}^2$
Módulo de Elasticidade - E	$7.2 \times 10^{10} \text{ N/m}^2$	$2.0 \times 10^{11} \text{ N/m}^2$
Coefficiente de Poisson - ν	0.33	0.30
Massa Específica - ρ	7800 kg/m^3	7860 kg/m^3
Comprimento - L	0.19 m	0.40 m

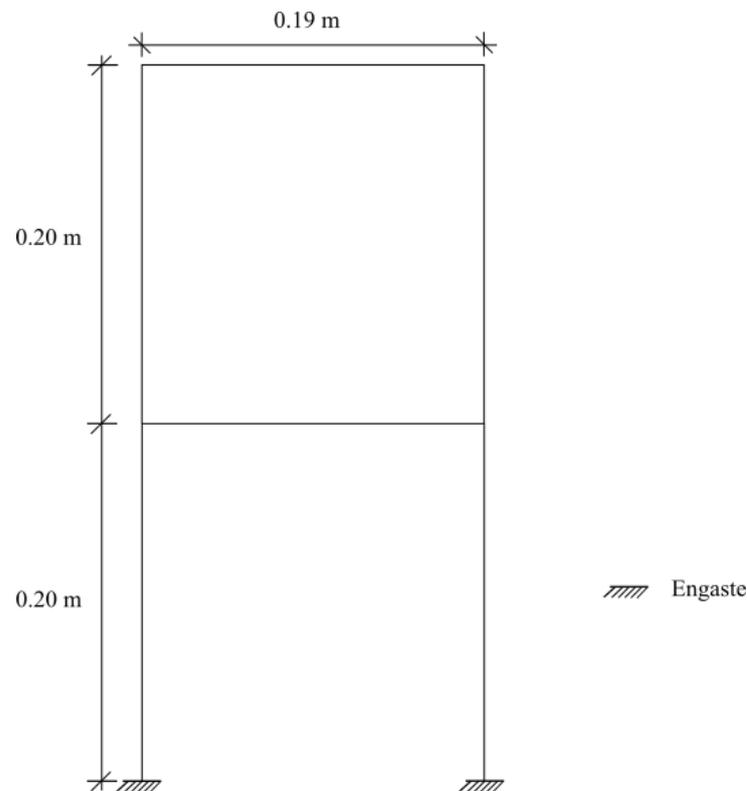


Figura 2 – Esquema do pórtico plano engastado utilizado.

Com base nas propriedades descritas, foi gerado um modelo numérico da estrutura intacta (sem dano) no programa MATLAB versão 2013b da empresa MathWorks, com 118 elementos de pórtico plano de seção retangular (Fig. 3) de 10mm de comprimento como ilustrado na Fig. 4. Cada elemento possui três graus de liberdade por nó, como mostra a Fig. 5.

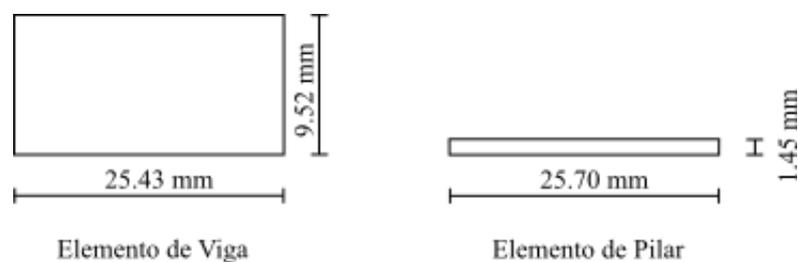


Figura 3 – Seção transversal dos elementos constituintes do pórtico.

Para que seja possível treinar as RNAs, torna-se necessária a obtenção dos dados de entrada e suas saídas correspondentes, que no caso deste trabalho tratam-se dos modos de vibração dos pórticos e a localização do dano, respectivamente.

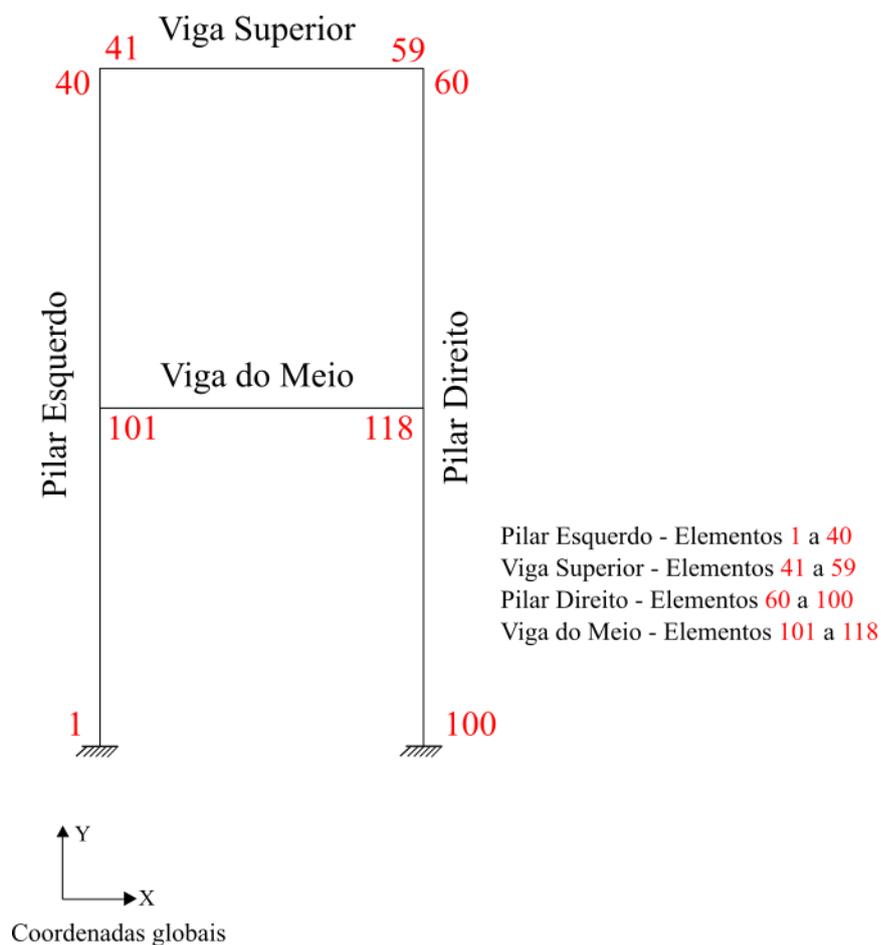


Figura 4 – Discretização do pórtico plano intacto.

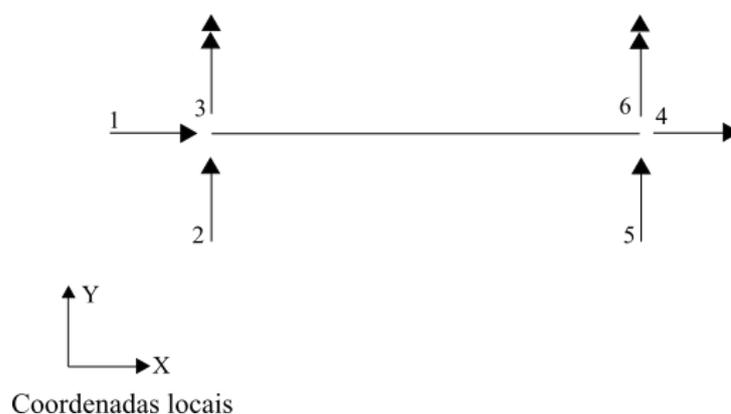


Figura 5 – Elemento de pórtico plano, com 3 graus de liberdade por nó.

Tendo isso em mente, foram criados, além do modelo intacto, 41 modelos numéricos diferentes contendo, cada um, um cenário de dano diferente. O dano foi simulado por meio de uma redução da seção transversal de um ou mais elementos, que significou reduções na área e

na inércia entre 5% e 50%, em diferentes elementos para cada cenário, como descrito na Tabela 3.

Tabela 3 – Cenários de dano utilizados no treinamento da RNA.

Cenário	Elemento Danificado	Dano Inserido (Redução na Inércia)	Cenário	Elemento Danificado	Dano Inserido (Redução na Inércia)
0	Nenhum (Intacta)	0%	21	53	7%
1	3	34%	22	54	48%
2	4	5%	23	55	31%
3	5	6%	24	56 e 58	15%
4	6	44%	25	63	28%
5	7	27%	26	64	14%
6	8	8%	27	65 e 66	43%
7	10	13%	28	67 e 69	41%
8	12	27%	29	70	36%
9	13 e 17	6%	30	71 e 75	7%
10	14 e 16	19%	31	73 e 78	31%
11	15 e 19	10%	32	79	11%
12	21 e 22	28%	33	80 e 84	22%
13	23 e 28	23%	34	85 e 87	39%
14	30	24%	35	88	50%
15	33	49%	36	89	43%
16	35 e 38	15%	37	90 e 96	20%
17	41	26%	38	102 e 107	10%
18	42	24%	39	106 e 111	32%
19	43 e 46	14%	40	108	19%
20	48 e 52	11%	41	114 e 116	9%

As matrizes de rigidez e de massa dos elementos foram obtidas através da Eq. (2) e da Eq. (3), respectivamente.

$$K = \begin{bmatrix} \frac{EA}{L} & 0 & 0 & -\frac{EA}{L} & 0 & 0 \\ 0 & \frac{12EI}{L^3} & \frac{6EI}{L^3} & 0 & -\frac{12EI}{L^3} & \frac{6EI}{L^3} \\ 0 & \frac{6EI}{L^2} & \frac{4EI}{L} & 0 & -\frac{6EI}{L^2} & \frac{2EI}{L} \\ -\frac{EA}{L} & 0 & 0 & \frac{EA}{L} & 0 & 0 \\ 0 & -\frac{12EI}{L^3} & -\frac{6EI}{L^3} & 0 & \frac{12EI}{L^3} & -\frac{6EI}{L^3} \\ 0 & \frac{6EI}{L^2} & \frac{2EI}{L} & 0 & \frac{6EI}{L^2} & \frac{4EI}{L} \end{bmatrix} \quad (2)$$

$$M = \rho \cdot A \cdot L \begin{bmatrix} \frac{1}{3} & 0 & 0 & \frac{1}{6} & 0 & 0 \\ 0 & \frac{13}{35} & \frac{11}{210}L & 0 & \frac{9}{70} & -\frac{13}{420}L \\ 0 & \frac{11}{210}L & \frac{1}{105}L^2 & 0 & \frac{13}{420}L & -\frac{1}{140}L \\ \frac{1}{6} & 0 & 0 & \frac{1}{3} & 0 & 0 \\ 0 & \frac{9}{70} & \frac{13}{420}L & 0 & \frac{13}{35} & -\frac{11}{210}L \\ 0 & -\frac{13}{420}L & -\frac{1}{140}L & 0 & -\frac{11}{210}L & \frac{1}{105}L^2 \end{bmatrix} \quad (3)$$

K e M são as matrizes de rigidez e massa do elemento, respectivamente;

A, E, I, ρ e L correspondem a: Área da seção transversal, Módulo de elasticidade, Momento de Inércia, densidade e comprimento do elemento, respectivamente.

Para o cálculo das matrizes de rigidez e massa globais, utiliza-se a matriz de rotação da estrutura R, através das Eq. (4), (5) e (6).

$$R = \begin{bmatrix} \cos\theta & \sin\theta & 0 & 0 & 0 & 0 \\ \sin\theta & \cos\theta & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \cos\theta & \sin\theta & 0 \\ 0 & 0 & 0 & -\sin\theta & \cos\theta & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

Onde θ é o ângulo do eixo global para o eixo local.

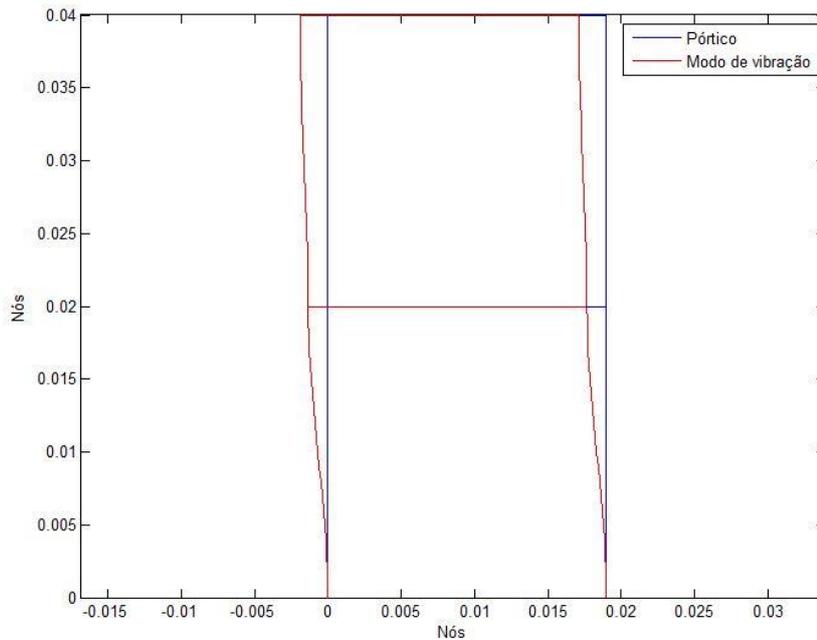
$$M_G = R^T \cdot M \cdot R \quad (5)$$

$$K_G = R^T \cdot K \cdot R \quad (6)$$

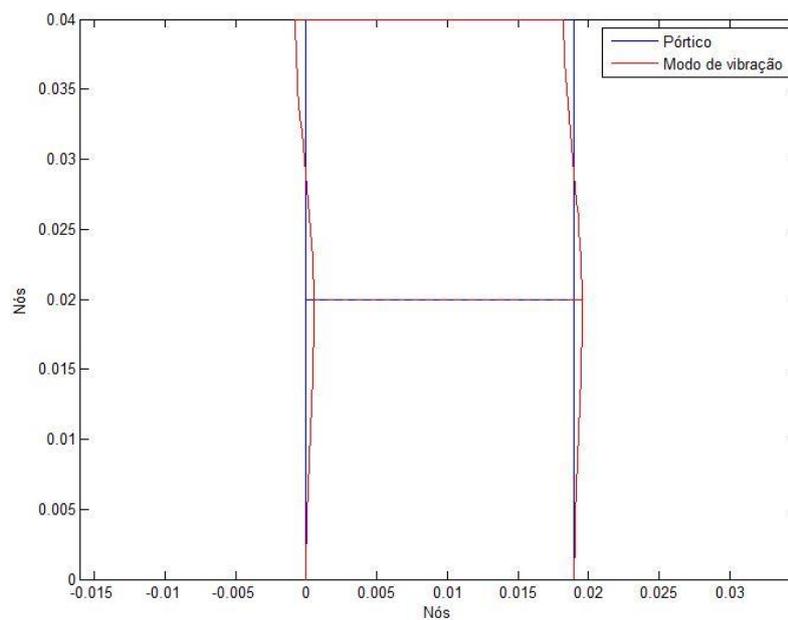
K_G e M_G são as matrizes globais de rigidez e massa, respectivamente.

Por fim, foram calculadas as cinco primeiras frequências naturais e seus respectivos modos de vibração para cada um dos casos estudados. Para este cálculo, foi utilizado o programa MATLAB, através da função *eig*.

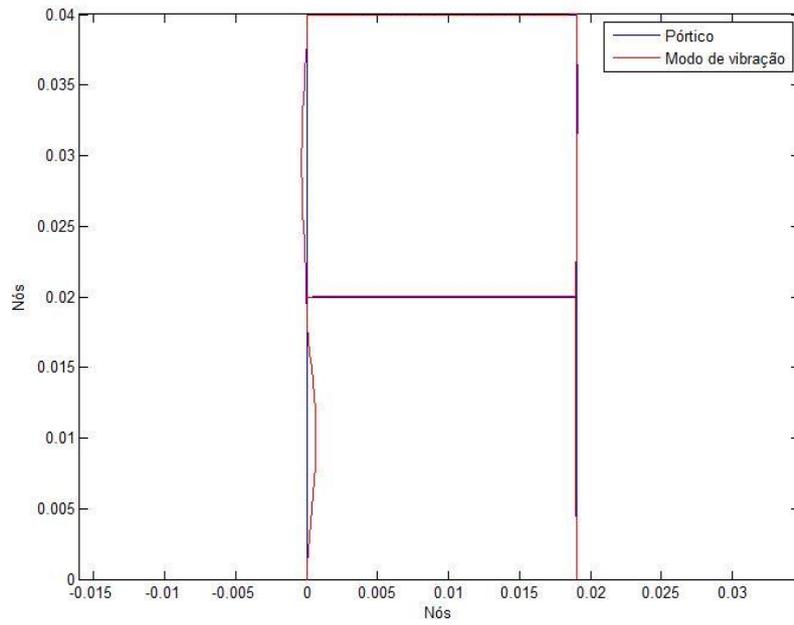
Os cinco primeiros modos de vibração obtidos para o modelo intacto, ou seja, sem nenhum elemento danificado, são ilustrados na Fig. 6. De maneira análoga, foram obtidos os cinco primeiros modos de vibração para os 41 modelos danificados.



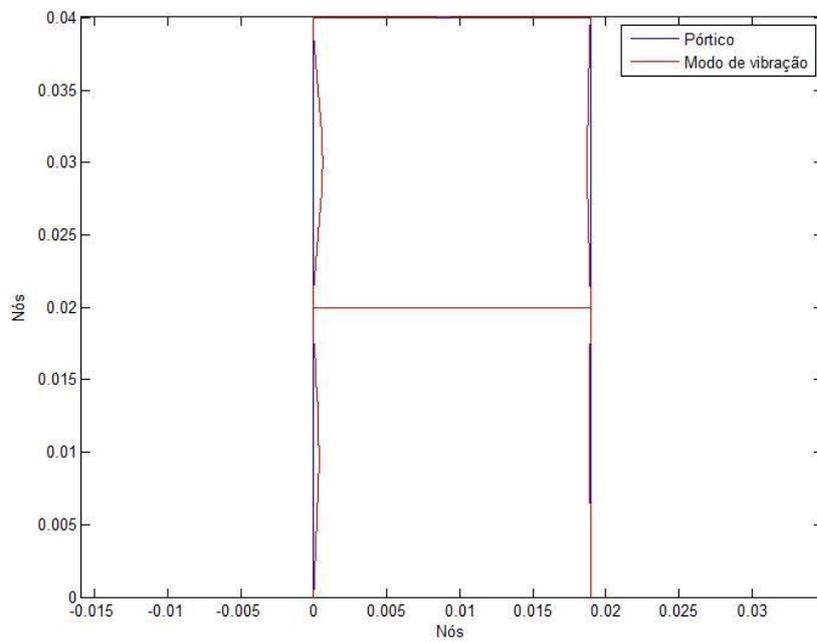
(a)



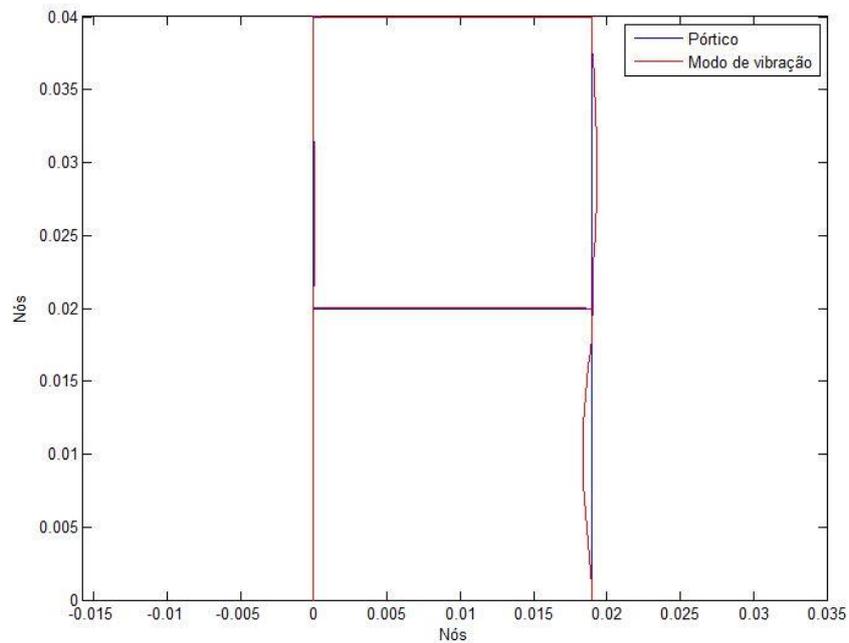
(b)



(c)



(d)



(e)

Figura 6– Primeiro modo de vibração (a); Segundo modo de vibração (b); Terceiro modo de vibração (c); Quarto modo de vibração (d); Quinto modo de vibração (e) referentes ao pórtico intacto.

4 ANÁLISE NUMÉRICA

Foi utilizado o programa MATLAB, em particular o pacote *Neural Network Toolbox* (NNTool), o qual contém as ferramentas necessárias para o uso de RNAs. O pacote NNTool possui uma interface de fácil utilização, permitindo ao usuário criar uma RNA, escolher suas propriedades como número de camadas, número de neurônios nas camadas intermediárias, funções de ativação, assim como importar de maneira simples os dados de entrada e saída que serão utilizados no treinamento da rede. Após a criação da rede, esta pode ser treinada com os dados importados, permitindo ao usuário definir algumas propriedades do treinamento como número de iterações, erro máximo e erro mínimo.

Quanto às características das RNAs utilizadas neste trabalho, todas são do tipo *feedforward* contendo apenas uma camada intermediária composta por 25 neurônios, com função de ativação *TANSIG* entre as camadas e algoritmo de treinamento *backpropagation* Levenberg-Marquardt (Fig. 7). Foram ainda selecionados aleatoriamente 70% dos dados para treinamento, 15% para validação e 15% para teste da rede.

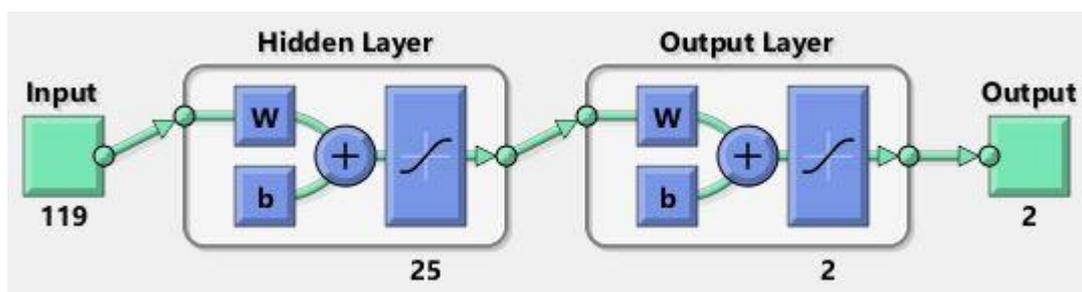


Figura 7 – Arquitetura da Rede Neural utilizada.

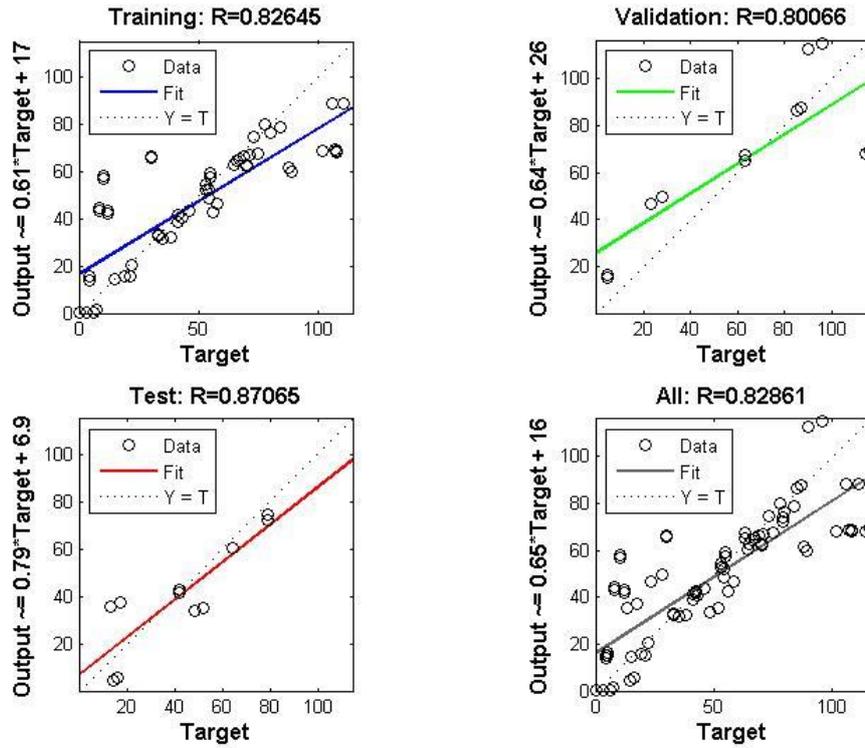
Como mencionado, foram treinadas cinco RNAs, onde cada uma delas utilizou um dos cinco modos de vibração calculados anteriormente. Exemplo: A Rede 1 foi treinada utilizando o primeiro modo de vibração de cada modelo numérico, e assim sucessivamente para as cinco redes.

Os modos de vibração tanto do modelo intacto quanto dos modelos danificados foram utilizados como dados de entrada para as RNAs deste trabalho e, para a saída das redes, foi utilizada a numeração dos elementos danificados, seguindo a mesma ordem da discretização mostrada anteriormente.

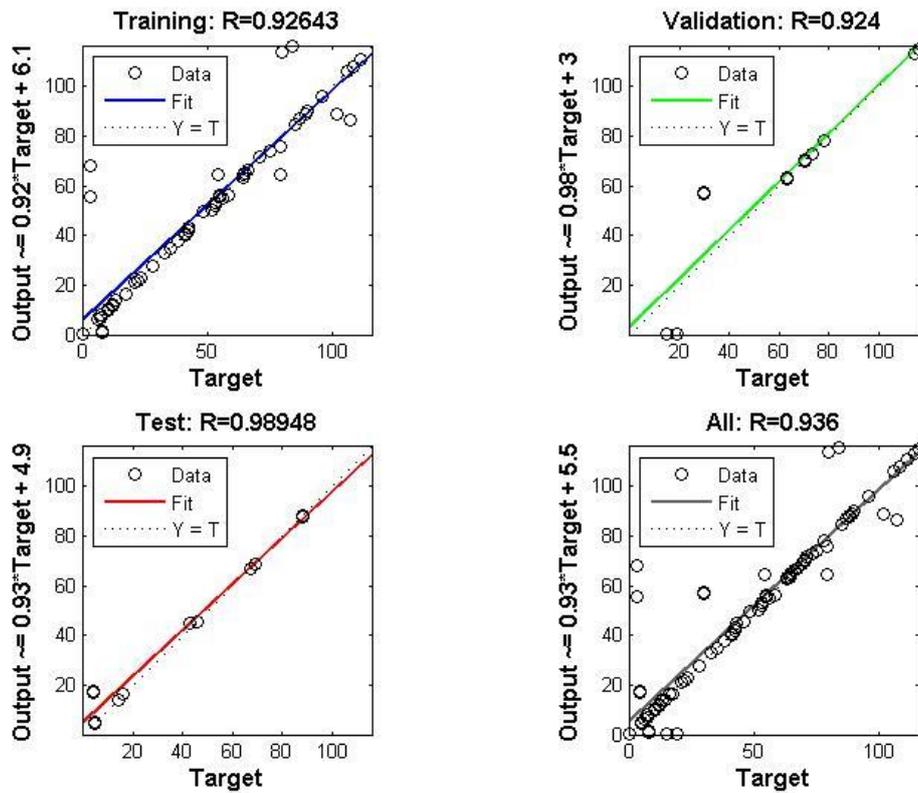
Durante o treinamento das redes foi ainda levado em consideração o fenômeno de *overfitting* (ou supertreinamento), que se caracteriza por uma generalização exacerbada da rede para os dados utilizados no treinamento, fazendo assim com que a mesma não apresente um bom desempenho quando são testados novos dados. Para evitar que isso ocorra, foram utilizadas duas técnicas: a parada antecipada, que consiste em parar o treinamento assim que a rede atinge o erro mínimo, e o retreinamento, onde a rede é treinada várias vezes consecutivas sem reiniciar seus pesos. Cada uma das redes apresentadas neste trabalho foram treinadas cinco vezes consecutivas, e o erro considerado aceitável foi de 8%.

A Figura 8 mostra os resultados obtidos nos treinamentos das cinco RNAs. Cada gráfico relaciona a resposta encontrada pela rede (*output*) e a resposta esperada (*target*). Após marcados os pontos referentes a essa relação, o programa utiliza regressão linear para criar uma reta e avaliar o treinamento, a validação e o teste da rede. É apresentado ainda um quarto gráfico intitulado *All*, onde são marcados todos os pontos referentes às três fases anteriores, para que possa ser feita uma avaliação geral do desempenho da rede.

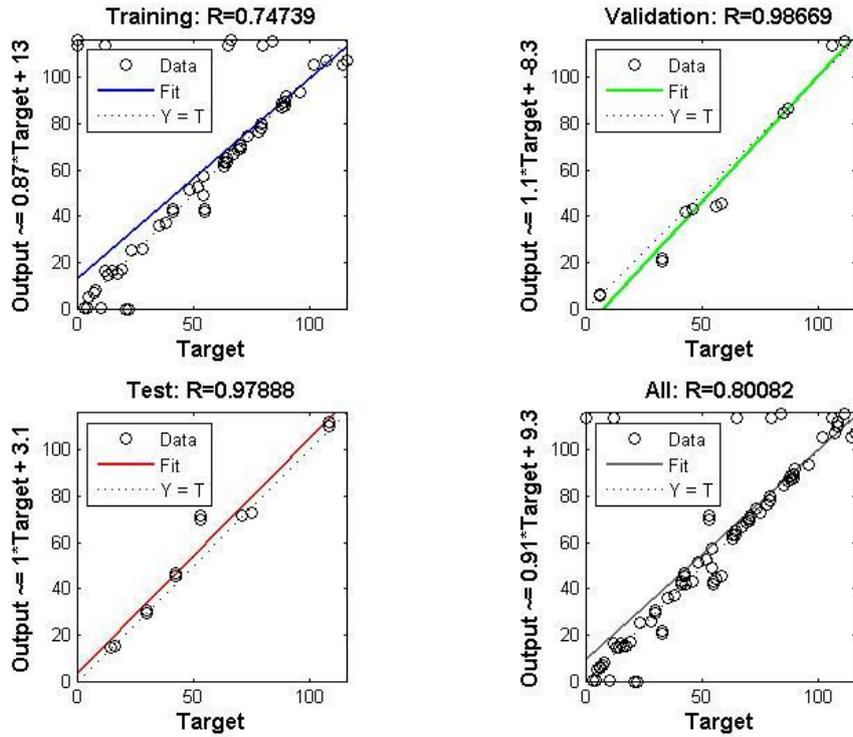
O valor de R apresentado nos gráficos representa a relação entre a resposta da rede e a resposta esperada. Logo, quanto mais próximo de 1 este valor, melhor é o desempenho da rede nas fases de treinamento, validação e teste.



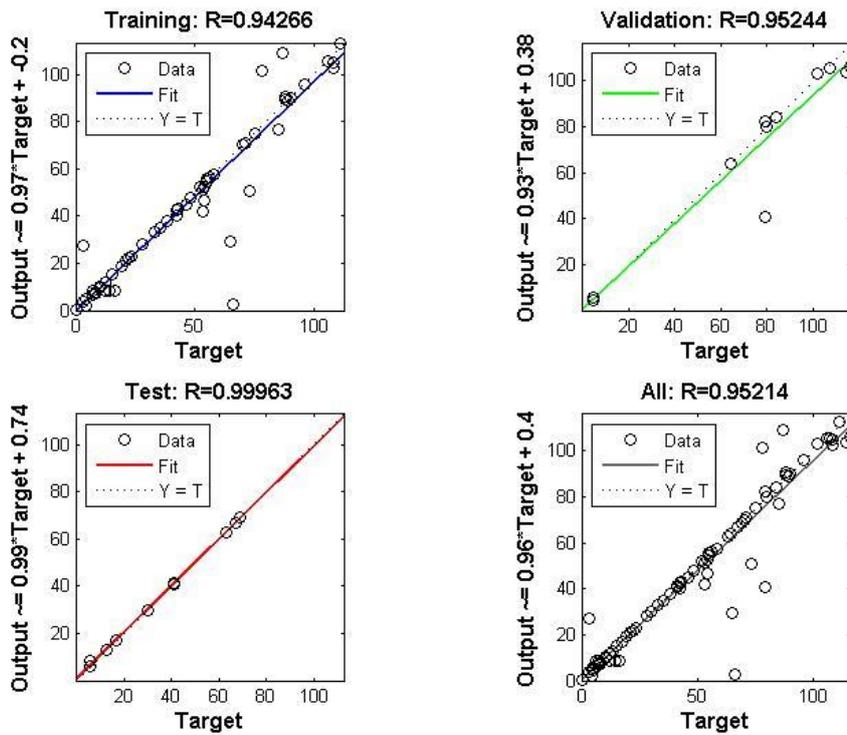
(a)



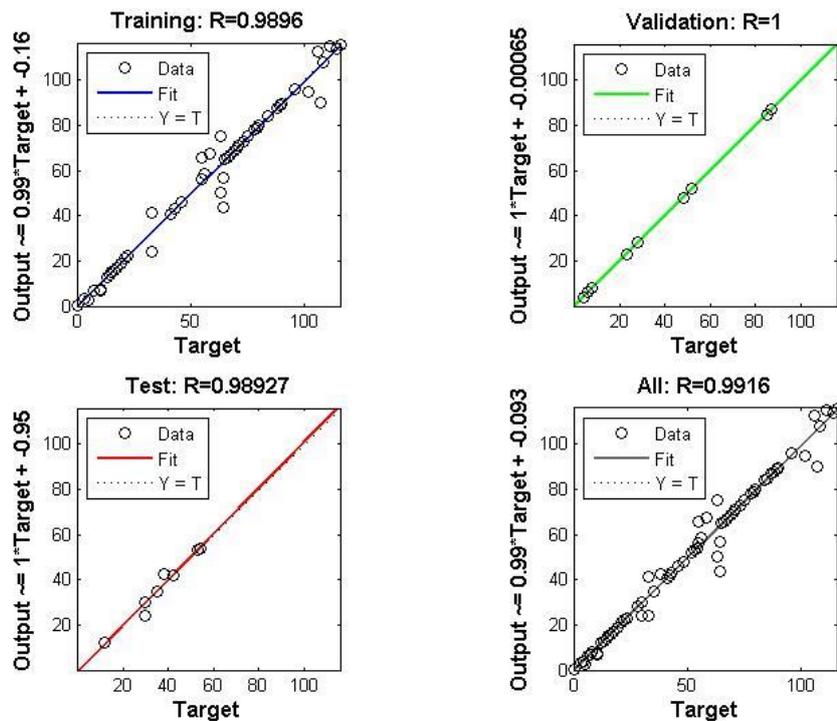
(b)



(c)



(d)



(e)

Figura 8 – Resultados obtidos no treinamento das RNAs referentes ao: Primeiro modo de vibração (a); Segundo modo de vibração (b); Terceiro modo de vibração (c); Quarto modo de vibração (d); Quinto modo de vibração (e).

Analisando os resultados, percebe-se que a RNA referente ao quinto modo de vibração é a que apresentou melhores resultados, com uma precisão de 98.96% na fase de treinamento e 98.93% na fase de teste. As RNAs que utilizaram o primeiro e o terceiro modo de vibração não obtiveram bons resultados, apresentando erro maior que 10% em uma das fases. Ainda assim, as demais RNAs criadas (segundo e quarto modo de vibração) também obtiveram bons resultados, com precisão mínima de 92.64% na fase de treinamento e 98.95% na fase de testes.

5 CONCLUSÕES

Este trabalho visou avaliar o desempenho e a precisão da técnica de RNAs quando utilizada em conjunto com propriedades dinâmicas na localização de danos em modelos de pórticos planos.

Para isso, cinco RNAs do tipo *backpropagation* foram treinadas, cada uma utilizando um dos cinco primeiros modos de vibração dos modelos numéricos criados como dados de entrada e, para suas saídas, foram utilizados os elementos danificados.

Com base nos resultados obtidos do treinamento e do teste das RNAs, pode-se concluir que todas as redes conseguiram assimilar os dados e localizar os danos com relativa precisão, porém a rede treinada com o segundo modo de vibração dos pórticos foi a que apresentou o melhor desempenho.

Sendo assim, é possível afirmar que a técnica de RNAs pode ser uma ferramenta promissora no que diz respeito ao monitoramento de estruturas. Uma vez que este trabalho foi desenvolvido numericamente, novos estudos em estruturas mais complexas e ainda em forma experimental são necessários para avaliar melhor seu potencial.

REFERÊNCIAS

- Braga, A., Ludermir, T. & Carvalho, A. 2000. *Redes Neurais Artificiais: Teoria e Aplicações*. LTC – Livros Técnicos e Científicos Editora S.A.
- MATLAB Matrix Laboratory - R2013b. MathWorks - MATLAB and Simulink for Technical Computing. Massachusetts, U.S.A, 2014.
- S. J. S. Hakim, H. Abdul Razak & S. A. Ravanfar. 2015. Fault Diagnosis on beam-like structures from modal parameters using artificial neural networks. *Malaysia Measurement*, Volume 76, December 2015, pp. 45-61.
- Paulraj M. P., Sazali Yaacob, M. S. Abdul Majid, Mohd Nor Fakhzan Mohd Kazim & Pranesh Krishnan. 2012. Structural Steel Plate Damage Detection using Non Destructive Testing, Frame Energy based Statistical Features and Artificial Neural Networks. *Malaysian Technical Universities Conference on Engineering & Technology 2012, MUCET 2012 Part 1- Electronic and Electrical Engineering. Procedia Engineering* 53 pp. 376 – 386.