



INFLUÊNCIA DA TEMPERATURA NA AVALIAÇÃO DE DANOS EM VIGAS UTILIZANDO REDES NEURAIS ARTIFICIAIS

Vanessa de Moura Santana

Graciela Nora Doz

vanessams@aluno.unb.br

graciela@unb.br

Programa de Pós-graduação em Estruturas e Construção Civil, Universidade de Brasília, CEP 70910-900, Brasília - DF, Brasil.

Resumo: Com o passar dos anos a preocupação com a integridade estrutural das construções vem sendo crescente. Dentre os numerosos métodos para avaliação da integridade estrutural destacam-se aqueles baseados na observação das propriedades dinâmicas, uma vez que frequências e modos dependem, fundamentalmente, da rigidez estrutural. Os métodos que avaliam esta alteração na rigidez demandam de um monitoramento contínuo da estrutura, e a busca de metodologias adequadas para o tratamento do vasto conjunto de dados coletados se faz necessária. Nesse sentido, as Redes Neurais Artificiais (RNAs) constituem uma ferramenta interessante para o tratamento destes dados. Entretanto, os efeitos ambientais, como temperatura, umidade e vento, limitam a aplicação bem-sucedida destes métodos. Dentre os efeitos ambientais mencionados a temperatura se destaca, por ser capaz de camuflar a influência provocada por pequenos danos. Com base no exposto, este trabalho apresenta a análise de uma viga metálica intacta e com diferentes cenários de danos, sob diferentes temperaturas, tendo como objetivo analisar a influência provocada por este efeito ambiental nas frequências da viga e no processo de avaliação de danos. Para a obtenção destas frequências foi utilizado o software de elementos finitos ANSYS. E para o tratamento dos dados obtidos neste software foram utilizadas RNAs Multilayer Perceptron, através do software Matlab.

Palavras-Chave: Integridade Estrutural, Danos, Frequências de Vibração, Temperatura, Redes Neurais Artificiais

1 INTRODUÇÃO

A utilização a longo prazo ou de maneira inadequada de uma estrutura, faz com que seu funcionamento fique comprometido e o surgimento de danos torna-se provável. Estes danos alteram as propriedades físicas e/ou mecânicas da estrutura, podendo provocar desconfortos aos usuários, colapsos parciais ou totais da construção.

Para identificar esses danos e assim fazer uma manutenção preventiva da estrutura, pode-se utilizar métodos baseados nas propriedades dinâmicas. Estes métodos se fundamentam no acompanhamento das alterações das características dinâmicas da estrutura, uma vez que estruturas danificadas apresentam perda de rigidez localizada, provocando alterações nas propriedades dinâmicas.

Porém, quando estes métodos são utilizados em estruturas susceptíveis à efeitos ambientais, como a variação da temperatura, vento, radiação solar, umidade, estes efeitos devem ser estudados antes da aplicação do método. Isto porque assim como os danos, esses efeitos ambientais também provocam alterações físicas e/ou mecânicas na estrutura, e consequentemente nas características dinâmicas.

Dentre esses efeitos ambientais a variação da temperatura é o mais significativo na variação das frequências modais (Li *et al.*, 2010). A correta interpretação desta variação é fundamental para se ter um método confiável de avaliação de dano, uma vez que pequenos danos influenciam nas propriedades dinâmicas assim como os efeitos provocados pela variação da temperatura.

Por outro lado, o monitoramento contínuo e/ou simulações numéricas de uma estrutura, para identificação das características dinâmicas e, posteriormente, a avaliação de dano, implica na necessidade de trabalhar com um grande conjunto de dados. Uma alternativa para analisar este vasto conjunto de dados são as Redes Neurais Artificiais (RNAs). Entretanto, pouco se conhece sobre o uso desta ferramenta para avaliação de danos considerando os efeitos da temperatura.

Partindo destas premissas, este trabalho tem como objetivo estudar a influência da variação da temperatura no processo de avaliação de danos de uma viga metálica a partir do uso de RNAs.

2 DETECÇÃO DE DANO UTILIZANDO RNA

Uma Rede Neural Artificial (RNA) é um processador distribuído paralelamente composto de unidades simples de processamento (neurônios artificiais), com capacidade de armazenar conhecimento (Haykin, 2009). Essas unidades são dispostas em camadas e associadas a pesos, sendo esses responsáveis pelo armazenamento do conhecimento.

O armazenamento do conhecimento confere a RNA a capacidade de aprendizagem. Além desta característica, as RNAs possuem a capacidade de generalizar a informação aprendida, através de um conjunto de exemplos, desde que este conjunto represente de maneira satisfatória o problema estudado.

Existem diversos tipos de RNAs, e estas, simplificada, podem ser classificadas segundo a sua arquitetura (camada única, múltiplas camadas, auto associativa, etc.), forma de

aprendizado (supervisionado ou não supervisionado) e funções de ativação utilizadas (degrau, tangencial, linear, etc.).

Neste trabalho optou-se por trabalhar com a RNA do tipo *Multilayer Perceptron* (MLP), utilizando o algoritmo de aprendizagem *Backpropagation*, cujo aprendizado é supervisionado, isto é, existe um responsável pela correção do erro entre a saída encontrada e a saída desejada, através do ajuste dos pesos. Optou-se pela utilização dessa rede, uma vez que a presença de camadas intermediárias permite que a rede solucione e generalize problemas com padrões mais complexos.

A RNA do tipo MLP é uma rede com arquitetura de múltiplas camadas. Na primeira camada, camada de entrada, são inseridos os dados que representam da melhor forma o problema. Nas camadas seguintes, camadas ocultas ou intermediárias, encontram-se os neurônios artificiais, responsáveis por parte do desempenho da rede. E por fim, na última camada, a camada de saída, é apresentado o resultado calculado pela RNA.

Nas camadas ocultas, com o auxílio das funções de ativação e dos pesos, é calculado o valor do neurônio. Para esta RNA é possível escolher qualquer função de ativação, fica a critério do usuário escolher a que melhor se adequa ao problema estudado.

O treinamento da rede ocorre em duas fases, a fase *forward*, cujo processamento ocorre dos dados de entrada para os dados de saída. E a fase *backward*, que percorre a rede no sentido oposto, dos dados de saída para os dados de entrada, utilizando a saída desejada e a saída encontrada para atualizar os pesos e minimizar o erro entre as saídas (Braga *et al.*, 2000). A Fig. 1 ilustra simplificada este algoritmo, onde X_i representa os dados de entrada; σ_i e ω_i neurônios das camadas ocultas; α_{ij} , β_{ij} e γ_{ij} os pesos e Y_i os dados de saída.




Figura 1. Modelo da RNA utilizada neste trabalho (Marcy (2013) adaptada)

O cálculo do neurônio na fase *forward* é feito de acordo com as Eq. (1) e Eq. (2) (Marcy, 2013), onde ' f ' representa a função de ativação e o significado das outras variáveis está na Fig. 1. E a correção dos pesos, na fase *backward* é feito como apresentado na Eq. (3), onde μ é usado para alcançar a melhor convergência.

$$\sigma_i = f\left(\sum_{k=1}^n X_k \cdot \alpha_{ik}\right) \quad (1)$$

$$\omega_i = f\left(\sum_{j=1}^n \sigma_j \cdot \beta_{ij}\right) \quad (2)$$

$$\gamma_{ij}^{novo} = \gamma_{ij}^{velho} - \mu \frac{\partial E^2}{\partial \gamma_{ij}} \quad (3)$$

Em um estudo pioneiro, Wu *et al.*, (1992) propôs utilizar as RNAs com o algoritmo de aprendizagem *Backpropagation* para detectar a presença de dano em um pórtico plano de três pavimentos. Através de simulações numéricas obteve as frequências naturais do pórtico intacto e com duas intensidades de dano, em três posições diferentes. Durante a fase de teste da rede obtiveram bons resultados, mostrando que as RNAs poderiam ser utilizadas para detecção de dano, e aplicadas no monitoramento automático das estruturas.

Sohn *et al.* (2002) em um estudo de revisão da literatura, relata como única desvantagem de se utilizar as RNAs como método de detecção de dano, a necessidade de um grande conjunto de dados da estrutura não danificada e danificada, para o treinamento da RNA. E para obter este conjunto de dados é necessário um monitoramento contínuo da estrutura ou construir um modelo numérico.

Marcy (2013) quantificou danos através das RNAs e o Método do Erro Residual (MER), uma técnica que permite localizar e quantificar o dano através do erro, ocasionado pela presença do dano, na equação de movimento da estrutura. Observou que as RNAs apresentaram maior precisão e velocidade de processamento que o MER. Maia (2016) obteve experimentalmente e numericamente dados de uma viga metálica e um pórtico plano, e tinha como objetivo utilizar as RNAs para detecção de dano, e estas apresentaram bons resultados.

3 INFLUÊNCIA DA TEMPERATURA NAS CARACTERÍSTICAS FÍSICAS E DINÂMICAS

A influência provocada pela temperatura nas características dinâmicas de uma estrutura vem sendo estudada há mais de 20 anos.

Wahab e Roeck (1997), através de estudos numéricos e experimentais, observaram que uma ponte protendida, sob uma redução de 15°C apresentava um aumento nas frequências naturais de 4% a 5%. Fu e DeWolf (2001), também com estudos numéricos e experimentais, sobre uma ponte mista (vigas metálicas e tabuleiro de concreto), observaram que a redução na temperatura em 60°F as frequências aumentavam em mais de 8%. Moser e Moaveni (2011) experimentalmente observaram que a redução de 25°C variou a frequência de 4 a 8% de uma ponte.

Xia *et al.* (2012) realizou um estudo da literatura, e constatou que o principal responsável pela variação das frequências nas estruturas, quando estava submetida a diferentes temperaturas, era o módulo de elasticidade.

Tendo como base a importância de se considerar a variação do módulo de elasticidade, Poh (2001) propõe calcular o módulo de elasticidade E do aço estrutural, para temperaturas de 0°C até 600°C, pela Eq. (4). Onde $E_{0^\circ\text{C}}$ é o módulo de elasticidade do aço a temperatura de 0°C e T é a temperatura.

$$E = E_{0^{\circ}\text{C}} \left[1 + \frac{T}{900 \cdot \ln(T/1,75)} \right] \quad (4)$$

Contudo, além do módulo de elasticidade, a temperatura também altera a geometria das estruturas. E quando se trata de estruturas complexas, esta influência deve ser tratada com cautela, uma vez que a temperatura é um parâmetro que depende de muitas variáveis aleatórias, que provoca uma distribuição não uniforme na estrutura (Zhou e Yi, 2014).

Neste trabalho a influência provocada pela temperatura será feita através de uma análise simplificada, por formulações lineares, como a apresentada na Eq. (5), uma vez que se trata de uma estrutura simples e esta variação tem uma representativa pequena comparada a variação do módulo de elasticidade, para a estrutura analisada.

$$\Delta L = L_0 \cdot \alpha \cdot \Delta T \quad (5)$$

Onde ΔL é o acréscimo provocado pela temperatura na dimensão estudada, L_0 o comprimento inicial, α o coeficiente de dilatação linear do material e ΔT a variação da temperatura.

Li *et al.* (2010) verificaram em seus estudos, sobre uma ponte estaiada localizada na China, que a temperatura apresenta uma correlação negativa com a frequência e com relação a forma modal não foi identificada uma relação clara. Ortiz Morales (2016) realizou ensaios em condições controladas de temperatura de uma viga metálica, e em seus experimentos, observou que o acréscimo na temperatura reduzia as frequências, e as taxas de amortecimento apresentaram uma fraca redução na primeira frequência.

As taxas de amortecimento não costumam ser utilizadas como indicador de dano, uma vez que sua obtenção é custosa (Wahab e Roeck, 1997) e os modos de vibração não apresentam uma sensibilidade a variação de temperatura, como observado por Li *et al.* (2010). Sendo assim, a frequência é o melhor parâmetro dinâmico para utilizar na avaliação do dano, quando a estrutura está submetida a diferentes temperaturas.

4 ANÁLISE NUMÉRICA

4.1 Exemplo Analisado

Optou-se por analisar numericamente uma viga com as mesmas características da de Ortiz Morales (2016), com o propósito de se verificar a influência que a temperatura provoca na avaliação do dano. E o modelo numérico foi validado com os dados obtidos experimentalmente, pelo referido autor.

Ortiz Morales (2016) realizou ensaios em laboratório de uma viga metálica com o objetivo de se obter as frequências e taxas de amortecimento. Estas características dinâmicas foram obtidas sob temperatura controlada com intervalos $\pm 2^{\circ}\text{C}$, começando a 18°C até 56°C .

A viga metálica foi construída com perfil de barra chata de aço A36, com condição de contorno apoiada-apoiada, comprimento entre apoios de 150cm e seção transversal retangular de 2,51cm x 0,59cm, representada na Fig. 2. Possui limite de escoamento mínimo de 250MPa e tensão de ruptura entre 400 e 500MPa. Além dessas características a viga possui:

- Módulo de Elasticidade a 0°C $[E_{0^{\circ}\text{C}}]$: $201,04 \text{ GPa}$
- Momento de Inércia a 25°C $[I]$: $4,296 \times 10^{-10} \text{ m}^4$
- Densidade do Material $[\rho]$: 7850 kg/m^3




Figura 2. Representação gráfica da viga analisada neste trabalho

Através de 6 acelerômetros instalados na direção dos graus de liberdade verticais (direção Y), Ortiz Morales (2016) obteve as três primeiras frequências de flexão e taxa de amortecimento dos três primeiros modos de vibração. Na Fig. 3 encontra-se representada a posição da instalação dos acelerômetros e a projeção das três primeiras formas modais. E para medir a temperatura foram usados 4 sensores instalados na parte superior da viga e distribuídos como mostrado na Fig. 4.




Figura 3. Posição da instalação dos acelerômetros sobre a viga e formas modais superpostas (Ortiz Morales (2016) adaptada)




Figura 4. Distribuição dos sensores de temperatura sobre a viga (Ortiz Morales (2016) adaptada)

Os ensaios foram repetidos três vezes para cada temperatura, com o objetivo de realizar um tratamento estatístico dos resultados. Na Tab. 1 são apresentadas as três frequências de flexão para algumas temperaturas, obtidas através da média dos três ensaios.


Tabela 1. Frequências obtidas por Ortiz Morales (2016) experimentalmente

Temp. (°C)	1° Freq. (Hz)	2° Freq. (Hz)	3° Freq. (Hz)
18	6,032	23,579	53,400
20	6,027	23,557	53,326
22	6,005	23,589	53,186
25	6,022	23,607	53,484
30	6,001	23,567	53,704
40	5,964	23,483	53,217
45	5,930	23,481	53,094
50	5,919	23,439	53,003

4.2 Modelo numérico

Para concepção do modelo numérico, utilizou-se o *software* de elementos finitos ANSYS, que através das plataformas *Workbench* ou APDL simula numericamente problemas complexos da engenharia.

O modelo numérico foi feito utilizando elementos Mesh2000, através de hexaedricos com 20 graus de liberdade. A viga foi discretizada com elementos de 2cm de comprimento, totalizando 150 elementos, e encontra-se representada na Fig. 5. As condições de contorno foram inseridas nas arestas inferiores da viga, em um lado o movimento em todas as direções foi impedido e do outro impediu-se o movimento em X e Y.

**Figura 5. Discretização da viga analisada numericamente**

A consideração da variação do módulo de elasticidade foi feita nas propriedades do material, através da inserção de uma relação tabular entre a temperatura e o módulo de Young. A influência provocada pela temperatura na geometria foi obtida através do ‘sistema de análise de estrutura estática’ presente na plataforma *Workbench*. E, por fim, as frequências foram calculadas pelo ‘sistema de análise modal’. Na Tab. 2 encontra-se alguns resultados obtidos com o modelo da Fig. 5 para as três frequências de flexão.

Tabela 2. Frequências obtidas numericamente

Temp. (°C)	1° Freq. (Hz)	2° Freq. (Hz)	3° Freq. (Hz)
18	6,0065	24,0225	54,0366
20	6,0051	24,0169	54,0240
25	6,0014	24,0019	53,9904
30	5,9975	23,9862	53,9549
40	5,9890	23,9523	53,8788
45	5,9845	23,9344	53,8384
50	5,9798	23,9157	53,7964

Por fim as frequências também foram obtidas por formulações analíticas. Uma viga apoiada-apoiada pode ter sua frequência natural de flexão calculada pela Eq. (6).

$$f_n = \frac{n^2 \pi}{2} \sqrt{\frac{EI}{\bar{m} L^4}} \quad (6)$$

Onde f representa a frequência natural da viga em [Hz], EI a rigidez a flexão, $\bar{m}$ a massa por unidade de comprimento, L o comprimento da viga e n o modo vibracional que se deseja calcular.

Substituindo as Eq. (4) e Eq. (5) na Eq. (6) é possível determinar as frequências de flexão de uma viga metálica apoiada-apoiada sob temperatura entre 0° e 600°C, apresentado na Eq. (7). A seguir, nas Eq. (8) e Eq. (9), esta calculado as três primeiras frequências de flexão a 25°C e na Tab. 3 o resultado para outras temperaturas.

$$f_n = n^2 \cdot \frac{\pi}{2} \sqrt{\frac{\left[E_{0^\circ\text{C}} \left(1 + \frac{T}{900 \cdot \ln(T/1,75)} \right) \right] I}{\left(\frac{b \cdot h}{\rho} \right) \cdot L^4}} \quad (7)$$

$$f_n = n^2 \cdot \frac{\pi}{2} \sqrt{\frac{2,0104 \cdot 10^{11} \left(1 + \frac{25}{900 \cdot \ln(25/1,75)} \right) (4,296 \cdot 10^{-10})}{\left(\frac{0,0251 \cdot 0,0059}{7850} \right) \cdot 1,50^4}} \rightarrow f_n = n^2 \cdot 6,002 \quad (8)$$

$$\begin{aligned} f_1 &= 1^2 \cdot 6,002 = 6,002 \text{ Hz} \\ f_2 &= 2^2 \cdot 6,002 = 24,007 \text{ Hz} \\ f_3 &= 3^2 \cdot 6,002 = 54,016 \text{ Hz} \end{aligned} \quad (9)$$

Tabela 3. Frequências obtidas analiticamente

Temp. (°C)	1° Freq. (Hz)	2° Freq. (Hz)	3° Freq. (Hz)
18	6,0066	24,0265	54,0597
20	6,0053	24,0211	54,0475
25	6,0017	24,0069	54,0155
30	5,9980	23,9918	53,9816
40	5,9899	23,9594	53,9087
45	5,9855	23,9422	53,8699
50	5,9811	23,9242	53,8295

A Tabela 4 apresenta o erro percentual entre as frequências numéricas com as formulações analíticas e resultados experimentais à 25°C.


Tabela 4. Diferença percentual das frequências numéricas com as analíticas e experimentais

Freq. (Hz)	Numérico	Analítico		Experimental	
		Freq.	Erro (%)	Freq.	Erro (%)
f_1	6,0014	6,0017	0,005	6,022	0,345
f_2	24,0019	24,0069	0,021	23,607	1,646
f_3	53,9904	54,0155	0,046	53,484	0,938

Como pode ser observado, o modelo numérico apresentou uma boa correlação com o modelo experimental e as formulações analíticas, logo pode ser considerado como validado.

4.3 Avaliação de danos

Para simular o dano foi feita uma redução na seção transversal da viga com extensão de 2 cm, que corresponde ao tamanho do elemento finito adotado na viga intacta. A largura do dano é a mesma da viga, ou seja, 2,51cm, e a altura variou-se para simular diferentes intensidades de dano. A Fig. 6 apresenta um trecho da viga com a presença de um dano.

**Figura 6. Representação de um trecho da viga danificada**

Quando o dano foi modelado com 2cm de comprimento, a malha foi reajustada para 1cm de comprimento, com o objetivo de discretiza melhor a viga danificada. Na Fig. 7 é possível observar a discretização em elementos menores.

Para melhor discretização da região danificada foram utilizados dois tipos de elementos finitos na viga, hexadricos com 20 graus de liberdade (na cor amarela na Fig. 7) e pentágonos com 15 graus de liberdade (representado na cor cinza na Fig. 7). Ao total os modelos danificados ficaram com aproximadamente 320 elementos.




Figura 7. Malha da viga com redução de 33,9% na seção transversal a 12cm do apoio

O dano altera a frequência de uma estrutura dependendo de sua intensidade e posição. Para verificar a sensibilidade da viga com relação às diferentes posições e intensidades de dano, foi verificado o dano presente em 9 pontos e com intensidades variando de 3,4% a 40,7%, com relação à área do elemento intacto. Na Fig. 8 é apresentada esta sensibilidade, onde a origem representa o apoio sem restrição de movimento em Z e '0,75' o meio do viga. Todos os dados apresentados na Fig. 8 foram obtidos à 25°C, temperatura esta adotada como padrão.




Figura 8. Influência do dano devido sua intensidade e posição

Verificou-se que a frequência variou de 0,1% a 4,5% no meio da viga, aproximadamente, de modo que estes índices passaram a ser utilizados como dados de entrada da rede. Foram criados 77 cenários de danos (D1 a D77) com as características indicadas na Tab. 5, onde a posição do dano tem como referência o apoio sem restrição de movimento em Z e a intensidade refere-se à percentagem da seção transversal retirada.

Tabela 5. Descrição dos cenários de dano criados

Dano	Posição (cm)	Intensidade	Dano	Posição (cm)	Intensidade	Dano	Posição (cm)	Intensidade	Dano	Posição (cm)	Intensidade
D1	3	3,4%	D21	65	16,9%	D41	50	28,8%	D61	52	37,3%
D2	17	3,4%	D22	70	16,9%	D42	57	28,8%	D62	61	37,3%
D3	33	3,4%	D23	75	16,9%	D43	64	28,8%	D63	70	37,3%
D4	48	3,4%	D24	21	20,3%	D44	71	28,8%	D64	75	37,3%
D5	57	3,4%	D25	36	20,3%	D45	75	28,8%	D65	6	40,7%
D6	68	3,4%	D26	44	20,3%	D46	7	33,9%	D66	10	40,7%
D7	75	3,4%	D27	55	20,3%	D47	15	33,9%	D67	18	40,7%
D8	9	8,5%	D28	62	20,3%	D48	19	33,9%	D68	26	40,7%
D9	25	8,5%	D29	72	20,3%	D49	28	33,9%	D69	37	40,7%
D10	41	8,5%	D30	5	25,4%	D50	39	33,9%	D70	47	40,7%
D11	53	8,5%	D31	19	25,4%	D51	48	33,9%	D71	56	40,7%
D12	63	8,5%	D32	33	25,4%	D52	57	33,9%	D72	66	40,7%
D13	72	8,5%	D33	45	25,4%	D53	67	33,9%	D73	75	40,7%
D14	75	8,5%	D34	58	25,4%	D54	75	33,9%	D74	5	33,9%
D15	2	16,9%	D35	69	25,4%	D55	4	37,3%	D75	28	30,5%
D16	14	16,9%	D36	75	25,4%	D56	13	37,3%	D76	65	32,2%
D17	27	16,9%	D37	3	28,8%	D57	20	37,3%	D77	68	11,9%
D18	39	16,9%	D38	12	28,8%	D58	26	37,3%			
D19	51	16,9%	D39	24	28,8%	D59	33	37,3%			
D20	58	16,9%	D40	37	28,8%	D60	43	37,3%			

Baseadas em um conjunto representativo de dados, as RNAs são utilizadas para reconhecer os padrões provocados pelas diferentes posições e intensidades de dano, estando este à temperatura padrão adotada de 25°C.

Para criação da RNA, utilizou-se o *software* de cálculo numérico Matlab. Este *software* possui alguns pacotes e rotinas pré-definidos, o que facilita sua utilização. Um desses pacotes é o Neural Network Toolbox que fornece algoritmos, funções e aplicativos para criar, treinar, visualizar e simular redes neurais (MATHWORKS, 2016).

No pacote *Neural Network Toolbox* é possível escolher a rede e suas características. Na RNA do tipo *Multilayer Perceptron* (MLP) com algoritmo de aprendizagem *Backpropagation* o usuário pode escolher a função de treinamento da rede, quantidade de neurônios, função de ativação, entre outras características, de modo que possa analisar e generalizar apropriadamente o problema.

O pacote também fornece ao usuário gráficos interativos, como o da regressão da rede, que mostra a relação entre as saídas encontradas pela rede (output) e o objetivo (target), durante as fases de treinamento e validação.

A RNA utilizada é denominada no Matlab como “Feed-forward backprop”. Como mencionado, adotou-se o algoritmo *Backpropagation*, com a regra de atualização de pesos Levenberg-Marquardt, nomeado, no Matlab, por “trainlm”. O desempenho do treinamento da rede foi obtido através da média dos erros quadrados.

Com relação à função de ativação, testaram-se três, a tangente hiperbólica, a sigmoideal e a linear. Tanto a sigmoideal como a linear, apresentaram um comportamento de distorção, não sendo possível obter resultados satisfatórios. Com isso, optou-se por utilizar com função de ativação a tangente hiperbólica.

Por tentativa e erro, foram testados de 6 a 12 neurônios, para cada conjunto de dados de entrada, afim de se analisar o comportamento da rede e verificar qual apresentava os menores erros durante a simulação. Além disso, foi aceito um erro de até 4% nos gráficos da regressão da rede, ou seja, a RNA foi considerada como apta apenas quando $R > 0,96$.

Foram fornecidos à RNA, como dados de entrada, as quatro primeiras frequências de flexão dos modelos de viga danificados (cenários D1 a D73), como também as quatro frequências da viga intacta, totalizando uma matriz de dados 4×74 . Para a fase de treinamento foram usados 70% destes dados, ou seja 52 cenários de dano e para a validação 30%, que corresponde a 22 cenários. Estes cenários são escolhidos aleatoriamente pela RNA para cada fase. Como dados de saída, para as fases de treinamento e validação, foram fornecidas as posições do dano com referência o apoio sem restrição de movimento em Z, apresentadas na Tab. 5.

Os cenários D74 a D77 foram utilizados durante as simulações da rede, também conhecida como fase de generalização. Na Tab. 6 são apresentados os resultados de cada rede (localização do dano), bem como os erros obtidos nas simulações. A primeira coluna da Tab. 6 representa a RNA, a segunda coluna a quantidade de neurônios e, nas demais colunas, as saídas obtidas nas simulações, saída desejada (posição do dano) e os respectivos erros, em centímetros, entre a saída fornecida e a esperada para os danos simulados.

Tabela 6. Erros encontrados na localização dos danos D74 a D77

Rede	Nº neurônios	D74 (cm)			D75 (cm)			D76 (cm)			D77 (cm)		
		Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro
1	6	4,4		0,6	29,1		-1,1	60,4		4,6	71,3		-3,3
		5,0		0,0	31,9		-3,9	60,3		4,7	71,8		-3,8
5,1			-0,1	23,1		4,9	68,5		-3,5	65,7		2,3	
3,9			1,1	25,1		2,9	69,1		-4,1	65,9		2,1	
5,1		5,0	-0,1	23,1	28,0	4,9	68,5	65,0	-3,5	65,7	68,0	2,3	
5,6			-0,6	27,7		0,3	64,8		0,2	69,5		-1,5	
4,9			0,1	27,4		0,6	64,5		0,5	69,7		-1,7	
6,9			-1,9	24,1		3,9	75,0		-10,0	75,0		-7,0	
5,2			-0,2	31,0		-3,0	64,6		0,4	72,7		-4,7	
5		5,0		0,0	25,4		2,6	64,1		0,9	75,0		-7,0
1	7	6,8		-1,8	20,9		7,1	64,0		1,0	67,2		0,8
		6,9		-1,9	24,2		3,8	63,9		1,1	67,7		0,3
5,4		5,0	-0,4	25,2	28,0	2,8	64,5	65,0	0,5	68,2	68,0	-0,2	
8,1			-3,1	28,4		-0,4	68,1		-3,1	62,4		5,6	
6,1			-1,1	24,8		3,2	69,7		-4,7	72,0		-4,0	
4,8			0,2	30,1		-2,1	65,1		-0,1	71,9		-3,9	

Tabela 6. Erros encontrados na localização dos danos D74 a D77 (continuação)

Rede	Nº neurônios	D74 (cm)			D75 (cm)			D76 (cm)			D77 (cm)		
		Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro	Saída obtida	Saída desejada	Erro
1		7,2		-2,2	28,7		-0,7	64,8		0,2	70,8		-2,8
		5,3		-0,3	28,2		-0,2	64,6		0,4	70,5		-2,5
2		5,1		-0,1	29,9		-1,9	64,5		0,5	70,4		-2,4
		6,1		-1,1	30,7		-2,7	64,2		0,8	69,1		-1,1
3		6,5		-1,5	29,6		-1,6	64,3		0,7	71,3		-3,3
		5,4		-0,4	27,4		0,6	64,1		0,9	71,5		-3,5
4	8	4,0	5,0	1,0	27,5	28,0	0,5	64,3	65,0	0,7	71,3	68,0	-3,3
		4,1		0,9	25,7		2,3	64,6		0,4	69,6		-1,6
		5,1		-0,1	28,4		-0,4	64,8		0,2	72,4		-4,3
		4,5		0,5	28,3		-0,3	62,7		2,3	69,5		-1,5
5		4,7		0,3	27,9		0,1	65,2		-0,2	69,3		-1,3
		3,7		1,3	30,3		-2,3	62,7		2,3	72,5		-4,5
6		3,6		1,4	27,7		0,3	65,1		-0,1	69,3		-1,3
1		5,3		-0,3	27,5		0,5	72,1		-7,1	73,7		-5,7
		5,2		-0,2	29,7		-1,7	69,8		-4,8	70,6		-2,6
		4,9		0,1	30,6		-2,6	68,6		-3,6	70,1		-2,1
		5,2	5,0	-0,2	27,6	28,0	0,4	64,4	65,0	0,6	67,8	68,0	0,2
2	9	5,7		-0,7	27,2		0,8	63,9		1,1	69,6		-1,6
		4,2		0,8	27,1		0,9	65,2		-0,2	74,0		-6,0
3		5,9		-0,9	27,3		0,7	65,0		0,0	74,0		-6,0
4		5,5		-0,5	28,5		-0,5	63,3		1,7	74,0		-6,0
1		6,7		-1,7	27,6		0,4	63,2		1,8	74,9		-6,9
		7,0		-2,0	29,0		-1,0	66,5		-1,5	74,9		-6,9
2		4,6		0,4	28,5		-0,5	63,8		1,2	70,7		-2,7
		4,9		0,1	27,4		0,6	63,5		1,5	69,0		-1,0
		6,9		-1,9	25,7		2,3	63,9		1,1	75,0		-7,0
		8,5	5,0	-3,5	26,4	28,0	1,6	64,4	65,0	0,6	75,0	68,0	-7,0
3	10	6,9		-1,9	27,2		0,8	66,1		-1,1	74,9		-6,9
		5,6		-0,6	33,8		-5,8	65,0		0,0	69,9		-1,9
4		6,3		-1,3	49,6		-21,6	60,2		4,8	74,8		-6,8
		6,5		-1,5	30,4		-2,4	69,6		-4,6	49,3		18,7
5		3,1		1,9	26,7		1,3	62,4		2,6	54,4		13,6
		2,7		2,3	25,7		2,3	58,0		7,0	67,8		0,2
1		5,7		-0,7	29,5		-1,5	65,2		-0,2	74,8		-6,8
		4,8		0,2	30,3		-2,3	65,2		-0,2	74,9		-6,9
		2,7		2,3	24,5		3,5	66,9		-1,9	73,7		-5,7
		9,2	5,0	-4,2	31,0	28,0	-3,0	66,1	65,0	-1,1	74,5	68,0	-6,5
3		7,3		-2,3	34,4		-6,4	67,0		-2,0	67,2		0,8
		4,7		0,3	29,0		-1,0	65,1		-0,1	75,0		-7,0
		4,1		0,9	20,9		7,1	63,3		1,7	71,9		-3,9
4		4,6		0,4	24,0		4,0	64,7		0,3	69,8		-1,8

Como pode-se observar na tabela, a rede que apresentou melhor desempenho foi a com 8 neurônios, cujo erros após o retreinamento foi inferior a 3cm. Além disto o dano D77 apresentou os maiores erros nas primeiras simulações, em todas as quantidades de neurônios, e isto pode ser justificado pela pequena intensidade deste dano. Ou seja, a RNA treinada apresenta maior dificuldade em localizar danos de pequena magnitude.

Sendo assim, a melhor configuração encontrada para a localização do dano na viga estudada possui a função tangente hiperbólica como função de ativação, 74 cenários de dados de entrada e 8 neurônios.

4.4 Influência da temperatura no método de avaliação de danos

Para verificar se as mudanças de temperatura alteravam a avaliação de danos, optou-se por simular variações de temperatura, obter as frequências modificadas apenas pela temperatura e, com estas, testar a rede obtida no item anterior. O resultado correto deveria ser a não localização de nenhum dano. Para estas simulações, com a temperatura, foram utilizados os dados da Tab. 7, ou seja, as frequências para temperaturas variando de 3° a 38°C.

Tabela 7. Temperatura e respectivas frequências utilizadas para testar a influência provocada pela temperatura na avaliação de dano

Temp.	3°C	18°C	30°C	38°C
f_1 (Hz)	6,0157	6,0065	5,9975	5,9907
f_2 (Hz)	24,0590	24,0225	23,9862	23,9592
f_3 (Hz)	54,1187	54,0366	53,9549	53,8944
f_4 (Hz)	96,1757	96,0299	95,8847	95,7771

Os resultados obtidos com as simulações dos dados da Tab. 7 para a RNA que apresentou os melhores resultados, com 8 neurônios, encontram-se na Tab. 8. Os resultados apresentados na Tab. 8 foram obtidas das mesmas RNAs utilizadas no item anterior, desde os dados de treinamento até saídas, inclusive funções e pesos. A primeira coluna diz respeito a rede e as demais colunas as saídas, ou seja, a posição do dano fornecida pelas RNAs, em centímetros.

Tabela 8. Saídas fornecida pela RNA com 8 neurônios para os cenários apresentados na Tab. 7

Rede	Saídas fornecida pelas RNAs (cm)			
	3°C	18°C	30°C	38°C
1	1,6E-11	4,0E-04	45,6	54,6
	0	2,5E-06	52,9	55,9
2	0	0	62,4	42,3
	0	0	57,5	41,4
3	9,6E-14	3,2E-09	44,8	43,0
	0	0	62,7	61,9
4	0	0	64,8	63,1
	0	0	60,6	58,6
5	1,5E-11	1,6E-05	51,4	61,3
	1,4E-13	4,0E-05	52,3	52,8
	0	2,0E-10	60,9	57,4
6	5,8E-14	3,2E-05	49,5	67,1
	3,8E-02	8,9E-11	69,1	72,8

Uma vez que a saída da rede é a distância com relação ao apoio, cujo deslizamento é permitido no eixo Z, portanto, as saídas obtidas nas simulações de 3°C e 18°C representam que não houve uma localização de dano. Isto ocorreu porque a redução da temperatura provoca aumento nas frequências, fazendo com que as temperaturas abaixo de 25°C ficassem fora do espectro fornecido durante o treinamento, o que provocará como *output* da rede a menor saída treinada, ou seja, a posição intacta.

Já para as temperaturas de 30°C e 38°C a rede apresentou como *output* (saídas) valores representativos, variando de 41,4cm à 72,8cm, ou seja, as temperaturas acima de 25°C alteram a avaliação de dano. Sendo assim, é de fundamental importância que se considere este efeito ambiental na concepção da RNA, para que a rede não forneça falsas localizações do dano como ocorreu para as simulações apresentadas.

5 CONCLUSÃO

Garantir a integridade estrutural é fundamental para que a estrutura tenha uma vida útil prolongada e proporcione conforto aos usuários. Neste sentido métodos de avaliação de dano são úteis afim de se realizar uma manutenção preventiva da estrutura.

Quando se utiliza métodos de detecção de dano que se baseiam nas características dinâmicas e a estrutura encontra-se susceptível a efeitos ambientais, principalmente à variação da temperatura, é de fundamental importância que se interprete corretamente a influência que este efeito provoca nas características dinâmicas.

Variou-se a quantidade de neurônios e dados de entrada utilizados nas análises até se obter a melhor precisão nos resultados. Poucos neurônios apresentaram uma convergência lenta e muitos não conseguiram localizar danos de pequena intensidade.

Por fim, quando se utilizou a RNA configurada para localizar dano, na viga sob influência apenas da temperatura, a RNA apresentou como resultado uma falsa localização do

dano para temperaturas acima de 25°C. Para pequenas intensidades de dano, até aproximadamente 8,5% para a viga estudada, a frequência natural de flexão teve uma redução inferior à provocada pela variação de 40°C. Logo, se a variação da temperatura não for considerada, ou for considerada de maneira errônea, os métodos de detecção de dano não serão confiáveis.

AGRADECIMENTOS

Agradeço ao Programa de Pós-graduação em Estruturas e Construção Civil (PECC) pela oportunidade, à acadêmica de doutorado Marília Marcy pelo suporte, a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação de Apoio à Pesquisa do Distrito Federal (FAP-DF) pela ajuda financeira.

REFERENCIAS

BRAGA, A. DE P.; CARVALHO, A. P. DE L. F.; LUDERMIR, T. B. *Redes Neurais Artificiais : Teoria e Aplicações*. Primeira ed. Rio de Janeiro, RJ, Brasil: LTC, 2000.

FU, Y.; DEWOLF, J. T. Monitoring and Analysis of a Bridge with Partially Restrained Bearings. *Journal of Bridge Engineering*, v. 6, n. February, p. 23–29, 2001.

HAYKIN, S. *Neural Networks and Learning Machines*. Third ed. Hamilton, Ontario, Canada: Pearson, 2009.

JIN, C.; JANG, S.; SUN, X.; LI, J.; CHRISTENSON, R. Damage detection of a highway bridge under severe temperature changes using extended Kalman filter trained neural network. *Journal of Civil Structural Health Monitoring*, v. 6, n. 3, p. 545–560, 2016.

LI, H.; LI, S.; OU, J.; LI, H. Modal identification of bridges under varying environmental conditions : Temperature and wind effects. *Structural Control and Health Monitoring*, v. 17, n. February 2009, p. 495–512, 2010.

MAIA, R. *Detecção de Dano Estrutural em Estruturas Planas Utilizando Redes Neurais*. Dissertação de Mestrado em Estruturas e Construção Civil, Publicação E.DM-025A/16, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília: Brasília, DF, 94p., 2016.

MARCY, M. *Identificação e Quantificação de Danos em Pórticos Espaciais Via Método do Erro Residual e Redes Neurais Artificiais*. Dissertação de Mestrado em Estruturas e Construção Civil, Publicação E.DM-001A/13, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília: Brasília, DF, 112p., 2013.

MATHWORKS. *Help System*, 2016.

MOSER, P.; MOAVENI, B. Environmental effects on the identified natural frequencies of the Dowling Hall Footbridge. *Mechanical Systems and Signal Processing*, v. 25, n. 7, p. 2336–2357, 2011.

ORTIZ MORALES, F. A. *Avaliação da influência da temperatura sobre os parâmetros modais de estruturas*. Dissertação de Mestrado em Engenharia Civil, Departamento de Engenharia Civil, Universidade Federal de Ouro Preto: Ouro Preto, MG, 110p., 2016.

- POH, K. W. Stress-Strain-Temperature Relationship for Structural Steel. n. October, p. 371–379, 2001.
- SOHN, H.; FARRAR, C. R.; HEMEZ, F.; CZARNECKI, J. A Review of Structural Health Monitoring Literature 1996 - 2001. *Structural Health Monitoring*, 2002.
- WAHAB, M. A.; ROECK, G. DE. Effect of Temperature on Dynamic System Parameters of a Highway Bridge. *Structural Engineering International*, p. 266–270, 1997.
- WU, X.; GHABOUSSI, J.; GARRETT, J. H. Use of Neural Networks in detection of structural damage. *Computers & Structures*, v. 42, n. 4, p. 649–659, 1992.
- XIA, Y.; CHEN, B.; WENG, S.; NI, Y.; XU, Y. Temperature effect on vibration properties of civil structures: a literature review and case studies. *Journal of Civil Structural Health Monitoring*, v. 2, p. 29–46, 2012.
- ZHOU, G.; YI, T. A Summary Review of Correlations between Temperatures and Vibration Properties of Long-Span Bridges. *Mathematical Problems in Engineering*, v. 2014, p. 19, 2014.