



Detecção de Danos Estruturais Baseada em Históricos de Aceleração e Redes Neurais Artificiais

Victor Fabrício Magalhães Carvalho¹, Marília Marcy Cabral de Araújo², Graciela Doz³

¹Universidade de Brasília / Departamento de Engenharia Civil e Ambiental / victor.mcarv@gmail.com

²Universidade Federal de Campina Grande / Departamento de Engenharia Civil / marilia.marcy@ufcg.edu.br

³Universidade de Brasília / Departamento de Engenharia Civil e Ambiental / graciela@unb.br

Resumo

Os processos naturais de deterioração estrutural, assim como a busca por projetos mais arrojados, resultam na necessidade de um constante monitoramento da saúde das estruturas civis, de maneira a permitir a intervenção precoce, visando garantir a segurança dos usuários e a redução dos custos de recuperação estrutural. Nesse contexto, os métodos de avaliação de danos baseados em variações das propriedades modais das estruturas passaram a ser bastante estudados, devido às suas capacidades de avaliação de uma maneira global. No entanto, a maioria desses métodos compartilha de alguns problemas em sua aplicação, como a perda de informações dos sinais de vibração da estrutura durante o processo de obtenção de suas características dinâmicas e a pequena variação das frequências naturais mesmo sob estado de danos significativos, podendo, em muitos casos, ser confundida com variações decorrentes de fatores ambientais, tais como a mudança de temperatura. Este trabalho é a primeira parte de um estudo que objetiva uma avaliação do uso de fatores estatísticos derivados diretamente de históricos de aceleração das estruturas, como parâmetros alternativos a serem aplicados, em aliança ao uso de redes neurais artificiais, em metodologias de detecção de danos estruturais. Para tanto, trabalhou-se inicialmente de forma numérica com vigas, considerando diferentes casos de dano estrutural. As estruturas estudadas foram submetidas a impactos e foram extraídos os sinais de aceleração para posterior processamento em forma de parâmetros estatísticos, que por sua vez foram utilizados para treinar, validar e testar redes neurais artificiais propostas para a detecção de danos estruturais, variando e analisando fatores como o número de neurônios e as funções de ativação da rede, assim como ruídos que existiriam em um ensaio experimental ou cenários de múltiplos danos. Os testes mostraram um bom desempenho do uso dos indicadores estatísticos como parâmetros de treinamento de redes para detecção de danos.

Palavras-chave

SHM; Monitoramento de estruturas; Detecção de danos; Redes neurais artificiais.

Introdução

A detecção de danos em estruturas civis é um tema de grande importância para a engenharia. A capacidade de identificar possíveis anomalias em uma estrutura permite a intervenção precoce, visando garantir a segurança dos usuários e a redução dos custos de recuperação estrutural. Nesse contexto, desenvolveu-se ao longo do tempo a área da engenharia conhecida como Monitoramento da Saúde Estrutural (em inglês, *Structural Health Monitoring* – SHM).

O SHM pode ser definido como um conjunto de ferramentas, sensores e técnicas capazes de interpretar o real estado de uma estrutura. Com o intuito de desenvolver técnicas que permitissem a avaliação do estado das estruturas de maneira global, foi proposta a utilização de seus parâmetros modais, sendo eles as frequências naturais, os modos de vibração e os amortecimentos, como indicadores de dano, por apresentarem sensibilidade às características físicas das estruturas. Nesse

contexto, foram desenvolvidas diversas metodologias para a avaliação das variações dos parâmetros modais das estruturas com o intuito de detecção de danos.

Metodologias como o índice MAC (*Modal Assurance Criterion*), capaz de correlacionar modos de vibração da estrutura intacta e danificada (Allemang & Brown, 1982), o Método da Curvatura Modal, para localização de danos em elementos de vigas (Pandey *et al.*, 1991), o indicador MSECR (*Modal Strain Energy Change Ratio*), capaz de localizar danos contando apenas com as matrizes de rigidez e modos de vibração dos elementos intactos e danificados (Shi & Law, 1998), o *Mode Shape Area Index*, baseado nas alterações das áreas sob os modos de vibração, capaz de detectar o dano com o uso dos dois primeiros modos de vibração de flexão (Huth *et al.*, 2005), e o método de Gillich & Praisach (2014), capaz de detectar e localizar danos em vigas utilizando uma equação em função do quadrado das curvaturas dos modos de vibração e de um fator relativo à profundidade do dano, são alguns exemplos dentre uma enorme gama de métodos desenvolvidos.

Essas metodologias, apesar de se mostrarem muito eficientes em um ambiente controlado, compartilhavam de alguns problemas que desafiam sua praticidade de aplicação em estruturas usuais. Por exemplo, a perda de informações dos sinais de vibração da estrutura durante o processo de obtenção de suas características dinâmicas dificulta a visualização de pequenas mudanças na estrutura. Ou a pequena variação das frequências naturais mesmo sob estado de danos significativos, podendo, em muitos casos, ser confundida com variações decorrentes de fatores ambientais, tais como a mudança de temperatura, como notado por Huth *et al.* (2005). Isso levou a uma busca por alternativas aos parâmetros modais como indicadores de dano. Uma das propostas é a utilização de respostas dinâmicas diretamente no domínio do tempo, como históricos de aceleração, de maneira a contornar a perda de informações resultante da transformação para o domínio da frequência e obter-se características que variem mais significativamente com a deterioração das estruturas, de forma que não possam ser confundidas com variações provocadas por fatores ambientais, como apontado em Alves *et al.* (2015).

Há ainda uma outra questão a ser abordada. A utilização, seja de variações dos parâmetros modais, seja de históricos de aceleração, em métodos de detecção de danos, envolve a necessidade de se trabalhar com um enorme volume de dados, além da dificuldade de se extrair informações importantes de sinais ruidosos. Neste contexto, técnicas de aprendizado de máquina, mais especificamente as Redes Neurais Artificiais (RNAs), vêm se provando valiosas ferramentas de tratamento de dados e reconhecimento de padrões, sendo amplamente utilizadas em estudos como Rucka & Wilde (2010), Bandara *et al.* (2014), Jin *et al.* (2015), Avci & Abdeljaber (2016), Marcy *et al.* (2017), Teng *et al.* (2019), Finotti *et al.* (2019) e Nunes *et al.* (2020). Avci *et al.* (2021) faz uma extensa revisão dos métodos de SHM, desde os tradicionais até os que utilizam aprendizado de máquina e aprendizado profundo.

O presente trabalho é parte de um estudo que busca avaliar o uso de fatores estatísticos derivados diretamente de históricos de aceleração das estruturas como parâmetros alternativos às propriedades modais para aplicação, juntamente ao uso de redes neurais artificiais, em metodologias de detecção de danos estruturais. Inicialmente foram estudados os históricos de aceleração de um modelo numérico de viga biapoiada, considerando-a em um estado intacto e também em diferentes cenários de dano. A partir desses registros foram extraídos parâmetros estatísticos utilizados no treinamento e testes de Redes Neurais Artificiais propostas para a detecção de danos estruturais.

Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são modelos de aprendizado de máquina inspirados no cérebro humano. Elas consistem em camadas de neurônios artificiais interconectados que processam informações e aprendem a reconhecer padrões a partir de exemplos dados durante seu treinamento.

Entre as arquiteturas de rede mais utilizadas está o Perceptron Multicamadas (em inglês, *Multilayer Perceptron* – MLP), apresentado na Figura 1. Isso se deve ao fato desse tipo de rede ser relativamente

simples, porém bastante efetivo em uma grande quantidade de problemas de classificação. Essa arquitetura se caracteriza pela presença de uma ou mais camadas ocultas, assim chamadas por não possuírem interface nem na entrada e nem na saída da rede, formadas por vários neurônios que processam informações em paralelo. Cada neurônio recebe um conjunto de entradas, realiza uma soma ponderada delas e aplica uma função de ativação para produzir uma saída a ser utilizada como entrada pelos neurônios da camada seguinte, até que seja obtida a saída geral da rede, classificando-se então como uma arquitetura *feedforward*. O MLP utiliza algoritmos de aprendizado supervisionado, mais comumente a retropropagação do erro (em inglês, *backpropagation*) para ajustar os pesos das ligações entre neurônios de forma a minimizar uma função de erro até que o resultado se encaixe dentro de um limite de tolerância estipulado, assim tornando a rede capaz de classificar corretamente novos dados fornecidos.




Figura 1 – Rede MLP com duas camadas ocultas.

Observa-se que redes do tipo MLP possuem diversos parâmetros que podem ser ajustados para o problema em questão, como o número de camadas ocultas, o número de neurônios por camada e suas funções de ativação, sendo eles geralmente determinados de maneira empírica. Portanto, é interessante que seja feita uma comparação do comportamento dessas redes ao variar-se esses parâmetros.

Parâmetros estatísticos extraídos de históricos de aceleração

O uso direto de sinais de aceleração no domínio do tempo como indicadores de dano pode ser uma tarefa complicada. Isso ocorre porque os sinais obtidos no monitoramento possuem uma imensa quantidade de informações, muitas vezes repletas de ruídos e, portanto, sem significância para o problema em questão. É muito importante, portanto, que sejam utilizados, como entrada das redes, parâmetros que possam representar os grandes conjuntos de dados obtidos durante o monitoramento das estruturas de maneira mais compacta, sem que haja perda de informações significativas.

Nesse sentido, Farrar e Worden (2012), sugerem o uso de dez indicadores estatísticos como uma forma de representar o conjunto de dados que forma um determinado sinal y . Os indicadores reduzem uma série temporal a um único parâmetro. Se utilizados em conjunto, podem formar um vetor característico que representa vários aspectos do sinal original.

Os parâmetros estatísticos representam diferentes características dos sinais, e sofrem alterações na presença de danos. O *pico de amplitude* do sinal, por exemplo, aumenta quando ocorre uma redução na rigidez do sistema. Já a *média* representa a tendência central do sinal e normalmente não sofre grandes alterações, mesmo em sistemas degradados. A *média quadrática* e a sua raiz (*RMS*) medem o grau de espalhamento dos dados, enquanto a *variância* e o *desvio padrão* trazem informações sobre a dispersão dos dados ao redor da média das amplitudes do sinal, sendo que todos eles sofrerão um aumento na presença de danos. A *assimetria* da distribuição dos dados de um sistema terá um valor

nulo até que seja introduzida alguma interferência que produza uma resposta não linear. Por sua vez, a *curtose* mede o grau de achatamento de uma distribuição. Por fim, o *fator de crista* e o *fator-k* são indicadores estatísticos utilizados para verificar desvios de uma resposta senoidal. A definição matemática desses parâmetros é apresentada na Tabela 1 a seguir, onde n representa o total de dados do conjunto.

Tabela 1 – Indicadores estatísticos utilizados como parâmetros sensíveis a danos.

Parâmetro	Equação
P1: Pico de amplitude (y_{peak})	$y_{peak} = \max y_i $
P2: Média (\bar{y})	$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$
P3: Média quadrática (\bar{y}_{sq})	$\bar{y}_{sq} = \frac{1}{n} \sum_{i=1}^n (y_i)^2$
P4: RMS	$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i)^2}$
P5: Variância (σ^2)	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$
P6: Desvio padrão (σ)	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$
P7: Assimetria (adimensional) (γ)	$\gamma = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3}{\sigma^3}$
P8: Curtose (adimensional) (κ)	$\kappa = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4}{\sigma^4}$
P9: Fator de crista (X_{cf})	$X_{cf} = y_{peak}/rms$
P10: Fator-k (X_k)	$X_k = y_{peak} \cdot rms$

É importante destacar que as maiores vantagens da utilização dos fatores estatísticos apresentados em uma metodologia de detecção de danos é que eles são capazes de representar diversos aspectos do sinal original e são facilmente obtidos a partir dele. Isso favorece o seu uso em técnicas de monitoramento contínuo.

Modelo numérico e treinamento das redes

O treinamento de RNAs exige uma grande quantidade de dados de uma estrutura em diferentes estados, que normalmente não podem ser obtidos para estruturas reais, onde se tem por referência somente o seu estado atual. Para essa questão, uma solução comumente apontada por pesquisadores, como Rucka & Wilde (2010), é a construção de modelos numéricos que simulem diversos outros estados possíveis da estrutura, gerando um conjunto de dados de tamanho suficiente para que possa ser utilizado no treinamento e validação das redes. Modelos numéricos são, portanto, de grande importância quando pretende-se utilizar RNAs para detecção de danos estruturais.

Para o presente trabalho, foi desenvolvido o modelo numérico de uma viga em aço de Perfil U 101,6 x 4,67, biapoiada com comprimento de 2,0 m. A viga foi discretizada em 40 elementos de 5 cm, de maneira a permitir a fácil adaptação do modelo para os vários casos de dano simulados. Foram simulados 9 pontos de medição, um a cada 20 cm, e foi aplicado um impacto de valor máximo 3 N num intervalo de 0 a 3 milissegundos, em um ponto distante 40 cm do apoio. O esquema da viga e sua seção transversal são apresentados, respectivamente, nas Figuras 2 e 3, enquanto as propriedades da seção e do material são apresentadas na Tabela 2.




Figura 2 – Representação do modelo da viga.




Figura 3 – Seção transversal da viga.

Tabela 2 – Propriedades da seção da viga e do material.

Propriedades	Valores
Área da Seção	1,05E-03 m ²
Momento de Inércia da Seção	1,34E-07 m ⁴
Módulo de Elasticidade	2,0E+11 N/m ²
Coefficiente de Poisson	0,3
Densidade	7850 kg/m ³

Para o treinamento das redes, foram simulados, além do caso da viga intacta, 15 casos de dano, apresentados na Tabela 3, onde h_{dano} é a altura danificada representada pelas hachuras na Figura 3.

Tabela 3 – Casos de dano utilizados no treinamento e validação das redes.

C0: sem elementos danificados	C8: elementos 20, 21 e 22; $h_{\text{dano}} = 8$ mm
C1: elementos 1, 2 e 3; $h_{\text{dano}} = 8$ mm	C9: elementos 23 e 24; $h_{\text{dano}} = 15$ mm
C2: elementos 4 e 5; $h_{\text{dano}} = 13$ mm	C10: elementos 25, 26 e 27; $h_{\text{dano}} = 2$ mm
C3: elementos 6, 7 e 8; $h_{\text{dano}} = 2$ mm	C11: elementos 28 e 29; $h_{\text{dano}} = 13$ mm
C4: elementos 9, 10 e 11; $h_{\text{dano}} = 8$ mm	C12: elementos 30, 31 e 32; $h_{\text{dano}} = 8$ mm
C5: elementos 12 e 13; $h_{\text{dano}} = 15$ mm	C13: elementos 33, 34 e 35; $h_{\text{dano}} = 13$ mm
C6: elementos 14, 15 e 16; $h_{\text{dano}} = 2$ mm	C14: elementos 36, 37 e 38; $h_{\text{dano}} = 15$ mm
C7: elementos 17, 18 e 19; $h_{\text{dano}} = 13$ mm	C15: elementos 39 e 40; $h_{\text{dano}} = 8$ mm

Os históricos de acelerações foram coletados para um intervalo de 3 segundos a partir do impacto a uma frequência de 3000 Hz, totalizando 9000 medições por ponto, para cada simulação. Então, foram

processados e transformados nos 10 parâmetros estatísticos apresentados previamente na Tabela 1, e organizados em matrizes [90x124], como apresentado em (1) e descrito a em seguida.

$$\begin{bmatrix} P1_{a1}C0_{R0} & P1_{a1}C0_{R1} & \cdots & P1_{a1}C15_{R2} \\ P2_{a1}C0_{R0} & P2_{a1}C0_{R1} & \cdots & P2_{a1}C15_{R2} \\ \vdots & \vdots & \ddots & \vdots \\ P10_{a9}C0_{R0} & P10_{a9}C0_{R1} & \cdots & P10_{a9}C15_{R2} \end{bmatrix} \quad (1)$$

As linhas são compostas pelos parâmetros estatísticos P , agrupados de 10 em 10 para cada um dos 9 pontos de medição a , totalizando 90 linhas. Já as colunas são compostas pelos diferentes casos de dano, de $C0$ a $C15$, organizados de acordo com o nível de ruído adicionado, sendo $R0$, $R1$ e $R2$ equivalentes, respectivamente, a 0, 5 e 10% de ruído. Para o caso $C0$, foram colocadas 1 coluna com ruído 0% ($R0$), 9 colunas com ruído 5% ($R1$) e 9 colunas com ruído 10% ($R2$). Para os demais casos, foram colocadas 1 coluna com ruído 0% ($R0$), 3 colunas com ruído 5% ($R1$) e 3 colunas com ruído 10% ($R2$), totalizando 124 colunas. Os valores das matrizes de entrada também foram normalizados entre -1 e 1 para uniformizar a influência dos diferentes parâmetros estatísticos.

A equação em (2) representa a maneira como os ruídos foram adicionados aos sinais.

$$x_{i,r} = x_i + r \cdot \sigma_{x_i} \cdot \text{randn}(0,1) \quad (2)$$

Onde: $x_{i,r}$ é o sinal com ruído; x_i é o sinal sem ruído; r é o nível de ruído; σ_{x_i} é o desvio padrão do sinal sem ruído; e $\text{randn}(0,1)$ é um valor aleatório de distribuição normal, média igual a 0 e desvio padrão igual a 1.

Já as saídas da rede foram dadas como matrizes [1x124] compostas apenas por binários, onde 0 representa ausência de dano e 1 representa a presença de dano, a exemplo do apresentado em (3), e cada uma de suas colunas corresponde à entrada de mesmo índice em (1).

$$[0 \ 0 \ \cdots \ 1] \quad (3)$$

Foram treinadas e avaliadas nesse trabalho, 4 redes MLP de uma única camada oculta e função de ativação sigmoide tangente hiperbólica (*tansig*), representada na Figura 4(a). O número de neurônios da camada oculta foi encontrado empiricamente através de tentativa e erro, e serão apresentados os resultados para 20 e 30 neurônios na camada oculta. Já na camada de saída, foram utilizadas funções de ativação sigmoide tangente hiperbólica (*tansig*) e linear saturada simétrica (*satlins*), representada na Figura 4(b). As funções de ativação utilizadas foram escolhidas devido à natureza binária das saídas fornecidas à rede durante o treinamento, e foram as que apresentaram resultados mais consistentes. As redes foram treinadas utilizando o algoritmo *backpropagation* de Levenberg-Marquardt e a função de performance minimizada foi a do Erro Quadrático Médio (MSE).




Figura 4 – Funções de ativação utilizadas. (a) Função *tansig*. (b) Função *satlins*.

Na Tabela 4 a seguir é apresentada a arquitetura das 4 redes treinadas e avaliadas.

Tabela 4 – Arquitetura das redes.

Rede	Camada Oculta (Função – No. de neurônios)	Camada de saída (Função)
1	<i>tansig</i> – 20	<i>tansig</i>
2	<i>tansig</i> – 30	<i>tansig</i>
3	<i>tansig</i> – 20	<i>satlins</i>
4	<i>tansig</i> – 30	<i>satlins</i>

Resultados e discussão

Para avaliar o desempenho das redes treinadas, foram utilizados 4 conjuntos de testes de generalização. Cada conjunto de teste T foi colocado separadamente em formato de matrizes similares à apresentada em (1), onde as linhas representam os parâmetros estatísticos por ponto de medição e as colunas representam conjuntos de dados seguindo a configuração apresentada na Tabela 5.

Tabela 5 – Configuração dos testes das redes.

Teste	h_{dano} (mm)	Ruído (%)	Elementos	No. de Colunas
T1	0	0		1
		5		4
		10		4
T2	10	0	23 e 24	1
		0	7, 8 e 9	1
		0	15, 16 e 36	1
		5	23 e 24	3
		5	7, 8 e 9	3
		5	15, 16 e 36	3
		10	23 e 24	3
		10	7, 8 e 9	3
		10	15, 16 e 36	3
T3	5	0	23 e 24	1
		0	7, 8 e 9	1
		0	15, 16 e 36	1
		5	23 e 24	3
		5	7, 8 e 9	3
		5	15, 16 e 36	3
		10	23 e 24	3
		10	7, 8 e 9	3
		10	15, 16 e 36	3
T4	2	0	23 e 24	1
		0	7, 8 e 9	1
		0	15, 16 e 36	1
		5	23 e 24	3
		5	7, 8 e 9	3
		5	15, 16 e 36	3
		10	23 e 24	3
		10	7, 8 e 9	3
		10	15, 16 e 36	3

Os conjuntos foram então submetidos às redes treinadas e as saídas correspondentes foram analisadas. A Tabela 6 apresenta o nível de acerto de cada uma das redes treinadas nos testes descritos acima.

Tabela 6 – Níveis de acerto e MSE das redes nos testes.

Rede	Acertos T1	Acertos T2	Acertos T3	Acertos T4	Acertos Totais
1	9/9 (100%)	21/21 (100%)	21/21 (100%)	16/21 (76,2%)	67/72 (93,1%)
2	7/9 (77,8%)	21/21 (100%)	20/21 (95,2%)	16/21 (76,2%)	64/72 (88,9%)
3	7/9 (77,8%)	21/21 (100%)	21/21 (100%)	14/21 (66,7%)	63/72 (87,5%)
4	7/9 (77,8%)	21/21 (100%)	21/21 (100%)	13/21 (61,9%)	62/72 (86,1%)

A Rede 1, *tansig-tansig* com 20 neurônios na camada oculta, foi a que apresentou o melhor resultado, seguida pela Rede 2, *tansig-tansig* com 30 neurônios na camada oculta. As Redes 3 e 4, com funções *tansig-satlins*, apresentaram um desempenho inferior. Isso mostra que a função *tansig* é mais efetiva na camada de saída. Também é possível observar que as redes com 20 neurônios na camada oculta performaram melhor que as com 30 neurônios. Isso aponta que com 30 neurônios a rede já passa a ser *super treinada*, o que diminui sua capacidade de generalização. É visível também que, em geral, as redes performaram muito bem para os casos de dano de 10 mm e de 5 mm, tanto para dano em um único ponto da estrutura, quanto para danos em múltiplos pontos (elementos 15, 16 e 36), assim como para todos os casos de ruídos apresentados. Porém, tiveram maior dificuldade em interpretar as entradas dos casos de dano de 2 mm e intacto. Entende-se com isso que as redes treinadas não são sensíveis o suficiente para distinguir com muita certeza entre um caso de dano reduzido como o de 2 mm e o caso intacto.

Conclusões

Nesse trabalho foi avaliado o desempenho do uso de indicadores estatísticos extraídos diretamente de históricos de aceleração de uma viga metálica biapoiada modelada numericamente. A viga foi modelada considerando 16 estados diferentes que foram utilizados para extrair os dados necessários para o treinamento de 4 RNAs de arquitetura MLP de uma camada oculta com diferentes números de neurônios e funções de ativação. As redes treinadas foram então testadas e avaliadas.

O bom desempenho dos indicadores estatísticos como parâmetros de detecção de danos foi claramente observado a partir dos resultados obtidos, que mostram boa capacidade de detecção para danos relativamente pequenos. Houve variação de desempenho ao se comparar redes com diferentes funções de ativação na camada de saída e diferentes números de neurônios na camada intermediária, sendo observado que, para a estrutura em estudo, a rede que melhor performou possuía 20 neurônios em sua camada oculta e funções de ativação *tansig-tansig*.

Apesar da consideração de ruídos nos dados utilizados, o presente estudo focou-se em um modelo numérico. Estudos futuros, portanto, são necessários para aliar o treinamento das redes utilizando-se dados obtidos de modelos numéricos e o teste delas utilizando-se dados obtidos de ensaios experimentais. Também se faz necessário um estudo comparativo de desempenho entre o uso dos parâmetros estatísticos e de parâmetros modais na detecção de dano de uma mesma estrutura, além de testar outros formatos de saída para as redes, de maneira a permitir também a localização do dano.

Referências

- ALVES, V.; CURY, A.; ROITMAN, N.; MAGLUTA, C.; CREMONA, C. Novelty detection for SHM using raw acceleration measurements. *Structural Control and Health Monitoring*, Vol. 22, Issue 9, 2015.
- AVCI, O.; ABDELJABER, O. Self-Organizing Maps for Structural Damage Detection: A Novel Unsupervised Vibration-Based Algorithm. *Journal of Performance of Constructed Facilities* 30 (3), 2016.
- AVCI, O.; ABDELJABER, O.; KIRANYAZ, S.; HUSSEIN, M.; GABBOUJ, M.; INMAN, D. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical Systems and Signal Processing* 147 107077, 2021.
- ALLEMANG, R. J.; BROWN, D. L. A correlation coefficient for modal vector analysis. *Proc. 1st Int. Modal Analysis Conference*, p. 110-116, 1982.
- BANDARA, R. P.; CHAN, T. H. T.; THAMBIRATNAM, D. P. Structural damage detection method using frequency response functions. *Structural Health Monitoring* 13(4), p. 418-429, 2014.
- FARRAR, C. R.; WORDEN, K. *Structural Health Monitoring: A Machine Learning Perspective*. John Wiley & Sons, Ltd, 2012.
- FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. *Latin American Journal of Solids and Structures* 16 (02), 2019.
- GILLICH, G.; PRAISACH, Z. Modal identification and damage detection in beam-like structures using the power spectrum and time–frequency analysis. *Signal Processing* 96 (A), p. 29-44, 2014.
- HUTH, O.; FELTRIN, G.; MAECK, J.; KILIC, N.; & MOTAVALLI, M. Damage Identification Using Modal Data: Experiences on a Prestressed Concrete Bridge. *Journal of Structural Engineering* 131 (12), 2005.
- JIN, C.; LI, J.; JANG, S.; SUN, X.; CHRISTENSON, R. Structural damage detection for in-service highway bridge under operational and environmental variability. *Proc. of SPIE Vol. 943*, 2015.
- MARCY, M.; SANTOS, I. C. e; BRITO, J. L. V. de; DOZ, G. N.; BRASILIANO, A. Atualização e identificação de danos baseada em dados experimentais de vigas com condições de apoio livre-livre. *Revista Interdisciplinar De Pesquisa Em Engenharia*, 2(30), p. 82-101, 2017.
- NUNES, L. A.; FINOTTI, R. P.; BARBOSA, F. S.; CURY, A. A. A hybrid learning strategy for structural damage detection. *Structural Health Monitoring* 20(4), p. 2143-2160, 2020.
- RUCKA, M.; WILDE, K. Neuro-Wavelet damage detection technique in beam, plate and shell structures with experimental validation. *Journal of Theoretical and Applied Mechanics* 48, 3, pp. 579-604, 2010.
- PANDEY, A. K.; BISWAS, M.; SAMMAN, M. M. Damage detection from changes in curvature mode shapes. *Journal of Sound and Vibration*, 145, pp. 321-332, 1991.
- SHI, Z. Y.; LAW, S. S. Structural damage localization from modal strain energy change. *Journal of Sound and Vibration* 218(5), pp. 825-844, 1998.
- TENG, S.; CHEN, G.; LIU, G.; LV, J.; CUI, F. Modal Strain Energy-Based Structural Damage Detection Using Convolutional Neural Networks. *Applied Sciences* 9(16):3376, 2019.