

DETECÇÃO DE DANOS ESTRUTURAIS POR MEIO DE REDES NEURAIAS ARTIFICIAIS (SOM E LVQ)

STRUCTURAL DAMAGE DETECTION BY ARTIFICIAL NEURAL NETWORKS (SOM AND LVQ)

Marília Marcy^a e Graciela Doz^b

^aUniversidade Federal de Campina Grande, Campina Grande, 58429-900 Brasil,
mariliamarcy@gmail.com

^bUniversidade de Brasília, 70910-900 Brasília, Brasil, graciela@unb.br

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

Resumo. Durante a vida útil as estruturas sofrem desgastes que podem comprometer seu funcionamento. Além disso, o crescente número de estruturas mais esbeltas, têm impulsionado o estudo e o desenvolvimento de novas técnicas capazes de realizar um monitoramento estrutural, sobretudo as ferramentas baseadas no uso das propriedades dinâmicas das estruturas. Neste sentido, métodos com a capacidade de detectar alterações, localizar e quantificar danos, tornam-se essenciais no acompanhamento funcional das edificações, como é o caso das Redes Neurais Artificiais (RNAs). Estes sistemas inteligentes são técnicas estritamente matemáticas que, ao trabalharem em conjunto com as características dinâmicas, transformam-se em ferramentas capazes de indicar mudanças na integridade estrutural. Neste contexto, RNAs do tipo Self Organizing Maps (SOM) com e sem o algoritmo Learning Vector Quantization (LVQ) foram aplicadas ao estudo de uma viga metálica com o objetivo de detectar e localizar danos estruturais, utilizando para isso, os softwares ANSYS para a modelagem da estrutura e o Matlab para a simulação das RNAs. Deste modo, foram desenvolvidos dois grupos de modelos numéricos da estrutura em estudo com e sem alteração na sua integridade, isto é, com diferentes cenários de dano, de modo que as suas características dinâmicas serviram como padrões de entradas para as redes. Após o processamento, os resultados foram analisados criticamente quanto ao desempenho das redes, permitindo uma boa avaliação da ferramenta com vistas à detecção de danos.

Keyword: Artificial Neural Networks, Dynamic Properties, Damage detection.

Abstract. The structures suffer from wear and tear that can compromise their functioning. Moreover, the increasing number of slender structures, have led to the study and development of new techniques capable of performing a structural monitoring, especially the tools based on the use of the dynamic properties of the structures. In this sense, methods with the ability to detect changes, locate and quantify damages, become essential in the functional monitoring of buildings, as is the case of Artificial Neural Networks (ANN). In this context, the Self Organizing Maps (SOM) ANN with and without the Learning Vector Quantization (LVQ) algorithm were applied to the metal beam with the objective of detecting and locating structural damages. Two groups of numerical models of the structure under study with and without alteration in their integrity were developed for the training and test phases, that is, with different damage scenarios, so that their dynamic characteristics served as input patterns for the networks. After the processing, the results were analyzed critically on the performance of the networks, allowing a good evaluation of the tool for damage detection.

1 INTRODUÇÃO

Atualmente os métodos construtivos vêm passando por grandes mudanças, principalmente, no que diz respeito à utilização de novos materiais, bem como ao uso máximo dos espaços disponíveis, resultando em uma maior exigência por estruturas que possam atingir maior eficiência de serviço, tornando-as mais esbeltas e, portanto, mais susceptíveis às ações dinâmicas. No entanto, tal fenômeno gera uma demanda por novos métodos capazes de acompanhar o desempenho funcional, observar e controlar vibrações excessivas, bem como detectar, previamente, possíveis danos.

Existem vários métodos capazes de compor um sistema de monitoramento estrutural, sobretudo, com uma abordagem das características dinâmicas da estrutura (frequências naturais, modos de vibração, amortecimento). No entanto, alguns apresentam restrições quanto ao tipo de estrutura e/ou podem necessitar de uma estimativa prévia de regiões mais propensas a anomalias. Para superar essas exigências, existem técnicas estritamente matemáticas que, ao serem trabalhadas com informações de caracterizam a situação real das estruturas, podem ser transformadas em ferramentas eficientes para a detecção de danos, como é o caso das metodologias baseadas na Inteligência Artificial (Redes Neurais Artificiais - ANN, Algoritmos Genéticos, entre outros).

Além da vantagem mencionada anteriormente, [Ahmed, 2016](#), [Bandara, 2013](#) mostraram que as RNAs aplicadas em uma abordagem de detecção de danos podem fornecer vantagens como a possibilidade de usar diferentes parâmetros de vibração como dados de entrada, o processamento rápido, baixa sensibilidade em presença de ruídos, etc.

Neste contexto, este trabalho tem como objetivo aplicar e avaliar o desempenho das RNAs do tipo Self Organizing Maps (SOM) em conjunto ou não com o algoritmo Learning Vector Quantization (LVQ) na detecção de danos de uma viga metálica, modelada no software ANSYS Academic ([ANSYS, 2016](#)). Assim, considerando que as frequências naturais de vibração sofrem alterações em função do estado físico da estrutura e que, para um desempenho adequado, a rede passa por duas principais fases de processamento (aprendizado – treinamento e generalização – teste), foram desenvolvidos modelos numéricos e suas 3 primeiras frequências foram utilizadas como dados de entrada para realizar treinamento e o teste.

2 METODOLOGIA

Duas vigas metálicas com condições de contorno livre-livre, com e sem regiões danificadas, desenvolvidas no software ANSYS ([ANSYS, 2016](#)), foram utilizadas como objeto de estudo para avaliar o desempenho de diferentes RNAs. Foram estimadas suas propriedades dinâmicas e, considerando a necessidade de treinar as RNAs para a detecção de danos, foram construídos modelos numéricos da viga intacta (mas submetida a diferentes temperaturas) e contendo diferentes cenários de danos (redução na altura da sua seção transversal).

Com bases nas 3 primeiras frequências de todos os modelos, foram aplicados à rede SOM com e sem a utilização do algoritmo LVQ, de modo que 70% dos 34 cenários foram utilizados para treinamento e o restante para testes das RNAs.

3 REDES NEURAIAS ARTIFICIAIS

As redes neurais artificiais (RNAs) são sistemas paralelos e distribuídos, formados por unidades básicas interligadas, chamadas de neurônios artificiais ([Pádua et. al, 2000](#)), com a capacidade de armazenar informações, reconhecer, classificar padrões e fazer previsões.

Trata-se de uma técnica inserida dentre as várias metodologias existentes para a solução de problemas de Inteligência Artificial, baseada no ajuste de conjuntos de dados (ajuste de pesos),

tornando-a capaz de aprender, por meio de experiências (treinamento), e generalizar comportamentos de um determinado problema.

As RNAs podem se classificar, de maneira geral e simplificada, quanto à forma de aprendizado (supervisionado e não supervisionado), às funções de ativação usadas em seu interior e com relação a arquitetura (número e organização dos neurônios artificiais). Como mencionado, neste trabalho foi utilizado o SOM simples (RNA sem supervisão) e com o algoritmo LVQ (Learning Vector Quantization), uma RNA auto organizável com supervisão.

3.1 Self Organizing Maps (SOM com e sem o algoritmo Learning Vector Quantization (LVQ))

Redes do tipo Self Organizing Maps (SOM) constituem um tipo de RNA treinada por regras de aprendizagem não supervisionadas e competitivas, que buscam associar padrões de acordo com características relevantes de um conjunto de dados de entrada (Haykin, 2001). Inspirada no sistema neural humano, a rede SOM é composta por unidades básicas chamadas neurônios artificiais, dispostos em posições físicas de acordo com uma topologia que pode ser retangular, hexagonal ou aleatória. (Figura 1).

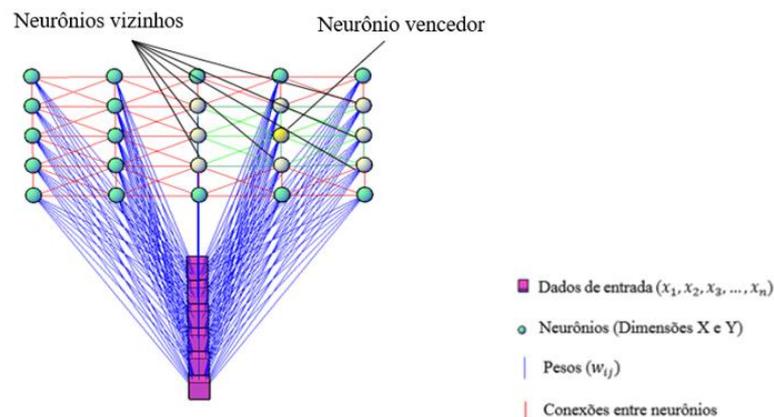


Figura 1. Estrutura da rede SOM ou mapa de Kohonen.

Conforme mencionado, este tipo de sistema inteligente busca agrupar em regiões de um mapa bi ou tridimensional amostras que apresentem semelhanças. Deste modo, o algoritmo de treinamento consiste nos seguintes passos:

Uma amostra (exemplo do problema que está sendo estudado) composta por variáveis predefinidas é fornecida, de modo que seus valores sejam agrupados como um vetor de entrada. Sabendo que cada neurônio artificial é acompanhado de pesos atribuídos aleatoriamente, o vetor entrada é então comparado com os pesos de cada unidade artificial por meio de uma função de distância, neste caso a distância Euclidiana.

O neurônio que apresentar a menor distância do vetor de entrada, é declarado como vencedor (i^*), resultando em uma aproximação dos pesos para sua região no mapa. Em seguida, os pesos do neurônio vencedor (w_{i^*}), bem como de todas as unidades artificiais localizadas em um raio de vizinhança predefinido, são atualizados utilizando a formulação de Kohonen mostrada abaixo.

$$w_{i^*}(n+1) = w_{i^*}(n) + \eta(n)h(n)(x(n) - w_{i^*}(n)) \quad (1)$$

Onde $\eta(n)$ e $h(n)$ representam a taxa de aprendizado, que decresce com o tempo, e a função de vizinhança (gaussiana, por exemplo) em torno do neurônio vencedor i^* , respectivamente.

Cada atualização do raio da vizinhança passa por mudanças, que são divididas em duas fases: ordenação e sintonia (Matlab, 2015). Ordenação: Esta fase leva um determinado número de etapas (iterações), de modo que a vizinhança começa com um maior raio de alcance (número de neurônios vizinhos) e vai diminuindo. Fase de Sintonia: Esta fase dura o resto do treinamento, sendo caracterizada pela redução da vizinhança a valores menores que 1, de modo que apenas o neurônio vencedor aprende o comportamento.

Este procedimento é repetido para cada vetor de entrada e, ao final do treinamento, o SOM adquire a capacidade de relacionar características similares, a fim de gerar classes de dados ou clusters em determinadas regiões do mapa bi ou tridimensional.

A utilização do algoritmo LVQ se dá logo após a finalização do SOM, especificamente, no sentido de melhorar a classificação. Deste modo, a partir de um conjunto de vetores associado a uma determinada classe por meio do SOM, o algoritmo LVQ é utilizado, sendo adotado um procedimento iterativo no qual a posição dos vetores é ajustada para minimizar o número de erros de classificação.

Como se trata de um algoritmo supervisionado, no qual há a intervenção de um agente externo (usuário), durante o treinamento são fornecidos conjuntos de entradas e saídas, de modo que o aprendizado baseia-se na comparação entre a resposta desejada (correta) e a obtida,

Assim, o processo de ajuste de pesos utilizando o LVQ é feito conforme formulação abaixo:

$$w_c = \begin{cases} w_c(n) + \eta(n)(x(n) - w_c(n)), & \text{classe correta} \\ w_c(n) - \eta(n)(x(n) - w_c(n)), & \text{classe incorreta} \end{cases} \quad (2)$$

O algoritmo finaliza com a etapa de teste, na qual são fornecidos dados de entradas ainda desconhecidos pelo sistema, isto é, informações cuja solução deseja-se conhecer.

4 ANÁLISE NUMÉRICA

As vigas modeladas em perfis de aço com seção transversal U (Perfil U 101,6 x 4,67 - ASTM – A36) baseadas nos modelos experimentais de Brasiliano (2005), cujas propriedades encontram-se na Tabela 1 e Figura 3, foram discretizadas em 33 elementos de 0,0653m de comprimento e 34 nós.

Propriedades	Valores
Momento de Inércia (I)	1,03E-07 m ⁴
Módulo de Elasticidade (E)	2,07E+11 N/m ²
Densidade do Aço	7850 Kg/m ³
Comprimento	2,155m

Tabela 1: Propriedades dos materiais.

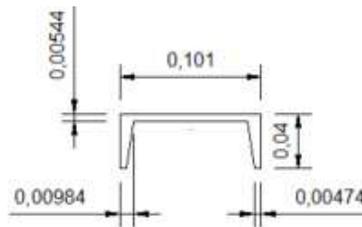


Figura 2: Seção transversal das vigas.

A primeira viga (intacta), chamada de Viga 1, apresentava todos os elementos com a mesma área e inércia, igual a $10,533 \times 10^{-4} \text{ m}^2$ e $13,026 \times 10^{-8} \text{ m}^4$, respectivamente. Já a Viga 2 apresentava um corte de 10 mm na seção transversal dos elementos 18 e 19 (Figura 3), representando uma redução de 50,8% e 10,4% na inércia e na área da seção transversal, respectivamente.

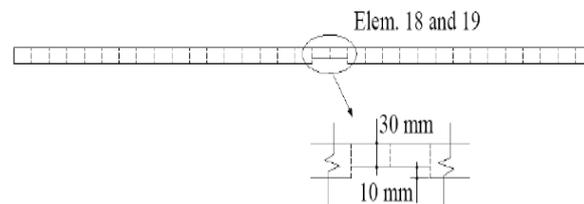
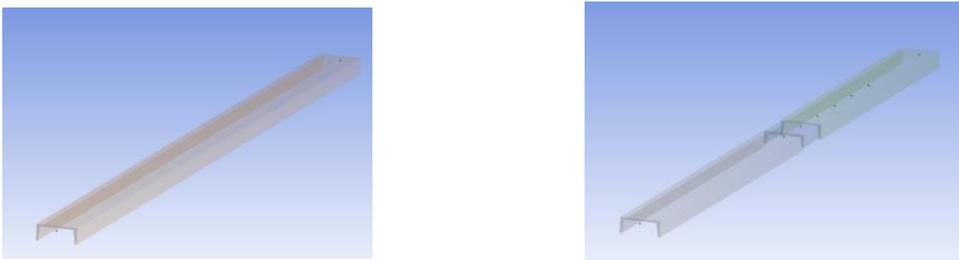


Figura 3. Esquema da Viga 2. (Brasiliano, 2005).

Foram desenvolvidos 22 modelos numéricos, sendo os dois primeiros os já descritos (V1 e V2 – Figura 4) e 20 modelos derivados destes (V3 a V22) com diferentes cenários de dano, além de 12 condições de variação de temperatura para a viga intacta, que tiveram como objetivo o treinamento das RNAs. Para o desenvolvimento dos modelos foi utilizada a versão acadêmica do *software* comercial de elementos finitos ANSYS – STUDENT (ANSYS, 2016).

As frequências e os modos de vibração dos modelos V1 e V2 estão apresentados na Tabela 2 e na Figura 5, respectivamente.

Figura 4. Modelos numéricos V1 e V2. (Marcy *et. al.*, 2016).

	Frequências (Hz)	
	V1	V2
1 ^a	43,7320	40,5100
2 ^a	120,3100	119,3500
3 ^a	235,2000	226,6400

Tabela 2: Frequências dos modelos V1 e V2.

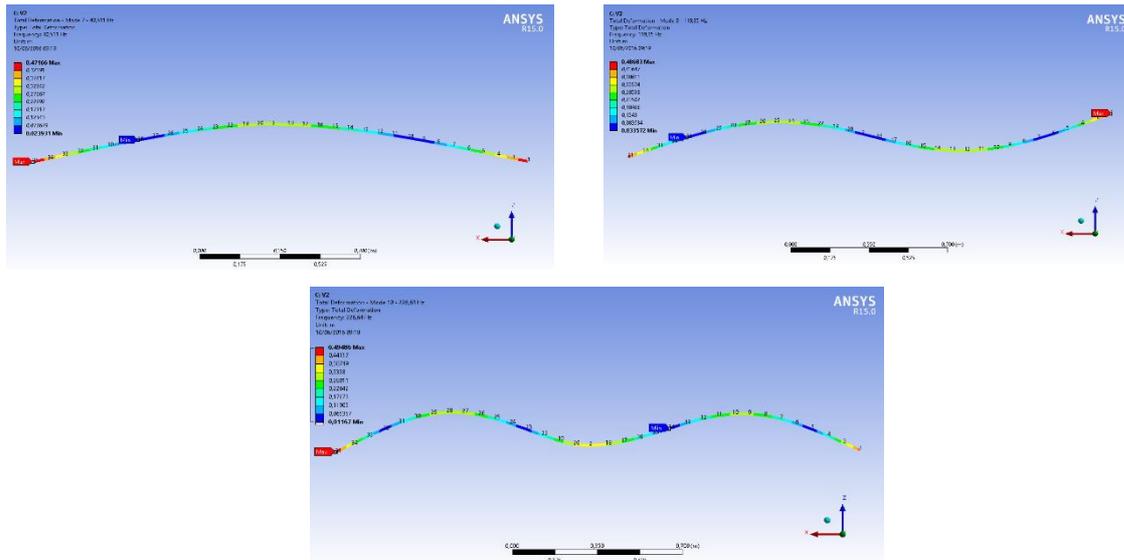


Figura 5. Três primeiros modos de vibração dos modelos V1 e V2.

Viga	Posição e extensão dos danos (altura do corte)	Viga	Posição e extensão dos danos (altura do corte)
V3	Posição: Elemento 18 e 19, Altura: 2cm	V13	Posição: Elemento 28 a 34, Altura: 2cm
V4	Posição: Elemento 18 e 19, Altura: 1cm	V14	Posição: Elemento 26 e 27, Altura: 2cm
V5	Posição: Elemento 18 a 21, Altura: 1cm	V15	Posição: Elemento 26 e 27, Altura: 3cm
V6	Posição: Elemento 18 a 21, Altura: 2cm	V16	Posição: Elemento 24 e 25, Altura: 2cm
V7	Posição: Elemento 18 a 21, Altura: 3cm	V17	Posição: Elemento 22 e 23, Altura: 2cm
V8	Posição: Elemento 20 e 21, Altura: 1cm	V18	Posição: Elemento 20 e 21, Altura: 2cm
V9	Posição: Elemento 22 e 23, Altura: 1cm	V19	Posição: Elemento 20 e 21, Altura: 3cm
V10	Posição: Elemento 24 e 25, Altura: 1cm	V20	Posição: Elemento 22 e 23, Altura: 3cm
V11	Posição: Elemento 26 e 27, Altura: 1cm	V21	Posição: Elemento 24 e 25, Altura: 3cm
V12	Posição: Elemento 28 a 34, Altura: 1cm	V22	Posição: Elemento 24 e 25, Altura: 0,5cm

Tabela 3: Vigas com diferentes cenários danificados.

Para a simulação dos modelos sem danos submetidos a vários cenários de temperatura, foram utilizados os valores da variação do Módulo de Elasticidade em função da temperatura, conforme proposto por Callister e Rethwish (2009), implementado nas propriedades do material, no software ANSYS. Foi desenvolvido um modelo de viga intacta, no qual foram testadas 12 condições de variação de temperatura, entre -10 a 40°C.

Assim, os cenários de cada fase da RNA e suas respectivas classes “danificada (D)” e “intacta (I)” estão apresentadas na Figura 6, sendo 28 exemplos utilizados na fase de aprendizado da RNA (treinamento) e 6 na fase de generalização (teste).

	CENÁRIOS DO TREINAMENTO																																CENÁRIOS DO TESTE			
	V 1	V 2	V 3	V 4	V 5	V 6	V 7	V 8	V 9	V 10	V 11	V 12	V 13	V 14	V 15	V 16	V 17	V 18	V 19	V 24	V 25	V 26	V 27	V 28	V 29	V 30	V 31	V 32	V 20	V 21	V 22	V 23	V 33	V 34		
CLASSE	I	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	I	I	I	I	I	I	I	I	I	I	D	D	D	D	I	I	

Figura 6. Cenários utilizados nas fases de treinamento e teste da RNA.

5 RESULTADOS

A detecção de danos utilizando a rede SOM com e sem o algoritmo LVQ, foi realizada no ambiente do Matlab (Matlab, 2015), especificamente, usando o *Neural Network Toolbox*, um pacote destinado ao uso das RNAs.

O Neural Network Toolbox™ é um pacote computacional inserido no ambiente do Matlab que fornece ferramentas para execução, visualização e simulação de Redes Neurais Artificiais em diferentes configurações, sejam elas no modo de aprendizado, no algoritmo utilizado para o seu treinamento, na maneira de processar dos dados, bem como nas funções de ativação utilizadas.

O processamento tem início com a indicação dos dados necessários em cada etapa (padrões de entrada), isto é, no treinamento e teste da rede. Como dados de entrada foram utilizadas as três primeiras frequências obtidas de cada um dos modelos descritos na Tabela 3, bem como dos modelos submetidos à variação de temperatura.

Neste trabalho, buscou-se detectar alterações nas frequências que pudessem indicar a presença de danos. Assim, diferentemente de outros trabalhos, para o processamento de ambas as redes (SOM com e sem o LVQ), ao final do processamento, deve-se ter a informação se a amostra pertence a uma classe de frequências “danificada” ou “intacta”.

5.1 SOM sem LVQ

Devido a sua natureza de aprendizado não supervisionado, o processamento do algoritmo SOM sem o LVQ não inclui a apresentação de outputs durante o treinamento. Deste modo, esta RNA agrupa as amostras conforme a semelhança entre suas características.

A rede foi construída segundo os seguintes critérios, originando a arquitetura apresentada na

Figura 7:

- Topologia: Hexagonal;
- Função de vizinhança: “linkdist”;
- Mapa bidimensional com 9 neurônios.
- Variáveis: 3 (frequências).

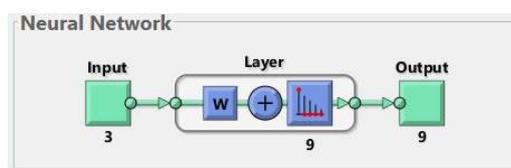


Figura 7. Arquitectura da rede SOM.

Após 50 iterações durante o treinamento, fase na qual as amostras são agrupadas nas classes “danificada” e “intacta”, observou-se que, baseado nos exemplos apresentados na fase de treinamento, os neurônios ativado para o conjunto de frequências de cada classe estão na Figura 8 ou, esquematicamente, no mapa bidimensional da Figura 9:

	CENÁRIOS DO TREINAMENTO																																
	V 1	V 2	V 3	V 4	V 5	V 6	V 7	V 8	V 9	V 10	V 11	V 12	V 13	V 14	V 15	V 16	V 17	V 18	V 19	V 23	V 24	V 25	V 26	V 27	V 28	V 29	V 30	V 31	V 32				
CLASSE	I	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	D	I	I	I	I	I	I	I	I	I	I	I	I	I	I
NEURÔNIO ATIVADO	7	8	9	6	8	9	3	7	7	4	4	8	5	2	3	2	1	1	2	7	7	7	7	7	7	7	7	7	7	7	7	7	

Figura 8. Resultados do treinamento.

No mapa bidimensional (Figura 9) nota-se uma região em amarelo, indicando a localização das amostras consideradas intactas, bem como as unidades em cinza que fazem referência à

localização das amostras consideradas danificadas, todas em correspondência com a **Figura 8**. Além disso, há uma numeração entre parênteses que representa o número de amostras (que se localizou naquela região, em outras palavras, que ativou o respectivo neurônio.

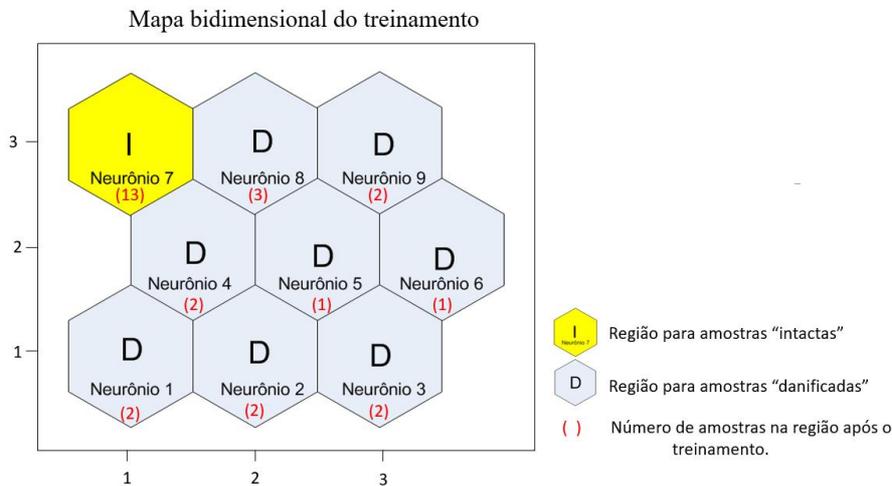


Figura 9. Mapa bidimensional com a localização dos neurônios após o treinamento.

Observa-se que a região reservada para as frequências referentes aos modelos intactos está localizada, predominantemente, no neurônio 7, com exceção das amostras dos cenários 7 e 8 (Verificação na **Figura 8**). Esquemáticamente no mapa bidimensional é possível observar tal localização, cujo número (13) representa o número de amostras que se localizaram no neurônio 7 (**Figura 9**).

Uma vez que a RNA foi treinada, isto é, definidas as regiões para cada tipo de classe (danificada e intacta), foram fornecidas as frequências dos modelos dos cenários de testes, de modo que o processamento da rede forneceu o resultado abaixo (**Figura 10**).

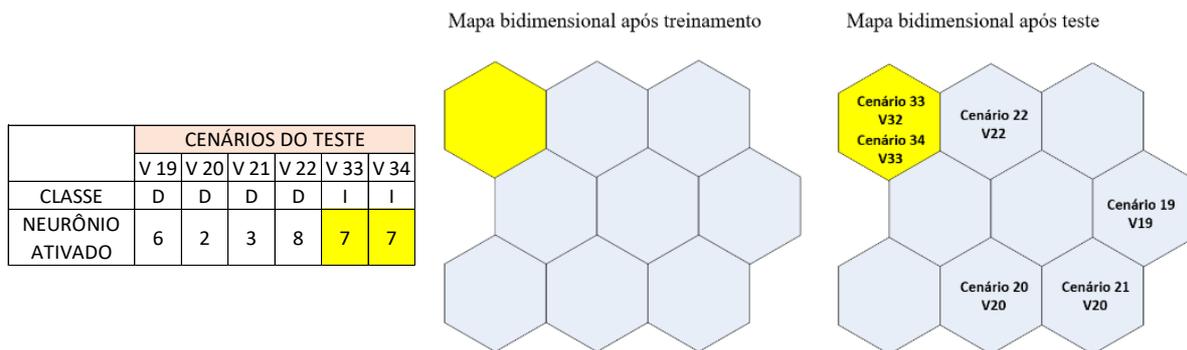


Figura 10. Resultados do teste.

Nota-se que houve um espalhamento dos neurônios ativados pelas amostras dos modelos danificados, isto é, os neurônios 2, 3, 6 e 8, todos condizentes à região para amostras danificadas obtidos no treinamento. Além disso, observa-se uma perfeita classificação dos modelos intactos, uma vez que todos se localizaram no neurônio 7, indicando, portanto, um bom desempenho do sistema inteligente.

Importante ressaltar que foi feito o retreinamento, ao menos, 3 vezes para verificar a convergência dos resultados. Além disso, foi feito um estudo prévio para obter o número de neurônios apropriado para o mapa bidimensional utilizado.

existentes com erros relativamente baixos considerando que os modelos numéricos não levam em conta efeitos como o ruído presente nos estudos que envolvem análise experimentais.

No que diz respeito às diferenças entre os sistemas inteligentes, pode-se indicar que, devido à supervisão do LVQ, o usuário deste tipo de sistema tem um maior controle do processamento da rede, uma vez que existem saídas desejadas e que, portanto, podem ser comparadas com as obtidas pela rede.

Além disso, percebe-se um grande potencial das RNAs em conjunto com as características dinâmicas das estruturas, sendo, portanto, um campo a ser explorado no contexto do monitoramento estrutural, conforme observado por Lee et. al., (2005), Mehjroo et. al., (2008), Meruane e Mahu (2014), entre outros.

Deste modo, conclui-se que as Redes Neurais Artificiais apresentaram uma boa sensibilidade ao caso estudado, sendo possível sugerir-las como uma possível ferramenta no monitoramento da saúde estrutural de edificações de pequeno porte. No entanto, ressalta-se a necessidade e a importância de se fazer novos estudos com as ferramentas descritas, sobretudo, no que diz respeito a modelos experimentais.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ahmed, M. S. Damage detection in reinforced concrete square slabs using modal analysis and artificial neural network. Nottingham, Reino Unido: *Thesis of Doctor of Philosophy from Nottingham Trent University*, 2016.
- ANSYS® Academic Research Mechanical, Release 16.1, Help System, Coupled Field Analysis Guide, ANSYS, Inc.
- Bandara, R. P. (2013). Damage Identification and condition assessment of building structures using frequency response functions and neural networks. Austrália: *Thesis of the Degree of Doctor of Philosophy, School Of Civil Engineering And Built Environment, Queensland University Of Technology*, 2013.
- Brasiliano, A. Identificação de sistemas e atualização de modelos numéricos com vistas à avaliação. *Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia*, 2005.
- Callister, W. D.; Rethwisch, D. G. Materials Science and Engineering: An Introduction (8 ed.). Wiley. doi:9780470941669, 2009.
- Haykin, S. Redes Neurais - Princípios e Prática. (T. P. Engel, Ed.) Porto Alegre: Bookman - 2ª edição, 2001.
- Lee, J. J., Lee, J. W., Yi, J. H., Yun, C. B., & Jung, H. Y. Neural networks-based damage detection for bridges considering errors in baseline finite element models. *Journal of Sound and Vibration*, pp. 555 – 578, 2005.
- Matlab Matrix Laboratory - R2015b. MathWorks - MATLAB and Simulink for Technical Computing. Massachusetts, U.S.A, 2015.
- Marcy, M.; Santos, I.; Brasiliano, A.; Brito, J. L.; Doz, G. Atualização e identificação de danos baseada em dados experimentais de vigas com condições de Apoio Livre-Livre. *Revista Interdisciplinar de Pesquisa em Engenharia*, 2016.
- Mehjroo, M., Khaji, N., Moharrami, H., Bahreininejad, A. Damage detection of truss bridge joints using artificial neural networks. *Expert Systems with Applications* 35, pp. 1122–1131, 2008.
- Meruane, V., & Mahu, J. Real-Time Structural Damage Assessment Using Artificial Neural Networks and Antiresonant Frequencies. *Shock and Vibration*, 2014.
- Pádua, B. A., Ludemir, T. B., Ponce De Leon, A. F. C. Redes Neurais Artificiais Teoria e Aplicações, LTC, Rio de Janeiro. 2000.