

## IDENTIFICAÇÃO DE DANOS EM ESTRUTURAS SANDUÍCHES COM A UTILIZAÇÃO DE REDES NEURAIIS CONVOLUCIONAIS

Ian D. Viotti<sup>1</sup> (IC), Ronny F. R. Junior (PG)<sup>1</sup>, Guilherme F. Gomes (PQ)<sup>1</sup>

<sup>1</sup>Universidade Federal de Itajubá

**Palavras-chave:** Materiais compósitos. aprendizado de máquina. visão computacional

### Introdução

A engenharia estrutural é cada vez mais solicitada para desenvolver estruturas mais leves, resistentes, seguras e de maior vida útil. Para que isso seja possível, técnicas de análise e manutenção devem ser aplicadas para garantir o seu bom estado durante a operação.

A diversidade de materiais, como as avançadas ligas leves e compósitos, demanda expertise especializada para garantir que as práticas de manutenção sejam adaptadas a cada material, aumentando a complexidade e os custos associados. Nesse sentido, a manutenção preventiva e preditiva ganha destaque como abordagens cruciais para manter as estruturas em condições ideais de operação. Nesse cenário nasce o campo de estudo de monitoramento da integridade estrutural ou *Structural health Monitoring (SHM)*.

O SHM em estruturas desempenha um papel crítico na manutenção e segurança desses componentes complexos (Gopalakrishnan et al. 2011). Com o uso crescente de materiais avançados, como compósitos de fibra de carbono e ligas leves, tornou-se imperativo desenvolver métodos sofisticados para identificar danos ocultos e potencialmente prejudiciais para a segurança.

Métodos de detecção de danos com base na vibração têm se mostrado eficazes na avaliação da integridade estrutural de estruturas. Esses métodos exploram as mudanças nas características dinâmicas da estrutura, como frequências naturais e formas dos modos de vibração, para identificar possíveis danos (Doebeling et al., 1998).

Isso é possível pois a presença de um dano altera a rigidez local da estrutural e, visto que o comportamento modal é dependente da rigidez, consequentemente alterando sutilmente os valores de frequências naturais ou as formas do modo de vibração (Maia et al., 2003).

No âmbito do SHM, o uso de estratégias de identificação de padrões, incluindo técnicas empregadas na ciência de dados, tem se mostrado altamente promissor.

Dentro do campo de SHM, o emprego de técnicas avançadas de *machine learning* e *deep learning* tem emergido como um recurso poderoso para identificação de padrões e detecção de falhas. Essas abordagens exploram a capacidade desses algoritmos em aprender padrões complexos a partir de grandes volumes de dados, permitindo a detecção, identificação e localização precoce de danos de maneira mais eficiente e precisa (Gomes et al, 2018).

O uso de *deep learning*, uma subárea do *machine learning*, tem permitido avanços notáveis na detecção de danos. Redes neurais profundas, como as redes neurais artificiais e Redes Neurais Convolucionais (RNC), podem ser treinadas em dados de vibração.

As RNCs, têm se destacado como uma ferramenta poderosa no SHM, especialmente quando se trata de analisar imagens dos modos de vibração da estrutura. As RNCs são uma categoria de algoritmos de *deep learning* projetados para processar dados de imagem de maneira eficiente, focando nas regiões de maior importância na imagem.

No contexto da detecção de danos, as RNCs são treinadas em conjuntos de dados que consistem em imagens dos modos de vibração da estrutura, capturados por meio de sensores ou sistemas de monitoramento. A arquitetura das RNCs é projetada para identificar padrões visuais complexos, permitindo que elas aprendam automaticamente características relevantes das imagens e consigam classificar o tipo de dano, localiza-lo e dimensiona-lo.

### Metodologia

A estrutura foi modelada pelo Método os Elementos Finitos (MEF) através do *Ansys Parametric Design Language* (APDL) devido à sua facilidade de parametrização da estrutura e do dano e automatização das rodadas de análise.

Para isso, foram criados 3 modelos para simular o comportamento da estrutura sob diferentes condições de dano. Um modelo de base (sem dano), um com dano no núcleo e um com dano na placa ou na interface.

A estrutura é uma placa sanduíche quadrada de 20x20 cm, as placas são compostas por 4 camadas de 0,33 mm, orientadas perpendicularmente ao engaste, com lâminas de malha do tipo *cross-ply* de polímero reforçado com fibra de vidro e o núcleo de espuma estrutural tem uma espessura de 1.25 cm.

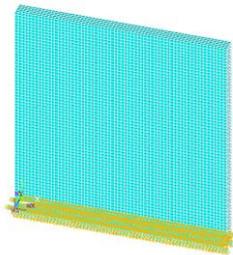


Figura 1 – Modelo numérico da placa.

O modelo numérico em elementos finitos que representa a estrutura com dano na placa e interface é semelhante ao da Figura 1, porém com um a inserção de um dano elíptico em uma das 4 camadas. O dano é modelado como uma redução local de rigidez, realizada com uma constante multiplicativa de 1%, alterando as propriedades elásticas ( $E_1$ ,  $E_2$  e  $G_{12}$ ) do laminado dentro da área da elipse (Figura 2).

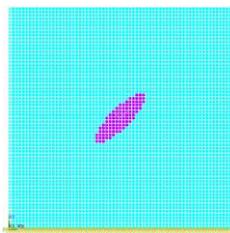


Figura 2 – Modelo numérico da placa com dano na lâmina.

O dano na placa foi modelado com um formato elíptico composto por 5 variáveis de decisão ( $\vec{X}_p$ ), assim como mostrado na Figura 3.

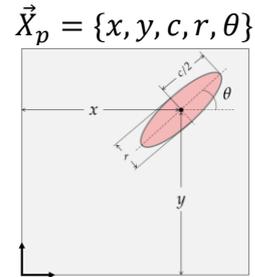


Figura 3 – Representação dos parâmetros do dano na placa.

O modelo numérico com dano no núcleo foi modelado a partir do de base, porém com um vazio em formato de elipsoide no interior do núcleo (Figura 4).

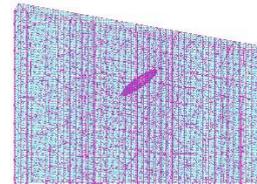


Figura 4 – Modelo MEF da placa com dano no núcleo.

O dano no núcleo foi modelado com um formato de elipsoide composta por 7 variáveis de decisão, formando o vetor de projeto  $\vec{X}_n$ .

$$\vec{X}_n = \{x, y, z, c, r, \theta_y, \theta_z\}$$

A base de dados gerada com pelo MEF foi usada para criar imagens representando o deslocamento modal das placas e essas imagens para o treinamento de RNC com o objetivo de classificar o tipo de dano (core, lâmina e interface) e identificar o dano (localização de dimensão). Dessa maneira, foram criados alguns tipos de RNC a fim de avaliar o desempenho de diferentes arquiteturas, sendo que a melhor opção foi levada a diante para realizar as tarefas de classificação e regressão. O fluxo de trabalho usado pode ser visualizado na Figura 5.

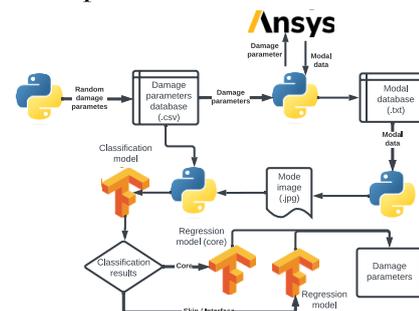


Figura 5 – Fluxo de trabalho para a detecção de

dano.

Nesse sentido, a princípio foi usado o modelo de RNC desenvolvido para esse trabalho, o *Gradient Sum* (GS). A arquitetura dele pode ser observada na Figura 6.

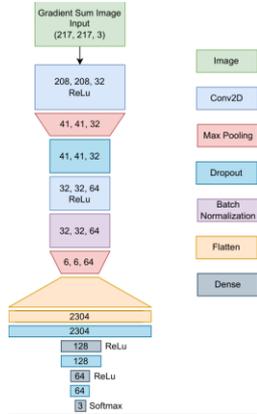


Figura 6 – Arquitetura GS da RNC.

Como exemplo, a Figura 7 mostra como é gerada a imagem de entrada do modelo GS, considerando 5 modos.

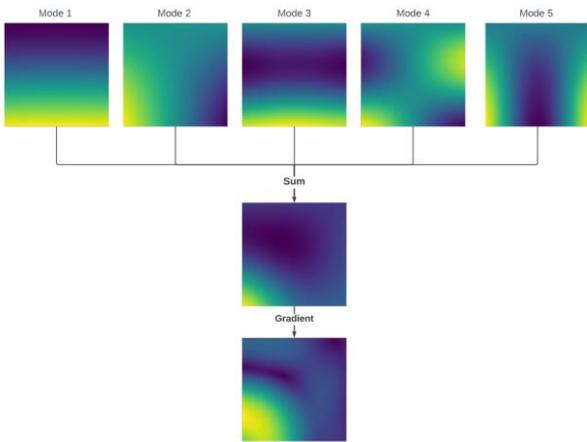


Figura 7 – Imagem de entrada da GS.

### Resultados e discussão

Todos os modelos foram avaliados com a sua performance na base de dados de teste, ou seja, aquela separada para avaliação e que não foi usada durante o treinamento, dessa maneira, possibilitando avaliar seu desempenho sem a ajuda do sobre-ajuste nos dados de treinamento.

Na avaliação do modelo de classificação (identificação entre as classes núcleo, lâmina e interface), avaliou-se a precisão, *recall* e *f1* da classificação, assim como sua matriz de confusão. A Figura 8 apresenta os resultados para os níveis de

ruído avaliados.

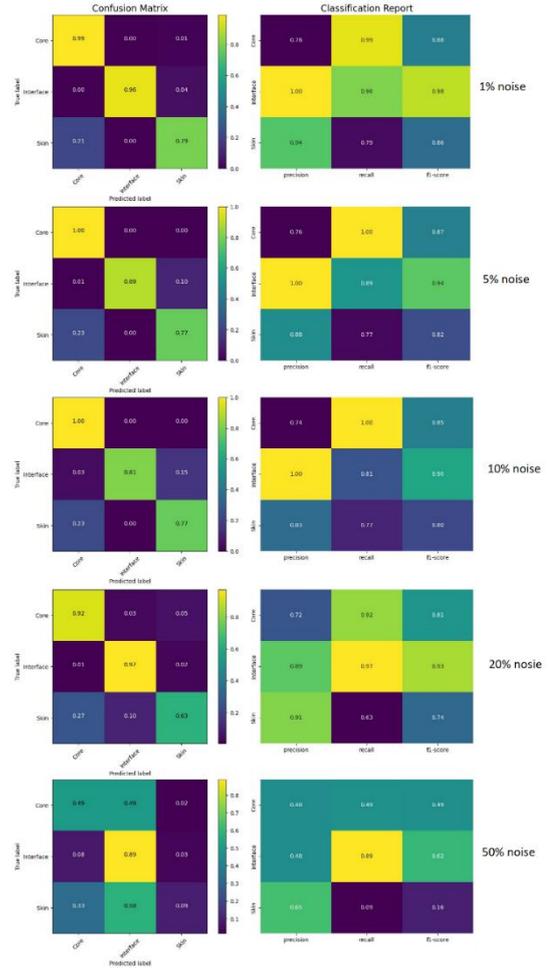


Figura 8 – Métricas da classificação.

Avaliando os resultados, pode-se observar piores métricas com maiores níveis de ruído, como esperado. Além disso, um padrão recorrente é a boa identificação de dano no núcleo e na interface, enquanto isso o dano na lâmina teve piores métricas.

Para determinar os parâmetros de localização ( $x, y, z, \theta_y, \theta_z$ ) e da dimensão ( $c, r$ ) do dano, foi usado um modelo CNN de regressão no qual a camada de saída é do tipo *Dense* com 7 (dano no núcleo) ou 5 (interface e lâmina) neurônios e com a função de ativação linear.

Para essa tarefa foi testada o modelo GS mas não se obteve bons resultados. Foi determinado então que seria usado somente a imagem de um dos modos como entrada na rede. No caso, o modo que mais é sensível ao dano é o modo 6, por isso foi usado.

A Figura 9 mostra as *feature maps* da primeira camada de convolução do modelo de regressão do dano no núcleo, ilustrando como a rede usa os filtros

para identificar mais facilmente os parâmetros do dano.



Figura 9 – Feature Maps da primeira camada de convolução.

A Figura 10 mostra os gráficos de erro residual e a correlação de previsão de cada parâmetro do modelo do núcleo.

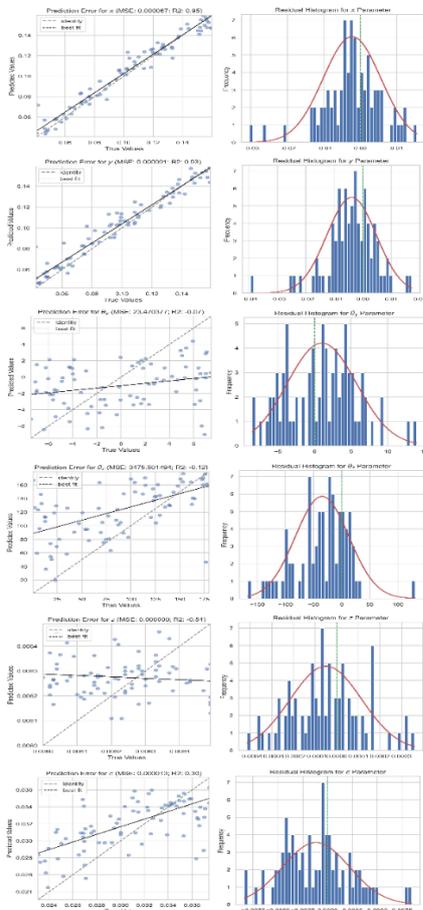


Figura 10 – Correlação de previsão e erros residuais de cada parâmetro do dano no núcleo.

A mesma análise foi feita para o dano na interface e lâmina com resultados semelhantes.

### Conclusões

As técnicas de SHM usadas para a classificação e localização do dano se mostraram eficientes. As RNC se apresentaram como uma solução computacionalmente eficiente mas mais complexa de se trabalhar que os algoritmos de aprendizado de máquina convencionais.

A tarefa de classificação realizada foi capaz de prever o tipo de dano com uma alta acurácia enquanto a regressão foi capaz de localizar o dano com boa correlação, entretanto o dimensionamento do dano não foi preciso e a regressão da inclinação do dano não foi satisfatória.

### Agradecimentos

Obrigado à Universidade Federal de Itajubá por fornecer uma excelente infraestrutura e ambiente para o desenvolvimento da pesquisa.

Obrigado ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

### Referências

- Gopalakrishnan S., Ruzzene M., Hanagud S. **Computational techniques for damage detection, classification and quantification.** In: Computational techniques for structural health monitoring. Springer, pp 407–461, 2011.
- Doebling, S., W., Farrar C., R., Prime, M., B. et al. **A summary review of vibration-based damage identification methods.** Shock Vib Dig 30(2):91–105, 1998.
- Maia N., Silva J., Almas E., Sampaio R. **Damage detection in structures: from mode shape to frequency response function methods.** Mech Syst Signal Process 17(3):489–498, 2003.
- Gomes, G., F. et al. **A Review of Vibration Based Inverse Methods for Damage Detection and Identification in Mechanical Structures Using Optimization Algorithms and ANN.** Arquivos de Computational Methods in Engineering, Springer, v. 26, n. 4, p. 883–897, 2019.