

IDENTIFICAÇÃO DE DANOS EM ESTRUTURAS SANDUÍCHES COM A UTILIZAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA

Ian D. Viotti¹ (IC), Guilherme F. Gomes (PQ)¹

¹Universidade Federal de Itajubá.

Palavras-chave: Estruturas sanduíches. monitoramento de integridade estrutural. aprendizado de máquina. redes neurais artificiais.

Introdução

O aprimoramento de métodos de segurança e manutenção em estruturas é um dos desafios mais discutidos na comunidade científica no momento. Há um grande investimento no desenvolvimento de técnicas automatizadas que detectam algum tipo de falha na estrutura, dentre elas, se destaca o monitoramento de integridade estrutural (SHM).

Nem sempre o uso de técnicas convencionais de monitoramento de dano é efetivo, visto que, especialmente em estruturas compostas, o dano não é visivelmente identificável.

Um dos parâmetros mais usados em metodologias SHM são aqueles baseados em vibrações, visto que são altamente sensíveis à mudança de rigidez da estrutura, especialmente o formato dos modos de vibração. Dessa maneira, tendo um modelo de referência, é possível conhecer os parâmetros da estrutura íntegra e, como a presença de danos altera sua rigidez, pode-se realizar o método inverso para identificar, localizar e/ou dimensionar o dano (GOMES et al., 2019).

A variação dos parâmetros modais devido à presença de dano não é facilmente identificada, necessitando de métodos computacionais poderosos para realizar o trabalho. Diante disto, algoritmos de aprendizado de máquina (AM) são ferramentas capazes de ajudar na identificação de padrões.

Neste trabalho, um estudo inovador sobre o uso de diferentes técnicas de AM em detecção e identificação de delaminação em painéis sanduíche é realizado. O dano é parametrizado segundo um elipsóide bi e tridimensional. Estudos de classificação da localização (em 3 diferentes grupos) e da identificação (tamanho) do dano são realizados por meio de técnicas de agrupamento e regressão por meio de Redes Neurais Artificiais (RNA).

Metodologia

A estrutura foi modelada pelo método dos elementos finitos com o *Ansys Parametric Design Language* (APDL) devido à sua facilidade de parametrização da estrutura e do dano.

Foram criados 3 modelos para simular os danos. Um modelo de base sem danos, um com dano no núcleo e um com dano na placa ou na interface.

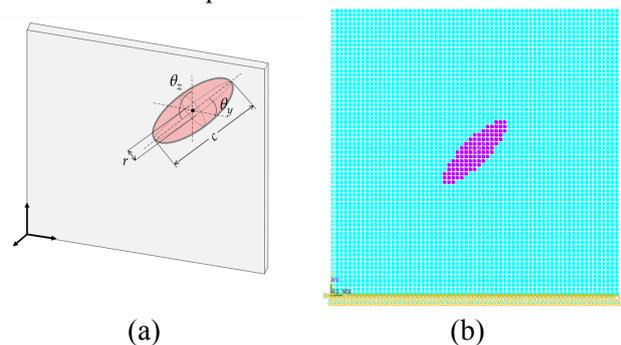


Figura 1 – Parametrização do dano (a) e modelo numérico em Elementos Finitos com dano na placa (b).

O dano na placa foi modelado com cinco parâmetros: posição em x , posição em y , comprimento, largura e inclinação no plano da placa, conforme o seguinte vetor \vec{X} .

$$\vec{X} = \{x, y, c, r, \theta\}$$

Já o dano no núcleo foi modelado com os 5 parâmetros do dano na placa, mais a posição em z e inclinação no plano da espessura, conforme o seguinte vetor \vec{Y} .

$$\vec{Y} = \{x, y, z, c, r, \theta_x, \theta_z\}$$

A fim de validar os resultados obtidos pelo Modelo em Elementos Finitos (MEF), as placas foram fabricadas e ensaiadas. A laminação dos Corpos De Prova (CDP) foi realizada pelo método *hand lay-up* com a inserção do dano elíptico em uma das 4 camadas do laminado, assim como mostrado na Figura 2.



Figura 2 – Manufatura dos corpos de prova.

Os corpos de prova fabricados foram ensaiados a fim de se obter os parâmetros modais da estrutura. Para isso, realizou-se o ensaio de vibração livre com a placa engastada-livre em uma mesa inercial e um vibrômetro laser para realizar a leitura da velocidade em 30 pontos da estrutura, como mostrado na Figura 3. A partir do ensaio modal, obteve-se a matriz de Função de Resposta em Frequência (FRF).



Figura 3 – Bancada de ensaio dos CDP

A fim de garantir a concordância dos MEFs com os experimentais, utilizou-se do método inverso para a obtenção dos parâmetros elásticos dos materiais da estrutura. Para isso, o algoritmo de otimização com enxame de partículas foi selecionado para minimizar o erro quadrático médio das 4 primeiras frequências naturais dos modelos.

Para a análise dos dados e modelagem dos algoritmos de AM, utilizou-se de ferramentas robustas de código aberto em *Python*. As seguintes bibliotecas foram utilizadas: *Pandas*, *Seaborn*, *PyCaret*, *Scikit-learn* e *Yellowbricks*.

A classificação do dano foi realizada com a utilização de modelos de AM para classificação multi-classe com treinamento supervisionado. Os dados de entrada foram as 5 primeiras frequências naturais e a resposta esperada foi a classificação entre as 3 classes:

dano no núcleo, dano na placa ou danos na interface.

Avaliou-se diversos modelos de AM que foram ranqueados com base nas seguintes métricas de avaliação: acurácia, AUC, revocação, F1, Kappa, MCC e TT.

Já a localização e o dimensionamento do dano foram realizados por meio de uma RNA do tipo perceptron de multicamadas para regressão com treinamento supervisionado, no qual os dados de entrada são as 5 primeiras frequências naturais e seus modos de vibração em 4 posição (sensores) e os dados de saída são os parâmetros do dano.

As RNAs tiveram seus hiper-parâmetros otimizados buscando melhorar as métricas MAE, MSE, R^2 e MAPE. Além disso realizou-se os testes Kolmogorov-Smirnov para se obter o parâmetro KS e *p-value* e verificar a normalidade da distribuição dos resultados residuais a partir da hipótese nula.

Resultados e discussão

No ensaio modal, foram avaliados a variação da velocidade e da FRF (magnitude e parte imaginária) em cada um dos 30 pontos em cada placa. Na Figura 4 foi comparado os resultados do ponto 1×1 (visto que ele é excitado pelos 4 primeiros modos) de cada dano com a placa sem danos.

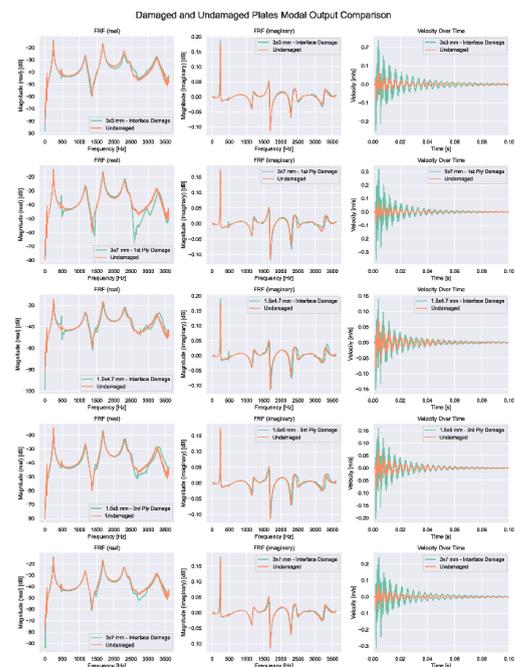


Figura 4 – Comparação dos resultados modais para cada modelo de dano.

É complexo analisar o sinal a olho nu simplesmente, e em função disso lança-se mão de

técnicas robustas de AM de modo a reconhecer padrões ocultos no sinal. Neste ponto justifica-se novamente a importância de técnicas de AM e de processamento de sinais em SHM.

Plotou-se os modos de vibrações obtidos pelo ensaio a fim de verificar sua concordância com o MEF, conforme a Figura 5.

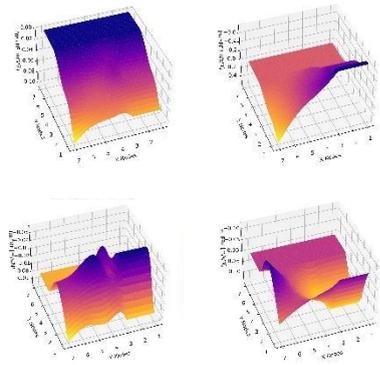


Figura 5 – 4 primeiros modos de obtidos por ensaio

Enquanto isso, verificou-se a deformação do MEF para os quatro modos, conforme mostrado na Figura 6.

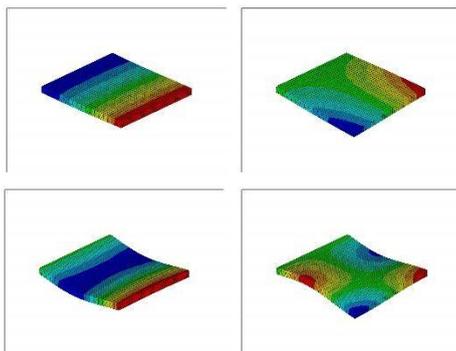


Figura 6 – 4 primeiros modos obtidos pelo MEF

Além da verificação quantitativa pela geometria dos modos, verificou-se sua concordância através da matriz *modal assurance criterion* (MAC), conforme mostrado na Figura 7.

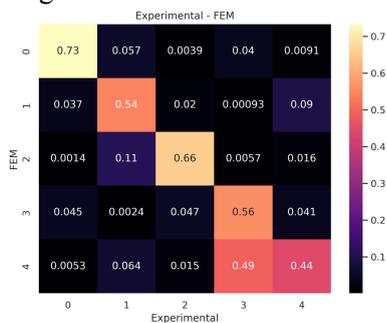


Figura 7 - MAC

Avaliando a matriz MAC, garante-se que os

modelos são concordantes para os 5 primeiros modos de vibração.

A partir da base de dados gerada com MEFs, avaliou-se graficamente a disposição dos modelos em função das frequências naturais. O resultado pode ser observado na Figura 8.

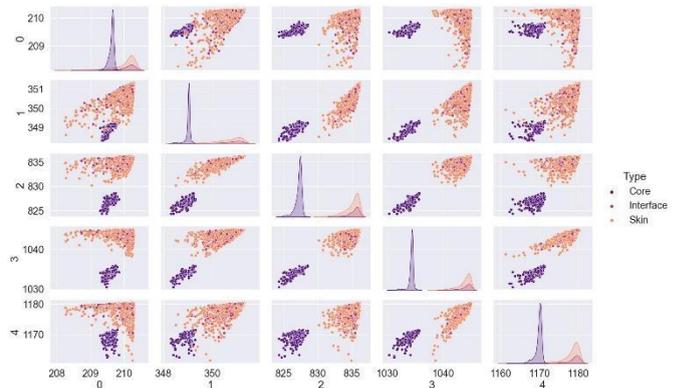


Figura 8 – Variação da frequência natural para cada tipo de dano

É possível visualizar que o dano no núcleo é claramente isolado em um grupo enquanto os danos na placa e interface estão isolados em outro, entretanto observa-se que não há distinção óbvia entre o dano na placa e na interface. Espera-se, portanto, que o modelo de classificação tenha alta precisão de classificar o dano no núcleo, mas não consiga distinguir o dano na interface e na placa.

A matriz relatório apresenta um sumário dos resultados da classificação e pode ser observada na Figura 9.

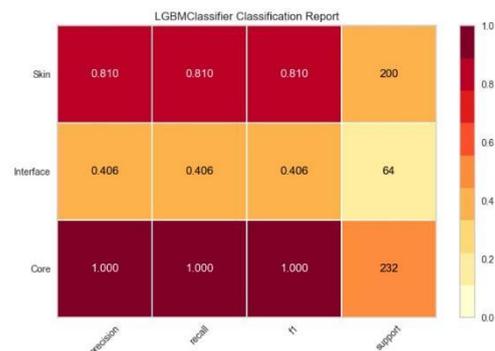


Figura 9 – Matriz relatório

Pelos dados de f1 do dano no núcleo, observa-se a classificação perfeita para esse tipo de dano. De forma contrária, a precisão da interface é a pior. A justificativa da interface ser classificada com menor precisão que a placa é que a base de dados é desbalanceada, ou seja, há mais dados de dano na placa que na interface, tornando

o modelo tendencioso. Estima-se que o contrário também ocorreria caso houvesse uma base de dados maior para interface em relação à placa.

Em relação à etapa de regressão para localização e dimensionamento do dano, as RNAs apresentaram bons resultados.

Quanto a identificação do dano na placa, considerando todas as métricas, quantitativas e qualitativas, da regressão pode-se concluir que a RNA obteve bons resultados para a identificação da posição (x, y) do dano e do comprimento (c) entretanto não se mostrou preciso para identificar a largura (r) e previu a inclinação (θ) de forma quase aleatória.

A Figura 10 apresenta o resultado da regressão para alguns modelos de dano.

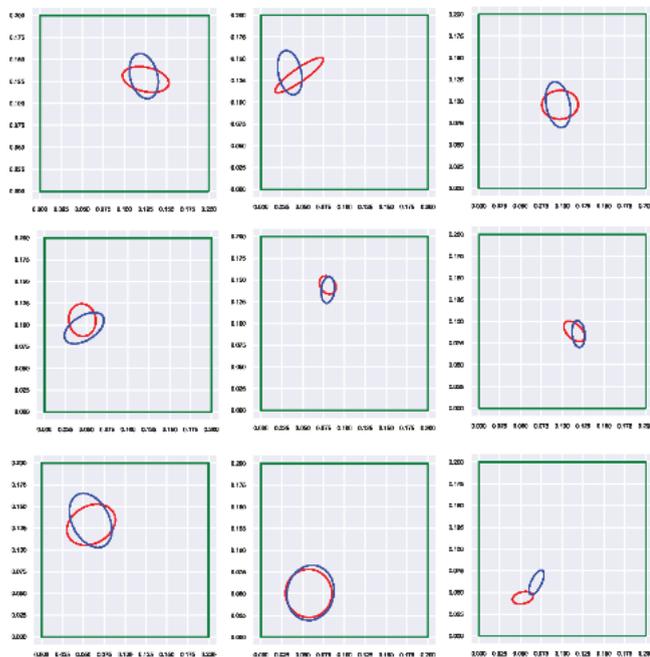


Figura 10 - Diagrama de demonstração do dano real (●) e predito (●) para placa/interface.

Quanto a identificação do dano no núcleo, pode-se concluir que a RNA obteve bons resultados para a identificação da posição em x e y (x, y) do dano, do comprimento (c) e da inclinação em z (θ_z) entretanto a previsão da largura (r), posição em z (z) e a inclinação em y (θ_y) foram realizadas de maneira quase aleatória.

A Figura 11 apresenta o resultado da regressão para alguns modelos de dano no núcleo.

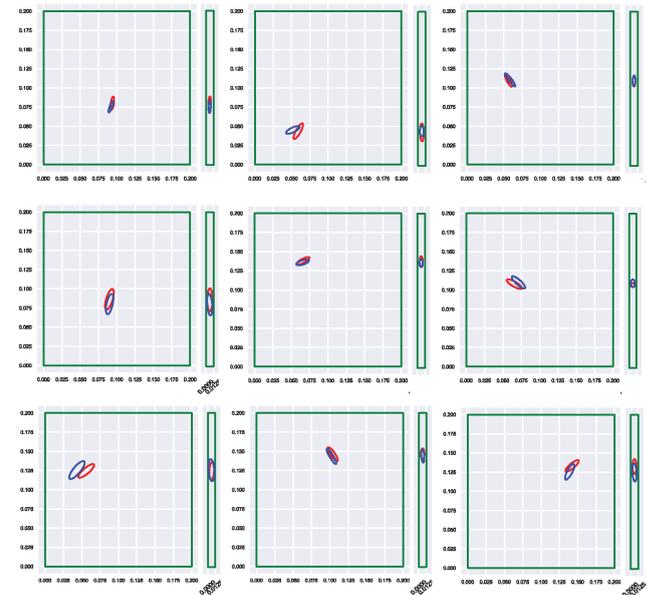


Figura 11 - Diagrama de demonstração do dano real (●) e predito (●) para o núcleo.

Conclusões

A técnica utilizada para a classificação do dano se mostrou eficiente para distinguir entre dano e placa/interface, entretanto a distinção entre placa e interface não foi possível, nem mesmo considerando os modos de vibração. A regressão para a localização e dimensionamento dos danos foi satisfatória, de maneira a localizar com acurácia a localização do dano. De maneira contrária, o dimensionamento teve um erro associado maior e, a inclinação do dano, foi prevista de maneira praticamente aleatória.

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

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. Archives of computational methods in engineering, Springer, v. 26, n. 4, p. 883–897, 2019.