

**“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”****Modelagem Numérica e Aprendizado Profundo para Detecção de Delaminações em Materiais Compósitos**Guilherme Conrado de Souza Silva<sup>1</sup> (IC), Guilherme Ferreira Gomes (PQ)<sup>1</sup><sup>1</sup>Universidade Federal de Itajubá.**Palavras-chave:** Aprendizado Profundo. Materiais Compósitos. Método dos Elementos Finitos. Monitoramento da Integridade Estrutural.**Introdução**

O emprego de materiais compósitos em aplicações de engenharia avançada, como aeronaves, veículos espaciais e sistemas militares, consolidou-se como elemento indispensável na atualidade. Essa relevância decorre do fato de que tais materiais representam um marco na evolução da engenharia de materiais, sobretudo quando comparados às ligas metálicas tradicionais, como alumínio e titânio. Para exemplificar, em aeronaves comerciais de última geração, aproximadamente 53% da massa estrutural é constituída por materiais compósitos (GAY, 2014).

Entretanto, diferentemente das ligas metálicas, que apresentam comportamento isotrópico e permitem a detecção relativamente simples de trincas e pequenas avarias, os compósitos exibem maior complexidade no processo de identificação de danos. Essa dificuldade é intensificada no caso de defeitos internos, como delaminações interlaminares, cuja detecção é desafiadora devido à sua natureza não superficial e ao comportamento anisotrópico do material (SINGH; SMITH; KUMAR, 2013).

Nesse contexto, o Monitoramento da Integridade Estrutural (SHM – *Structural Health Monitoring*) surge como uma estratégia promissora, fundamentada na combinação de tecnologias computacionais e técnicas não destrutivas, visando acompanhar, em tempo real, o estado de saúde das estruturas (DU et al., 2024). Uma das principais vantagens do SHM é a possibilidade de aumentar a confiabilidade e o desempenho estrutural durante todo o ciclo de vida, fornecendo estimativas mais precisas na previsão de falhas (ZANETTI et al., 2025).

Entre as abordagens mais utilizadas no SHM, destacam-se as técnicas baseadas em resposta dinâmica, como a análise modal, que possibilita a obtenção de parâmetros experimentais da função de resposta em frequência (FRF). Esses parâmetros permitem a construção de bases de dados adequadas para a identificação, detecção e classificação de anomalias no comportamento estrutural (MELLO; GOMES, 2025).

Na etapa de processamento e interpretação desses dados,

ferramentas baseadas em aprendizado profundo, em especial as Redes Neurais Convolucionais (CNNs), vêm se mostrando altamente eficazes. Tais modelos são capazes de extrair informações relevantes de representações gráficas ou imagens, permitindo identificar padrões associados à integridade estrutural, classificar tipos de falhas e acelerar a eficiência do monitoramento (NGUYEN et al., 2024).

Estudos recentes reforçam essa tendência. Viotti, Ribeiro e Gomes (2024) aplicaram CNNs para identificar danos em estruturas sanduíche por meio da análise de imagens, alcançando resultados expressivos na previsão da localização e da extensão dos danos. De forma complementar, Viotti e Gomes (2023) e Gomes e Silva (2025) propuseram metodologias baseadas em modelagem por elementos finitos, nas quais a presença de danos foi representada pela redução de propriedades mecânicas locais ( $E_1, E_2$  e  $G_{12}$ ). O diferencial do presente trabalho consiste em propor uma modelagem alternativa, em que a região de delaminação é simulada como ausência de contato entre as camadas, proporcionando maior fidelidade numérica à natureza física do problema.


**Metodologia**

A estrutura da placa estudada foi baseada na geometria de um painel fornecido pela Embraer, com dimensões de 1 m x 1 m e empilhamento de camadas definido por  $[0/\pm 45/90]_{2S}$

A modelagem foi realizada utilizando o Método dos Elementos Finitos (MEF) por meio do *software Abaqus*, conforme Figura 1, sendo a estrutura parametrizada para permitir a inserção de diferentes entradas de parâmetros e a execução automatizada em loop para geração de casos.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Figura 1 – Modelo numérico da estrutura em elementos finitos.



Foram desenvolvidos dois modelos:

Modelo 1: sem a presença de danos, representando a condição de referência (*baseline*), para obtenção das frequências naturais correspondentes à estrutura íntegra; Modelo 2: com a possibilidade de inserção de danos do tipo delaminação interna, com o objetivo de validar um modelo de aprendizado profundo para detecção de falhas não perceptíveis a olho nu.

Ambos os modelos compartilham os mesmos parâmetros geométricos, propriedades mecânicas e tamanho de malha.

Diferentemente de Gomes e Silva (2025), a modelagem do dano não consistiu apenas em modificar as propriedades mecânicas do compósito, mas sim em criar regiões sem contato entre camadas específicas, representando de forma mais realista a condição de delaminação.


A placa foi modelada com 16 sólidos, cada um representando uma camada do laminado. Em seguida, foram atribuídas partições nestes sólidos para representar as áreas de delaminação. A condição de contato entre as camadas foi definida por meio do comando *TIE* do *Abaqus*, excluindo das regiões de contato as partições correspondentes às delaminações. Assim, garantiu-se que essas áreas permanecessem sem aderência, simulando adequadamente o dano. Após essa etapa, os sólidos foram empilhados para compor o laminado, sendo então aplicadas as condições de contorno, a aplicação da malha e, por fim, realizada a análise modal, conforme pode ser visto pelo fluxo apresentado na Figura 2.

Os danos foram caracterizados por cinco variáveis de decisão, que compõem o vetor de danos, utilizado para

treinamento dos modelos de aprendizado profundo. Essas variáveis representam a interface onde está localizado o dano, o número de danos, o tamanho dos danos, e por fim, a localização no plano cartesiano da placa.

$$\vec{D} = \{i, n, t, x, y\}$$

Figura 2 – Fluxo de modelagem



Para construção da base de dados, o processo de geração foi automatizado, permitindo a criação de um lote suficientemente amplo para execução de 1000 simulações. Cada simulação gerou os 40 primeiros modos de vibração, extraídos em formato de imagem para posterior utilização no treinamento do modelo de aprendizado profundo.

Definiu-se que o modelo deveria conter, no mínimo, uma interface com dano e, no máximo, três interfaces com a presença simultânea de danos. Em cada interface, foram considerados de um a quatro danos, totalizando uma variação entre um e doze danos totais possíveis no laminado. O tamanho dos danos foi estabelecido no intervalo de meia polegada a duas polegadas, com posterior conversão para milímetros.

A posição dos danos foi definida em um plano cartesiano com coordenadas  $x$  e  $y$  variando de 10 mm a 990 mm, de modo a manter uma margem de 10 mm nas extremidades da placa. Essa margem foi adotada para evitar a ocorrência de danos nas arestas e vértices, uma vez que delaminações nessas regiões são facilmente perceptíveis a olho nu, não justificando o objetivo do presente estudo.

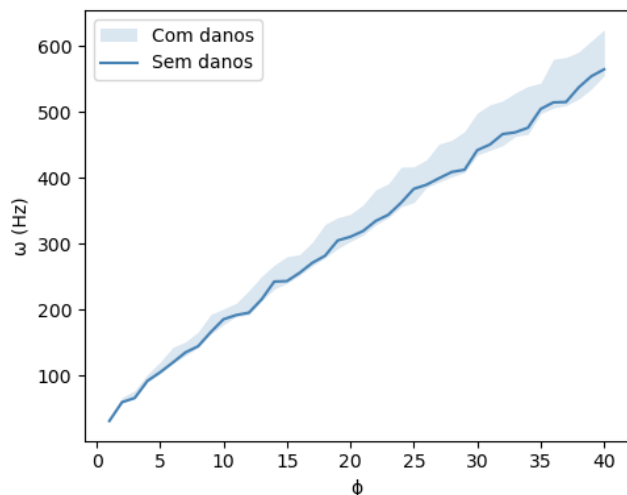
## Resultados e discussão

Os resultados obtidos neste estudo são apresentados em duas principais vertentes: a primeira relacionada à modelagem por elementos finitos e a segunda ao modelo de aprendizado profundo.

No que se refere à análise por MEF, observou-se que a presença de danos impacta a resposta estrutural da placa, alterando os valores das frequências naturais. Essa alteração indica uma variação na rigidez da estrutura.

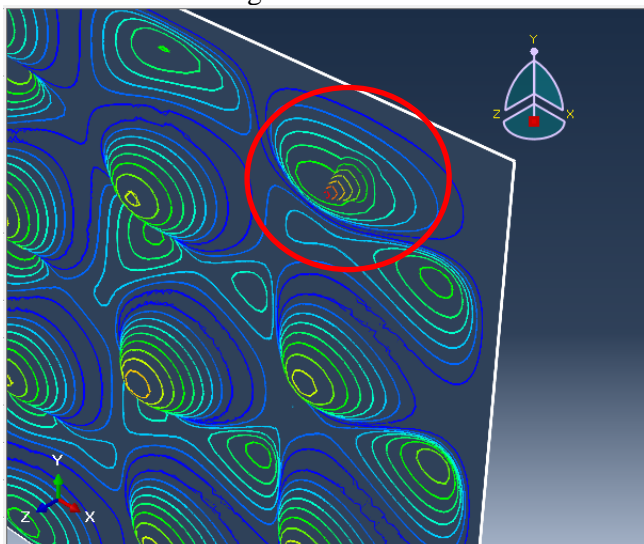
“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Figura 3 – Variação das frequências naturais por modo de vibração em função da presença de danos



A análise do gráfico apresentado na Figura 3 permite interpretar que, à medida que se aumentam os modos de vibração, ocorre uma variação mais pronunciada das frequências naturais quando comparadas ao modelo *baseline*, ou seja, o modelo sem a presença de danos. Nota-se que, quanto maior o modo considerado, maior é a dispersão dos valores obtidos para as placas com danos em relação à placa íntegra.

Figura 4 – Resultado da análise em elementos finitos, evidenciando uma região de dano.

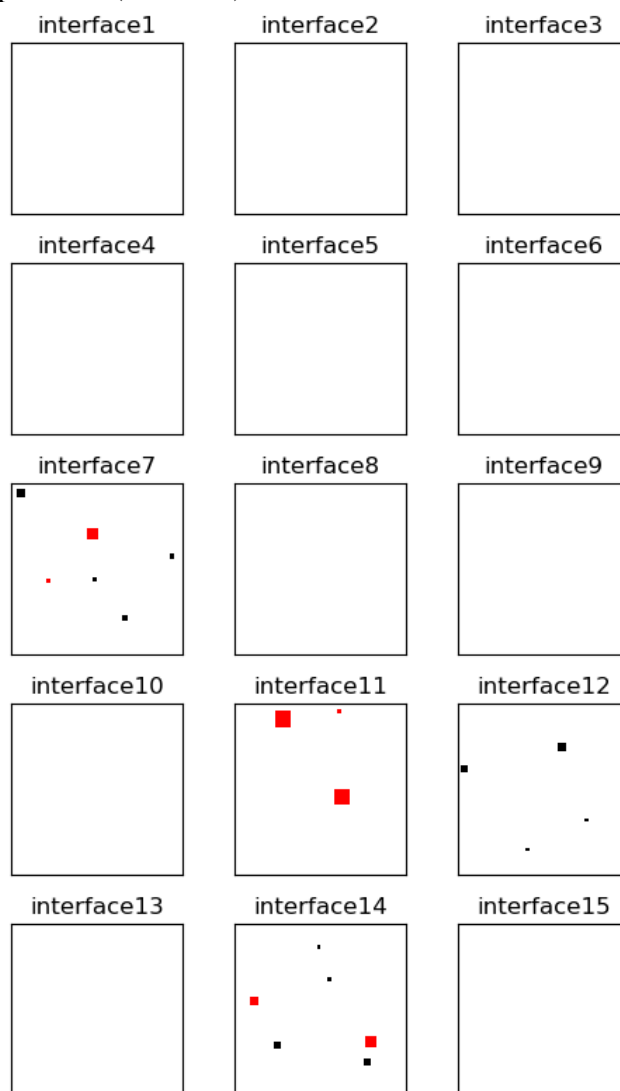


A partir da Figura 4, observa-se que a região de dano, por não apresentar contato entre as camadas, encontra-se mais suscetível ao deslocamento fora do plano, quando comparada às regiões intactas. Esse comportamento ocorre porque a área delaminada está descolada da

estrutura, resultando em regiões com maior deslocamento devido à menor rigidez local.

No que se refere ao modelo de aprendizado profundo, a elevada complexidade do problema, associada à variabilidade do vetor de dano e ao tamanho limitado do conjunto de dados, impôs restrições ao desempenho obtido. Em síntese, o modelo ainda não demonstrou uma capacidade de aprendizado suficientemente robusta para diferenciar de forma consistente os diversos cenários de dano.

Figura 5 – Comparação de um caso de teste (preto) com o melhor resultado atingido pelo modelo de aprendizado profundo (vermelho).



Observou-se que, mesmo no melhor caso analisado, os resultados apresentaram limitações: embora duas interfaces tenham sido corretamente identificadas, os

**“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”**

valores referentes ao número de danos por interface não foram previstos de forma precisa, e a localização espacial das regiões de delaminação aproximou-se da posição real em apenas um dos doze casos avaliados. Quanto à estimativa do tamanho dos danos, verificou-se extrapolação do intervalo definido, com atribuição de valores fora do padrão esperado. Dessa forma, estudos futuros, com ampliação do banco de dados e refinamento do modelo, tornam-se necessários para alcançar maior acurácia e generalização dos resultados.

**Conclusões**

O estudo demonstrou que a modelagem do dano por ausência de contato entre camadas no MEF representa de forma mais realista a delaminação, impactando significativamente as frequências naturais e o comportamento estrutural. Essa abordagem permitiu observar de maneira consistente como a presença, localização e tamanho dos danos influenciam os modos de vibração, reforçando a importância da representação adequada de falhas interlaminares em análises numéricas. Já na etapa de aprendizado profundo, constatou-se que a complexidade do problema, somada à variabilidade do vetor de danos, ainda constitui um desafio para que a CNN estabeleça correlações plenamente consistentes entre as imagens e os rótulos. Apesar dessas limitações, o trabalho contribui ao evidenciar os obstáculos frente à construção de *datasets* robustos para aplicações em SHM e ressalta a relevância de investigações futuras, seja por meio do aumento da base de dados, da adoção de estratégias de geração sintética ou da exploração de técnicas alternativas de aprendizado, de modo a ampliar a acurácia e a confiabilidade na detecção de múltiplos danos em compósitos.

**Agradecimentos**

Agradeço ao Prof. Guilherme Ferreira Gomes pela orientação e à Universidade Federal de Itajubá (Unifei) juntamente com o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por possibilitar esse estudo.

**Referências**

DU, Jinbo; ZENG, Jie; WANG, Han; DING, Huiming; WANG, Haijin; BI, Yunbo. Using acoustic emission technique for structural health monitoring of laminate composite: A novel CNN-LSTM framework. *Engineering Fracture Mechanics*, v. 309, 110447, 2024.

GAY, Daniel. *Composite Materials: Design and Applications*. 3. ed. Boca Raton: CRC Press, 2014.

GOMES, Guilherme Ferreira; SILVA, Guilherme Conrado de Souza. Influence of surface imperfections and damage on the structural properties of composite cylindrical shells: A modeling and prediction approach. *Composite Structures*, v. 372, 119497, 2025.

MELLO, Felipe Martarella de Souza; GOMES, Guilherme Ferreira. Sensor placement optimization for composite aircraft structures: A multi-objective Kriging-based approach. *Composite Structures*, v. 353, 118723, 2025.

NGUYEN, Duc C.; SALAMAK, Marek; KATUNIN, Andrzej; POPRAWA, Grzegorz; GERGES, Michael. Vibration-based SHM of railway steel arch bridge with orbit-shaped image and wavelet-integrated CNN classification. *Engineering Structures*, v. 315, 118431, 2024.

SINGH, R.; SMITH, J.; KUMAR, P. Damage of composite materials. *Procedia Engineering*, v. 51, p. 104–109, 2013.

VIOTTI, Ian Dias; GOMES, Guilherme Ferreira. Delamination identification in sandwich composite structures using machine learning techniques. *Computers & Structures*, v. 280, 106990, 2023.

VIOTTI, Ian Dias; RIBEIRO, Ronny Francis; GOMES, Guilherme Ferreira. Damage identification in sandwich structures using Convolutional Neural Networks. *Mechanical Systems and Signal Processing*, v. 220, 111649, 2024.

ZANETTI, Matteo; NEGRI, Doglas; VANDEPITTE, Dirk; TITA, Volnei; MEDEIROS, Ricardo de. Analysing the influence of delamination on composite structures using modal analysis and statistical indices. *Composite Structures*, v. 371, 119427, 2025.