

Influência das Imperfeições Superficiais nas Propriedades Estruturais de Casca Cilíndrica Composta: Uma Abordagem de Modelagem e Predição

Guilherme Conrado de Souza Silva¹ (IC), Guilherme Ferreira Gomes (PQ)¹

¹Universidade Federal de Itajubá.

Palavras-chave: Aprendizado de Máquina. Materiais Compósitos. Método dos Elementos Finitos. Monitoramento da Integridade Estrutural.

Introdução

Nas últimas décadas, os materiais compósitos avançados têm ganhado crescente relevância em aplicações de alta performance, principalmente devido à sua excepcional relação resistência/peso, sendo amplamente utilizados nas indústrias aeroespacial, automotiva e de defesa. As aeronaves comerciais modernas, por exemplo, são compostas por cerca de 50% de compósitos em peso, refletindo seu impacto na melhoria da eficiência estrutural e sustentabilidade das operações (GIURGIUTIU, 2022; BACHMANN; HIDALGO; BRICOUT, 2017).

Apesar das vantagens, o uso desses materiais introduz novos desafios, como a manutenção da integridade estrutural e a complexidade associada à detecção de danos. Estruturas compostas são suscetíveis a diversos modos de falha, exigindo estratégias de monitoramento mais sofisticadas para garantir a longevidade e a confiabilidade. A esse respeito, o monitoramento da integridade estrutural, ou *Structural Health Monitoring* (SHM), tem se destacado como uma ferramenta essencial (GIURGIUTIU, 2014), permitindo a detecção precoce de falhas e a prevenção de interrupções inesperadas em serviços críticos (DEUTSCHES INSTITUT FÜR NORMUNG, 2003).

O SHM utiliza metodologias avançadas, como sensores inteligentes e captação de imagens, sendo o monitoramento por vibração uma das técnicas mais eficazes para a detecção de danos em estruturas compostas. Essa abordagem não destrutiva explora as alterações nas frequências naturais e modos de vibração de uma estrutura para identificar trincas e delaminações que não seriam perceptíveis visualmente (VIOTTI; RIBEIRO; GOMES, 2024).

Contudo, o processamento e a análise de grandes quantidades de dados coletados por sistemas SHM exigem o uso de técnicas de aprendizado de máquina (AM) e aprendizado profundo (AP), capazes de identificar padrões e anomalias nos dados. Modelos de AM, como regressão logística, são fáceis de treinar e possuem baixo custo computacional, porém têm

desempenho limitado em problemas complexos (SHARIFANI; AMINI, 2023). Já os modelos de AP, inspirados na organização cerebral, são mais eficazes para resolver esses problemas.

Viotti e Gomes (2023) apresentaram um método inovador para a identificação de delaminações em estruturas sanduíche compostas, utilizando dados modais obtidos via método dos elementos finitos (MEF). Esse estudo utilizou modelos de AM para classificar e localizar danos com alta precisão, principalmente em camadas superficiais. Em continuidade, Viotti, Ribeiro e Gomes (2024) investigaram o uso de redes neurais convolucionais (RNCs) para identificar danos em estruturas compostas, alcançando alta precisão, mesmo em imagens ruidosas, apesar de limitações em relação ao dimensionamento e inclinação dos danos.

A pesquisa também abordou a influência de danos nas respostas estruturais e a predição de flambagem em estruturas de parede fina compostas, mostrando que a delaminação afeta significativamente a flambagem (GOMES; MESQUITA; BENDINE, 2024). Outro estudo relevante é o de Wagner et al. (2019), que utilizou AM para otimizar a sequência de empilhamento em cilindros compostos submetidos à compressão, maximizando a carga de flambagem e minimizando a sensibilidade a imperfeições.

O presente estudo não só amplia a abordagem de parametrização de danos de pesquisas anteriores, como também explora a correlação entre flambagem e vibração, uma área pouco investigada na literatura recente. Além disso, inova ao integrar a modelagem de imperfeições em cilindros compostos, fator ainda não abordado no campo de SHM. Com isso, esta pesquisa contribui de forma inédita para a área, propondo novas metodologias para a detecção de danos em materiais compósitos.

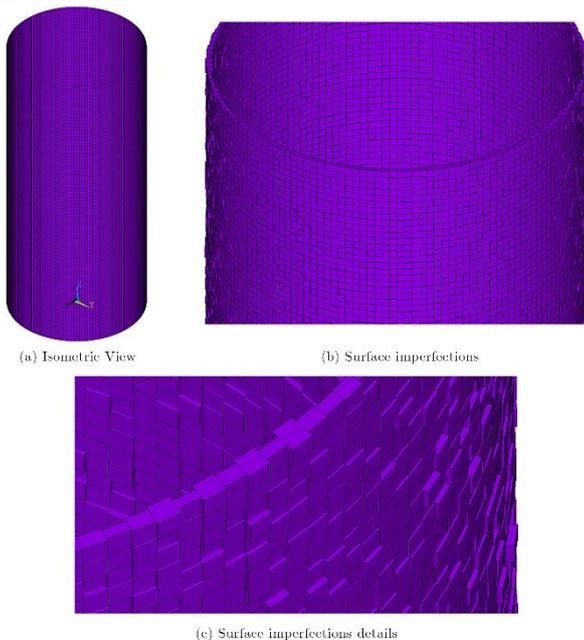
Metodologia

A estrutura estudada foi modelada utilizando o MEF por meio da linguagem Ansys Parametric Design Language (APDL), devido à sua eficácia na parametrização,

inclusão de danos e automatização das análises. Dois modelos principais foram desenvolvidos: um modelo base sem dano, destinado à avaliação de imperfeições superficiais, e um modelo com dano, utilizado para treinar e validar modelos de AM na previsão de danos e imperfeições superficiais.

Ambos os modelos compartilham os mesmos parâmetros, como geometria, propriedades mecânicas e tamanho de elemento, utilizando o elemento *SHELL281*. A estrutura consiste em um cilindro de 0,224 m de altura e 0,1 m de diâmetro, com 10 camadas de CFRP (polímero reforçado com fibra de carbono) de 0,00012 m de espessura média. O modelo base foi inicialmente utilizado para investigar a influência de imperfeições superficiais, introduzidas por um coeficiente variacional (*CV*) calculado por meio de um script em Python, que variou a espessura média de cada elemento.

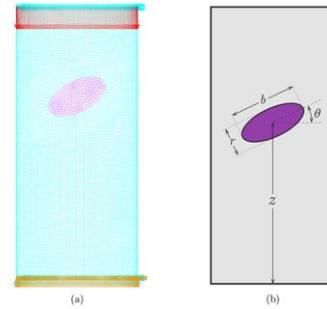
Figura 1 – Modelo numérico da estrutura em elementos finitos.



O modelo numérico com dano inclui uma área elíptica ao longo da casca cilíndrica (Figura 2), onde foi simulada uma redução local de rigidez, implementada por um coeficiente multiplicativo percentual (α), que altera as propriedades elásticas do laminado (E_1, E_2, G_{12}). Este dano é caracterizado por cinco variáveis de decisão que formam o vetor de danos (\vec{D}), utilizado para treinar os modelos de AM.

$$\vec{D} = \{z, b, r, \theta, \alpha\}$$

Figura 2 - Modelo numérico da estrutura em elementos finitos.



Para criar a base de dados necessária ao treinamento dos modelos de AM, automatizou-se o processo de análises estáticas, modais e de flambagem, gerando 1000 rodadas de aquisição de resultados. Paralelamente, parâmetros iniciais, como danos e imperfeições, foram gerados aleatoriamente dentro de intervalos específicos definidos na Tabela 1.

Tabela 1 - Intervalo adotado para os parâmetros iniciais.

Parâmetro inicial	Limite inferior	Limite superior
z [mm]	0	224
b [mm]	5	50
r [mm/mm]	0.1	1
θ [°]	-90	90
α [%]	0	100
CV [%]	0	30

O tratamento dos dados foi realizado em duas etapas: remoção de *outliers* e normalização, utilizando técnicas como o intervalo interquartil (IIQ) e o escalonamento *mín-máx*, para garantir uma base de dados consistente e ajustada.

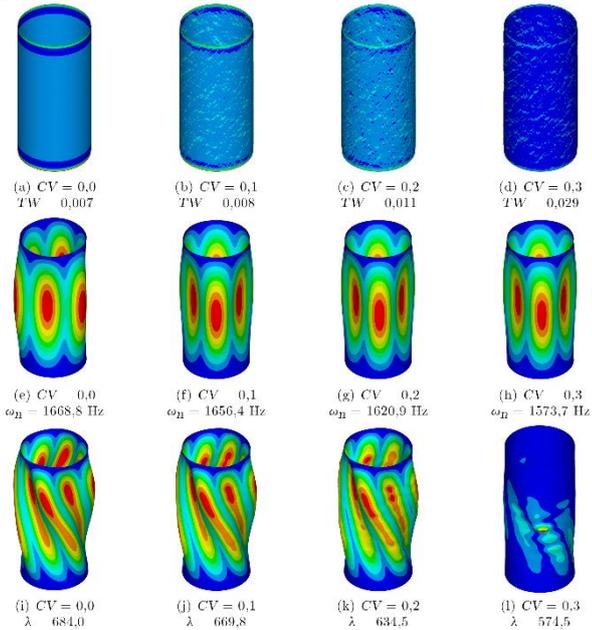
Os *outliers* foram removidos para evitar que valores extremos distorcessem os resultados, enquanto a normalização garantiu que todas as variáveis estivessem na mesma escala, evitando influências indesejadas no treinamento do modelo de AM. A normalização foi realizada utilizando a técnica *mín-máx*, transformando os dados para o intervalo entre 0 e 1, o que melhorou a eficiência e precisão das previsões.

Resultados e discussão

Os resultados iniciais, apresentados na Figura 3, evidenciam a influência do *CV* da espessura média sobre a resposta estrutural da estrutura sem danos. À medida que o *CV* aumenta, a probabilidade de falha estrutural (*TW*) cresce significativamente, enquanto a frequência natural (ω_n) e o autovalor de flambagem (λ) diminuem. Um aumento de *CV* para 0,30 resultou em uma redução

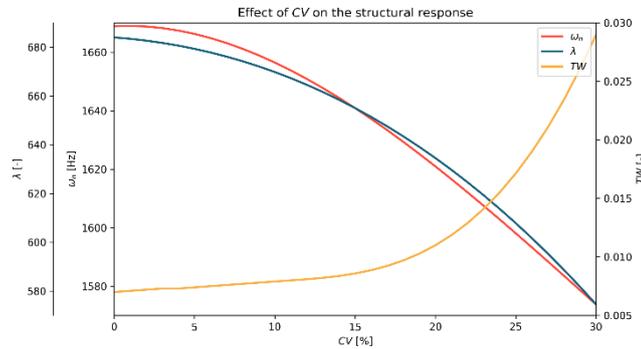
de 16% em λ , uma queda de 5% em ω_n , e um aumento superior a 300% em TW , indicando uma clara degradação no desempenho estrutural. Além disso, observou-se que, com o CV próximo de 30%, ocorrem flambagens locais na casca cilíndrica.

Figura 3 – Impacto da variação das imperfeições superficiais nas respostas estruturais.



A Figura 4 complementa esses achados, mostrando a variação das respostas estruturais em função do aumento do CV da espessura média. As imperfeições superficiais contribuem para uma perda de rigidez e estabilidade da estrutura, sugerindo que a análise das imperfeições é essencial para prever falhas estruturais.

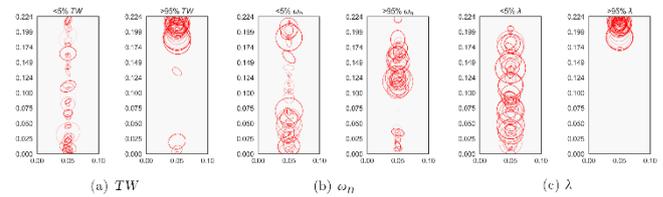
Figura 4 – Efeito do CV na resposta estrutural da estrutura sem dano.



Em relação aos danos, a Figura 5 mostra que aqueles com maior impacto nas respostas estruturais estão localizados nas extremidades do cilindro, onde há maior concentração de tensões, e apresentam α de maior

severidade. Danos com menor impacto são mais distribuídos ao longo da estrutura e têm menor dimensão ou menor severidade de α .

Figura 5 - Danos com menor e maior impacto nas respostas estruturais TW , ω_n e λ .



Ao comparar diferentes modelos de AM para prever os parâmetros de dano, verificou-se que os modelos não apresentaram previsões satisfatórias, com erros consideráveis e baixa acurácia. No entanto, como destacado na Figura 6, os dez melhores resultados, especialmente para os parâmetros b e r , foram mais precisos. O parâmetro z , por outro lado, apresentou maior suscetibilidade a erros.

Figura 6 - Comparação entre os danos dos dados de teste (cinza) e os danos previstos pelos modelos (azul).

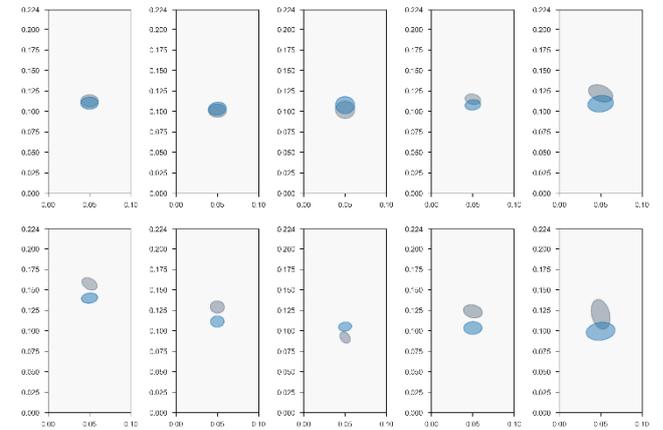
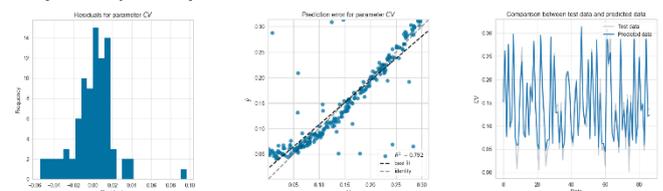


Figura 7 - Avaliação dos resultados de regressão para a imperfeição superficial.



Na previsão do CV da espessura média, os resultados foram mais promissores. A análise, detalhada na Figura 7, mostrou que os modelos de AM apresentaram melhor desempenho, com um coeficiente de determinação (R^2) de 0,792 e uma distribuição de resíduos relativamente

equilibrada, sugerindo maior precisão na previsão de imperfeições superficiais.

Conclusões

Os resultados iniciais da análise da estrutura sem danos, conforme apresentado na Figura 3, demonstram uma correlação significativa entre o CV da espessura média e as respostas estruturais, como TW , ω_n e λ . Com o aumento do CV , o parâmetro TW , que reflete a probabilidade de falha estrutural, também cresce. Embora, no contexto da pesquisa, os valores de TW não tenham atingido níveis que indiquem falha iminente, sua elevação reforça a vulnerabilidade da estrutura. Em contrapartida, tanto ω_n quanto λ diminuem com o aumento do CV , indicando perda de rigidez e estabilidade estrutural. A observação de flambagem local na casca cilíndrica, com CV próximo a 30%, destaca a sensibilidade da estrutura a grandes imperfeições na espessura.

Na avaliação dos modelos de AM aplicados à previsão dos parâmetros de dano, os resultados demonstraram baixo desempenho. Os modelos analisados apresentaram previsões imprecisas, evidenciadas pelos erros consideráveis e pelos gráficos de resíduos que mostraram dificuldades em capturar padrões nos dados. A Figura 6 revela que, embora as cinco melhores previsões tenham apresentado resultados relativamente aceitáveis, os parâmetros z , θ e α foram os mais suscetíveis a erros, enquanto b e r apresentaram maior precisão, mas ainda insatisfatória.

Por outro lado, os modelos de AM aplicados à previsão do CV da espessura média apresentaram resultados mais promissores. A análise dos resíduos e erros de previsão, apresentada na Figura 7, reflete um desempenho mais satisfatório para o CV , com menor dispersão de erros.

Em resumo, a análise demonstrou que a previsão do CV da espessura média é satisfatória, mas a previsão dos parâmetros de dano requer maior desenvolvimento, seja em termos de refinamento dos dados ou de um modelo numérico com dano mais representativo. Esses achados são valiosos para o aprimoramento de estratégias de SHM em estruturas de CFRP, além de fornecer direções para futuras pesquisas nessa área.

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

- BACHMANN, J.; HIDALGO, C.; BRICOUT, S. Environmental analysis of innovative sustainable composites with potential use in aviation sector—a life cycle assessment review. *Science China Technological Sciences*, Springer, v. 60, p. 1301—1317, 2017.
- DEUTSCHES INSTITUT FÜR NORMUNG. Condition monitoring and diagnostics of machines – General guidelines. Berlin, 2003. DIN ISO 17359.
- GIURGIUTIU, V. Stress, Vibration, and Wave Analysis in Aerospace Composites for SHM and NDE Applications. [S.l.]: Elsevier, 2022.
- GIURGIUTIU, V. Structural Health Monitoring with Piezoelectric Wafer Active Sensors. [S.l.]: Elsevier, 2014.
- GOMES, G. F.; MESQUITA, M. H.; BENDINE, K. Predictive modeling of buckling in composite tubes: Integrating artificial neural networks for damage detection. *Mechanics of Advanced Materials and Structures*, Taylor Francis, p. 1–15, 2024.
- SHARIFANI, K.; AMINI, M. Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, Social Science Research Network, v. 10, n. 7, p. 3897–3904, 2023.
- VIOTTI, I. D.; RIBEIRO, R. F.; GOMES, G. F. Damage identification in sandwich structures using convolutional neural networks. *Mechanical Systems and Signal Processing*, Elsevier, v. 220, n. 4, p. 111649, 2024.
- VIOTTI, I. D.; GOMES, G. F. Delamination identification in sandwich composite structures using machine learning techniques. *Computers & Structures*, Elsevier, v. 280, p. 106990, 2023.
- WAGNER, H. et al. Decision tree-based machine learning to optimize the laminate stacking of composite cylinders for maximum buckling load and minimum imperfection sensitivity. *Composite Structures*, Elsevier, v. 220, p. 45–63, 2019.