

Monitoramento de integridade estrutural utilizando inteligência artificial: Desafios, avanços e aplicações

Victor Higino Meneguitte Alves
Universidade Federal de Juiz de Fora (UFJF)

 <https://orcid.org/0000-0001-8959-050X>
victor.meneguitte@engenharia.ufjf.br

Vinicius Antônio Meneguitte Alves
Universidade Federal de Juiz de Fora (UFJF)

 <https://orcid.org/0009-0000-2024-9602>
vinicius.meneguitte@engenharia.ufjf.br

Alexandre Abrahão Cury
Universidade Federal de Juiz de Fora (UFJF)

 <https://orcid.org/0000-0002-8860-1286>
alexandre.cury@ufjf.edu.br

RESUMO

Este artigo apresenta uma revisão sistemática e traz reflexões críticas acerca da utilização de técnicas de inteligência artificial para identificação de deterioração estrutural por meio de sinais de vibração (i.e., acelerações, deslocamentos, etc). Abordagens baseadas em aprendizado de máquina e aprendizado profundo são consideradas promissoras para aumentar a segurança e otimizar os cronogramas de manutenção preventiva. Entretanto, alguns autores reconhecem as preocupações decorrentes de métodos estritamente supervisionados, da natureza do tipo “caixa-preta” dos modelos e de suas interpretabilidades por operadores humanos. A contribuição deste trabalho consiste, portanto, em fornecer informações relevantes sobre o atual paradigma de detecção de danos, possibilitando previsões em tempo real, não destrutivas e confiáveis sobre a segurança da construção no âmbito da Indústria 4.0. Além disso, os desafios relacionados ao emprego de inteligência computacional para

reconhecimento de padrões e tomada de decisão no monitoramento de anomalias estruturais são relatados e examinados em estudos de casos recentes.

Palavras-chave: detecção de danos estruturais; inteligência computacional; aprendizado de máquina; aprendizado profundo.

Structural integrity monitoring using artificial intelligence: Challenges, advances and applications

ABSTRACT

This paper presents a systematic review and brings critical reflections on the use of artificial intelligence techniques to identify structural deterioration through vibration signals (i.e., accelerations, displacements, etc.). Approaches based on machine learning and deep learning are considered promising for increasing safety and optimizing preventive maintenance schedules. However, some authors recognize concerns arising from strictly supervised methods, the “black box” nature of the models and their interpretability by human operators. Therefore, the contribution of this work is to provide relevant information about the current damage detection paradigm, enabling real-time, non-destructive, and reliable predictions about construction safety within the scope of Industry 4.0. Furthermore, challenges related to the use of computational intelligence for pattern recognition and decision-making in monitoring structural anomalies are reported and examined in recent case studies.

Keywords: damage detection; constructions; computational Intelligence; machine learning; deep learning.

Submissão em: 05/08/2023 | **Aprovação em:** 10/02/2024

1. INTRODUÇÃO: ANTECEDENTES E NOVOS DESAFIOS

A predição do estado atual de segurança de uma determinada estrutura é uma tarefa importante para manter o seu desempenho durante toda a sua vida útil. Entretanto, essa predição é altamente dependente das condições ambientais, cargas de uso, definições de projeto e muitos outros fatores, implicando em uma interação bastante complexa e frequentemente impraticável de serem analisadas conjuntamente. Inicialmente, a avaliação de estruturas surge por inspeções visuais humanas que podem ser inviáveis em locais de acesso remoto, além de serem uma análise subjetiva do engenheiro/técnico e ainda enviesadas por serem limitadas apenas à superfície do elemento construtivo, visto que danos internos à estrutura não poderiam ser identificados desta maneira.

Assim, os sistemas de monitoramento de integridade estrutural (SHM, do inglês *Structural Health Monitoring*) atraem muita atenção de pesquisadores em diversos domínios, como Engenharia Civil (Zhang; Lei, 2021), Mecânica (Wang; Lu; Yan., 2019), Ferroviária (Meixedo *et al.*, 2021) e Aeroespacial (Yuan, 2016), devido à sua abordagem não destrutiva e em tempo real que tem potencial para economizar custos com manutenção, visto que a periodicidade de reparos pode ser otimizada. Geralmente, as tarefas de SHM são divididas em quatro estágios, com níveis mais altos exigindo mais esforço para serem concluídos, a saber: (I) relatar a existência do dano, (II) localizar o dano, (III) quantificar o dano e (IV) determinar a vida estrutural restante (Rytter, 1993). A união desses níveis forma um sólido conjunto que sustenta a comunidade científica de SHM, fornecendo-lhes uma ferramenta poderosa para gerenciar as complexidades da identificação de danos.

Nesse contexto, a maioria dos métodos convencionais para SHM utiliza a análise modal, que se apoia na identificação de parâmetros modais (Moughty; Casas, 2017) como frequências naturais, taxas de amortecimento e modos de vibração. Contudo, esse processo de identificação modal é uma filtragem que pode levar à perda de informações,

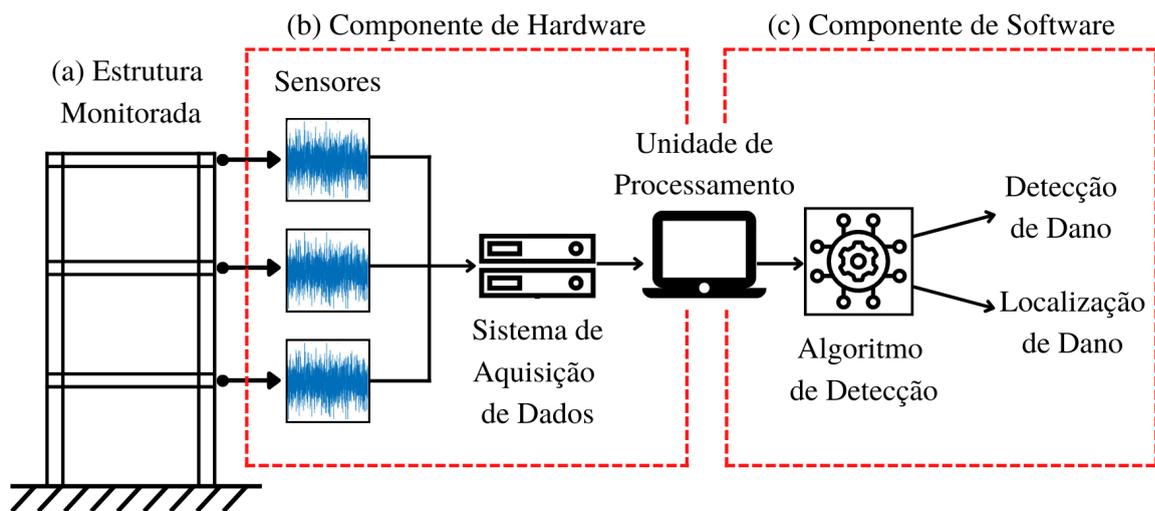
ocultando pequenas alterações estruturais que podem estar relacionadas a danos (Morales; Cury, 2018). De fato, a pesquisa conduzida por Morales e Cury (2018) evidenciou que, de modo geral, não é possível estabelecer uma relação clara entre as variações de temperatura e os efeitos de danos estruturais sobre as frequências naturais de vibração de uma viga biapoiada testada em laboratório. Além disso, os métodos baseados em parâmetros modais assumem que a estrutura permanece no domínio elástico linear após o surgimento do dano, o que nem sempre corresponde à realidade (Cury; Crémona; Diday, 2010).

Uma outra abordagem consagrada, partindo de visão computacional, é discutida detalhadamente por Dong e Catbas (2021), a qual automatiza o processo de inspeção visual, mas mantém a desvantagem de só analisar o exterior dos elementos estruturais. Naquele trabalho, os autores destacam alguns desafios para se aplicar métodos baseados em visão computacional, como sombra, iluminação não-uniforme, mudanças no ângulo de inclinação e vibração da câmera. Dessa forma, anomalias ou processos de degradação podem ocorrer dentro dos componentes estruturais e permanecer ocultos à observação superficial. Descontinuidades, fissuras ou vazios no concreto podem estar entre esses problemas subjacentes (Tian *et al.*, 2021), assim como falhas ocultas, incluindo corrosão das armaduras embutidas, fibras fraturadas ou fissuras de delaminação em materiais compostos (Daneshjoo; Shokrieh; Fakoor, 2018). Por outro lado, o monitoramento baseado em vibração avalia a integridade das estruturas por meio de dados dinâmicos coletados por sensores posicionados nas próprias estruturas. Essa última estratégia será o enfoque principal no presente texto e é extremamente útil quando se torna difícil ou impraticável identificar problemas estruturais apenas visualmente.

Recentemente, abordagens têm sido desenvolvidas para explorar o potencial do uso de técnicas de inteligência artificial (IA) na detecção de degradação estrutural. Dentre essas ferramentas, destacam-se as Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Networks*), Máquinas de Vetor de Suporte (SVM, do inglês *Support Vector Machine*), Conjunto de Árvores de Decisão (DT, do inglês *Decision Tree*), Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*), dentre outras (AVCI *et al.*,

2021). Um sistema padrão de detecção de danos é mostrado na Figura 1, sendo composto por dois elementos principais: o *hardware* e o *software*. Na parte de *hardware* (Figura 1(b)), sensores (acelerômetros) distribuídos pela estrutura (Figura 1(a)) são utilizados para coletar as respostas dinâmicas através de um sistema de aquisição, podendo estes sinais serem gerados por excitação ambiental ou forçada. Já o elemento de *software* (Figura. 1(c)) fica responsável pelo pré-processamento dos dados, além do pós-processamento que pode se dar a partir de um algoritmo definido para reconhecimento de padrões, realizar a detecção, localização e/ou quantificação do dano. Note-se que nada impede a execução simultânea das quatro tarefas (I a IV) pelo mesmo método. Entretanto, esse problema se torna sucessivamente mais difícil. Assim, é comum que alguns autores se limitem a investigar uma tarefa específica, isto é, verificar apenas a existência do dano (equivalente ao nível I), por exemplo.

Figura 1 - Principais elementos de sistemas de detecção de danos estruturais.



Fonte: Elaboração própria, baseada e adaptada da obra de Avci *et al.* (2021).

Assim, desenvolvimentos recentes na tecnologia de sensores tendem a melhorar a confiabilidade e oferecer preços cada vez mais acessíveis para uso em aplicações de grande escala. Isso se torna uma conquista notável, pois a localização se torna mais precisa quanto mais sensores estão dispersos ao longo de uma estrutura. Ademais, os

vários avanços na tecnologia de *chips*, juntamente com o aumento na capacidade de processamento, tornaram possível empregar aspectos da Indústria 4.0 ao monitoramento de estruturas. Como consequência, o processamento de sinais é um tópico que está em constante expansão, além de ser uma ferramenta fundamental para as tecnologias SHM, como resultado dos recentes desenvolvimentos em IA, aprendizado de máquina (ML, do inglês *Machine Learning*) e aprendizado profundo (DL, do inglês *Deep Learning*).

Nessa perspectiva, o objetivo do presente trabalho é fornecer uma visão abrangente dos avanços e desafios no monitoramento estrutural por meio de dados dinâmicos, destacando o progresso alcançado nesse campo na Indústria 4.0. Desta forma, esta revisão sistemática se destaca em meio às já existentes por comparar as técnicas mais recentes de SHM baseadas em ciência de dados, ML e DL quanto ao nível na escala de Rytter (1997) das tarefas que executam. Outro aspecto relevante e original deste trabalho é a discussão crítica do caráter supervisionado ou não-supervisionado dos algoritmos, as implicações disso em uma situação real de monitoramento, além das metodologias que diversos autores têm trazido para solucionar esses problemas. Esta pesquisa também faz um levantamento dos principais dados de *benchmark*, ou seja, de estruturas ensaiadas experimentalmente que possuem maior recorrência na literatura por se tratarem de estudos de caso bem consolidados e com dados abertos à comunidade científica. Assim, a lista de bases de dados recomendada possibilita a comparação facilitada entre os métodos do estado da arte. Por fim, traremos reflexões éticas acerca da interpretabilidade dos modelos de inteligência computacional, os quais tendem a atuar como “caixas-pretas”, seguido de uma discussão sobre técnicas disponíveis para reduzir esse tipo de comportamento. Desse modo, o presente artigo servirá, também, como um manual introdutório de boas práticas no âmbito do campo de estudo do SHM baseado em IA.

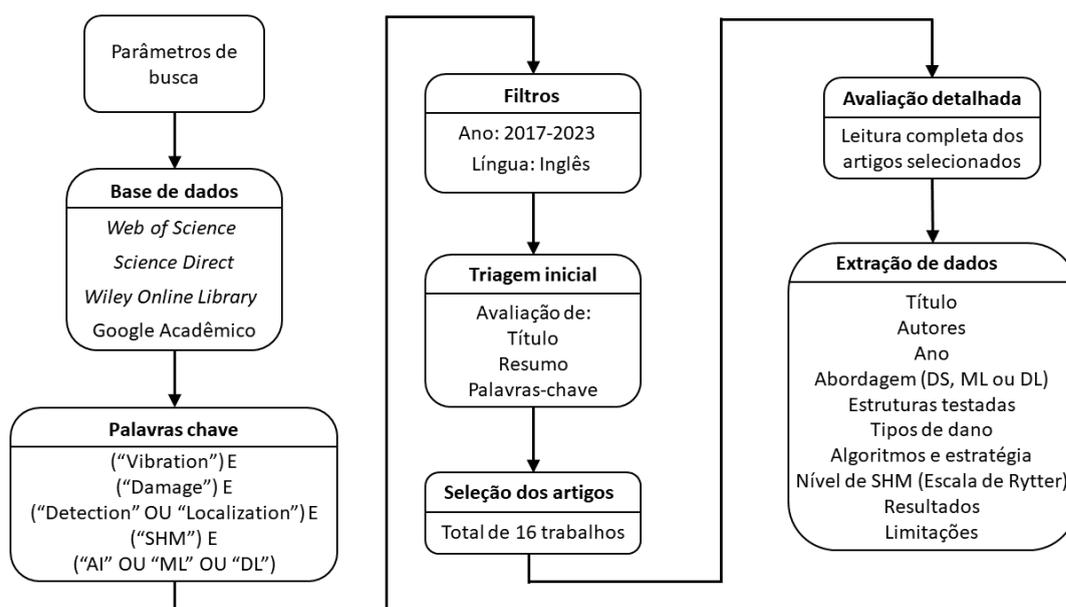
2. METODOLOGIA

Este artigo foi desenvolvido a partir de pesquisas bibliográficas. Foram considerados apenas artigos entre os anos de 2017 e 2023, visando abranger os estudos

mais atuais sobre o tema. Vale destacar que essa compilação não pretende ser uma abordagem exaustiva de todos os métodos de SHM com dados dinâmicos desenvolvidos até o momento, mas sim uma coleção criteriosamente selecionada de artigos revisados por pares, oferecendo uma visão panorâmica do estado da arte atual. Utilizando uma estratégia de busca sistemática, foram identificados e incluídos nesta compilação os trabalhos mais relevantes, provenientes de reconhecidas bases acadêmicas como Web of Science, Science Direct, Wiley Online Library e Google Acadêmico, com um enfoque em artigos de revistas mais expressivas do campo de estudo de SHM. A meta é propiciar uma análise panorâmica do progresso alcançado nesse campo, reconhecendo os avanços e desafios que norteiam o monitoramento estrutural através de dados de vibração na era da Indústria 4.0. Os termos e conectivos booleanos usados para combiná-los na busca foram: (“*Vibration*”) E (“*Damage*”) E (“*Detection*” OU “*Localization*”) E (“SHM”) E (“AI” OU “ML” OU “DL”). Os termos são inseridos em inglês devido à sua presença majoritária nas revistas mais relevantes.

Posteriormente, foram avaliados os títulos, resumos e palavras-chave, a fim de excluir trabalhos que não tivessem a ver com abordagens de uso de algoritmos de inteligência computacional aplicados ao monitoramento de estruturas. Dos documentos restantes, 16 foram selecionados, lidos na íntegra e julgados pelos autores como sendo os estudos que melhor representam, de forma abrangente, o estado da arte do tema. Após a leitura, esses 16 artigos tiveram seus dados catalogados e as suas descobertas e resultados apresentados e discutidos. Além disso, esse trabalho é baseado também em artigos do tipo revisão da literatura com o intuito de se verificar o que é produzido de característica mais inovadora na área de detecção de danos estruturais com base em dados de vibração com IA. Portanto, para detalhes complementares sobre o tema, sugere-se os trabalhos de Avci et al (2021); Azimi, Eslamlou e Pekcan (2020). Uma visão geral da metodologia utilizada neste trabalho é ilustrada na Figura 2.

Figura 2 – Fluxograma da revisão sistemática proposta.



Fonte: Elaboração própria.

3. TÉCNICAS DE IDENTIFICAÇÃO DE ANOMALIAS E SEUS RESULTADOS

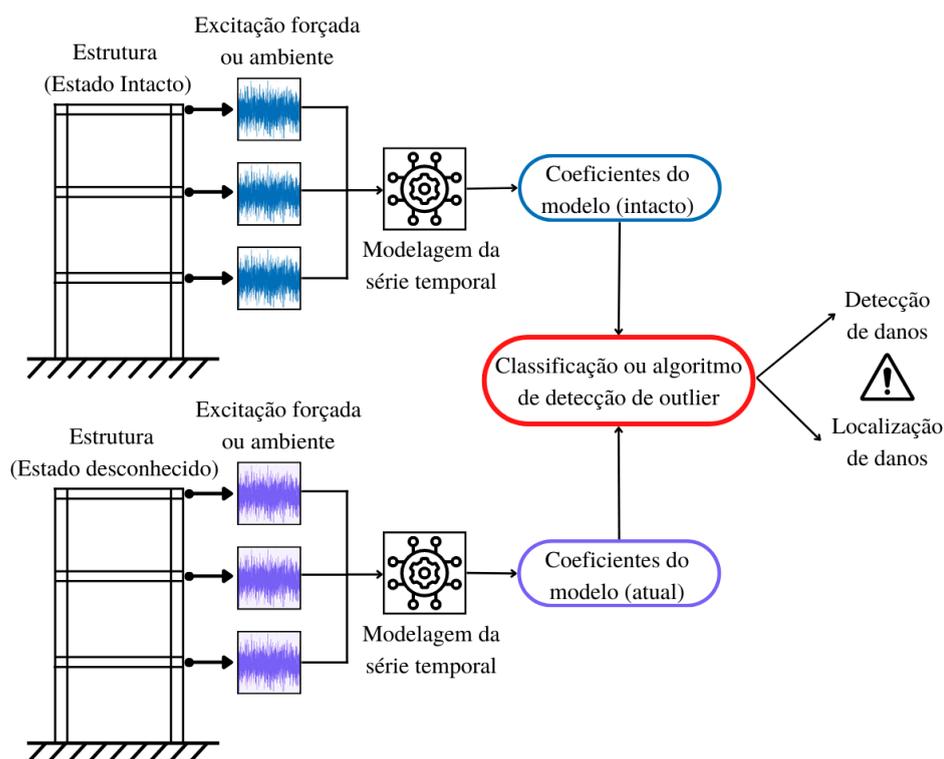
Essa seção apresenta alguns dos resultados de trabalhos mais recentes na área de pesquisa de detecção de danos estruturais baseados em dados de vibração. Dessa maneira, são apresentadas abordagens através de ciência de dados e aprendizado de máquina e aprendizado profundo, explorando as suas vantagens e limitações.

3.1 DETECÇÃO DE DANOS COM CIÊNCIA DE DADOS (DS, DO INGLÊS DATA SCIENCE) E APRENDIZADO DE MÁQUINA (ML)

O trabalho de Alves e Cury (2021) utiliza, fundamentalmente, conceitos de ciência de dados e estatística para localizar danos estruturais. A partir de dados de vibração coletados no estado intacto (referência) e do estado atual (desconhecido) da estrutura, extraí-se as características no domínio do tempo, frequência e quefrência. Depois de extraídas 35 características dos sinais brutos de aceleração, é fundamental construir um

índice que reflita objetivamente o(s) local(is) do dano. Como resultado, a técnica sugerida começa determinando intervalos percentis para cada uma das características associadas ao estado intacto da estrutura. Em seguida, é feita uma análise de *outliers* (valores aberrantes, ou anormais) comparando-se as características do estado desconhecido aos intervalos criados a partir da estrutura de referência (saudável). Como resultado, um índice de dano é calculado de modo que quanto maior o número de características discrepantes em um determinado local (sensor), maior é o índice de dano, correspondendo à maior probabilidade de dano. Note que esse processo de comparação dos sinais intactos com sinais desconhecidos da estrutura (possivelmente danificada) é uma ideia recorrente entre os métodos da literatura. A Figura 3 ilustra esse esquema típico.

Figura 3 – Esquema típico de detecção de danos com inteligência artificial a partir de sinais dinâmicos.



Fonte: Elaboração própria, baseada e adaptada da obra de Avci *et al.* (2021).

Essa metodologia foi melhorada e totalmente automatizada em Alves e Cury (2023). Dessa vez, entretanto, as características extraídas foram posteriormente filtradas por uma técnica de seleção de recursos não supervisionada denominada InFFS, com base em sua relevância e não redundância. Além disso, um novo índice de dano ponderado foi empregado para investigar a existência de um grau de importância no conjunto de características selecionadas. Apesar de ser completamente não supervisionado e automatizado, o método alcançou resultados comparáveis a abordagens tradicionais e até recentes técnicas de aprendizado profundo em todas as aplicações testadas. Em um experimento de viga biapoiada, o método revelou-se promissor em detectar danos extremamente sutis, como pequenos furos, que apresentaram variações inferiores a 1% da primeira frequência natural. Essa capacidade demonstra a sua viabilidade na identificação precoce de danos em cenários em que abordagens baseadas em análise modal seriam ineficazes. Outrossim, o método igualmente evidenciou a sua sensibilidade em detectar danos consideravelmente graves como, por exemplo, uma perda de rigidez de 51,7% em 4 pilares de aço de um pórtico de pequena escala.

Em ambos os casos, o modelo de detecção foi criado apenas com os dados intactos (processo não-supervisionado). Entretanto há casos em que o esquema utilizado é o de um treinamento supervisionado. Assim, traz-se à tona a questão de como os dados danificados seriam gerados para treinar os modelos, haja vista que seria contraditório danificar propositalmente a estrutura.

Uma estratégia supervisionada do estudo de Gui et al (2017), investigou a viabilidade de se utilizar máquinas de vetores de suporte (SVM) associadas a técnicas de otimização para extração aprimorada de características e parâmetros de otimização para detecção de danos. Dois tipos de métodos de extração de características foram avaliados, incluindo parâmetros de modelos autorregressivos (AR, do inglês *AutoRegressive*) e erros residuais de parâmetros estatísticos. Assim, foram testadas três técnicas de otimização: método de busca em grade (GS, do inglês *Grid Search*), otimização de enxame de partículas (PSO, do inglês *Particle Swarm Optimization*) e algoritmo genético (GA, do inglês *Genetic Algorithm*) para determinar, efetivamente, os parâmetros no SVM.

Assim, fica evidente a discussão da existência de possíveis níveis diferentes de importância entre as características usadas como entrada. Sob essa ótica, o trabalho de Ghiasi, Ghasemi e Chan (2021) realizou uma extração de características usando pacotes de energia relativa *wavelet* (WPRE) e sugeriu um método de Seleção de Características (FS, do inglês *Feature Extration*) para escolher as características mais relevantes e não-redundantes. Para a classificação foi utilizada uma versão melhorada de SVM. A cada etapa, foram realizadas comparações com outras métricas mostrando maior precisão na detecção da existência de danos. O método foi testado em seis estruturas com acurácias de 79,8% até 99,7%.

Para mitigar a influência de um fator ambiental externo, o estudo de Finotti *et al.* (2017) utilizou as frequências naturais e medições de temperatura da estrutura como entrada para o método SVM. Para verificar a metodologia proposta, foram utilizados dados experimentais da Torre Gabbia, na Itália, que incluem registros do comportamento estrutural antes, durante e após um evento sísmico. Ao analisar os resultados da aplicação na torre, verificou-se que a técnica baseada nas frequências naturais foi eficiente em detectar mudanças estruturais, com resultados em concordância com a situação real da torre, permitindo identificar claramente os danos causados pelo evento sísmico. Entretanto, revela o desafio de se adquirir os dados de treinamento dos modelos em diferentes cenários estruturais.

Em uma tentativa de solucionar a questão dos dados danificados para treino, sob uma perspectiva baseada em modelos, Mariniello *et al.* (2021) produziu uma biblioteca de respostas estruturais "patológicas" e "não patológicas" virtuais usando modelos em elementos finitos calibrados por testes de laboratório e aplicou-a a uma metodologia de vibração atrelada a um método de aprendizado baseada em árvores de decisão. O método foi utilizado para identificar respostas anormais, indicar a localização e a severidade de dano. Sua abordagem foi capaz de localizar danos únicos, mas mostrou precisão reduzida ao lidar com dois ou mais elementos danificados. Em geral, a metodologia proposta classificou os danos aprendendo as propriedades de um conjunto

de dados simulados, expondo a desvantagem de que, se a modelagem do sistema estrutural não for realista o suficiente, a abordagem se torna inválida.

Assim, visando minimizar essas limitações, o trabalho de Zacharakis e Giagopoulos (2022) apresentou uma técnica de detecção de danos utilizando método dos elementos finitos (FEM, do inglês *Finite Element Method*), algoritmos meta-heurísticos e medições experimentais. O objetivo principal era facilitar uma estratégia de inspeção baseada em vibração de estruturas explorando informação de monitoramento. Como ponto de partida, desenvolveu-se um modelo FE a partir de um algoritmo de Otimização por Enxame de Partículas (PSO, do inglês *Particle Swarm Optimization*) que pode descrever a resposta dinâmica da estrutura saudável com precisão. O modelo FE otimizado, juntamente com medições experimentais de vibração da estrutura, compõem as entradas da detecção de danos, enquanto a saída é um modelo FE danificado que aproxima a resposta dinâmica da estrutura danificada do mundo real. Para tanto, uma área danificada é inserida no modelo FE ótimo, alterando os parâmetros de rigidez e massa para aproximar o efeito do dano físico. Após a convergência do procedimento de otimização, a área inserida destaca a região danificada da estrutura. Foram testadas duas estruturas: o chassi de um veículo e uma barra de material compósito. O maior erro na modelagem das estruturas testadas foram 2,38% e 2,14%, respectivamente. Ademais, os cenários de danos causaram mudanças na resposta dinâmica das estruturas físicas de 2,5% até 5,39%. A abordagem proposta foi capaz de encontrar a área danificada no total de 4 cenários estudados.

Com base em uma coletânea representativa de 22 casos de uso da ciência de dados em SHM, o livro de Cury *et al.* (2022) expõe diversos fatores críticos que impactam o desempenho dos algoritmos de identificação de danos em sistemas estruturais de grande escala. Esses desafios também são evidenciados nos demais estudos apresentados nesta seção. Primeiramente, no âmbito do *Big Data*, a alta dimensionalidade dos parâmetros monitorados representa um desafio na análise e processamento efetivo da vasta quantidade de dados envolvidos. Além disso, fatores ambientais e operacionais, como temperatura, umidade e tráfego, podem introduzir variabilidade e incerteza nas

medições, dificultando ainda mais o processo de identificação. A complexidade inerente das grandes estruturas também contribui para a dificuldade em detectar e localizar danos com precisão. Além disso, garantir a confiabilidade dos dados medidos é fundamental para obter resultados precisos e confiáveis. Outro problema significativo é a sensibilidade limitada das respostas estruturais globais a danos locais, o que pode dificultar a detecção precoce de anomalias sutis. Por fim, entende-se que o monitoramento eficaz da integridade estrutural requer a integração do conhecimento físico e de engenharia em algoritmos de aprendizado de máquina, a fim de possibilitar um processo de dados para decisões eficientes.

3.2 DETECÇÃO DE DANOS COM APRENDIZADO PROFUNDO (DL)

Pesquisas recentes na literatura utilizam aprendizado profundo (DL) para detectar danos estruturais, entendendo esse problema como uma tarefa de classificação de séries temporais (Sony *et al.*, 2022). Nessa perspectiva, as Redes Neurais Convolucionais (CNN) são as mais utilizadas, visto que se tornaram o estado da arte de DL para reconhecimento de padrões em imagens (Ciresan *et al.*, 2010). Entretanto, para o uso em sinais de vibração, adota-se comumente Redes Neurais Convolucionais de uma dimensão (1D CNN), visto que, neste caso, trata-se de vetores (sinais), e não matrizes (imagens). A vantagem dessa abordagem é a sua capacidade de extrair automaticamente as características sensíveis a danos dos sinais de aceleração através do treinamento de camadas de neurônios subsequentes, enquanto outros métodos convencionais de mineração de dados usam características escolhidas à mão, as quais podem ser uma opção não otimizada para uma estrutura em particular ou falhar em alcançar o mesmo nível de desempenho em outras estruturas.

Desse modo, a estratégia desenvolvida no trabalho de Abdeljaber *et al.* (2017) consistiu em uma metodologia baseada em 1D CNN para a localização de danos em juntas de uma estrutura de aço testada em laboratório, como mostrado na Figura 4. Esse estudo possui grande importância por introduzir um importante *benchmark* chamado Qatar University Grandstand Simulator (QUGS), o qual possibilitou diversas aplicações

de DL no campo do SHM desde então. Basicamente, o dano consiste em um afrouxamento dos parafusos que conectam a união entre vigas, simulando uma deterioração estrutural. O objetivo do algoritmo é identificar corretamente a posição de quaisquer articulações danificadas. Cada uma das 30 articulações equipadas com acelerômetros precisa de sua própria 1D CNN, que deve ser projetada e treinada especificamente para isso como parte da metodologia sugerida. Cada CNN_i tem a tarefa de avaliar a saúde de uma única articulação i usando apenas os dados brutos de aceleração registrados nessa articulação. Portanto, o método de detecção de danos proposto é considerado descentralizado, pois a rede de uma articulação não tem o auxílio das demais CNNs.

Figura 4 - Vista da estrutura de aço: QUGS.

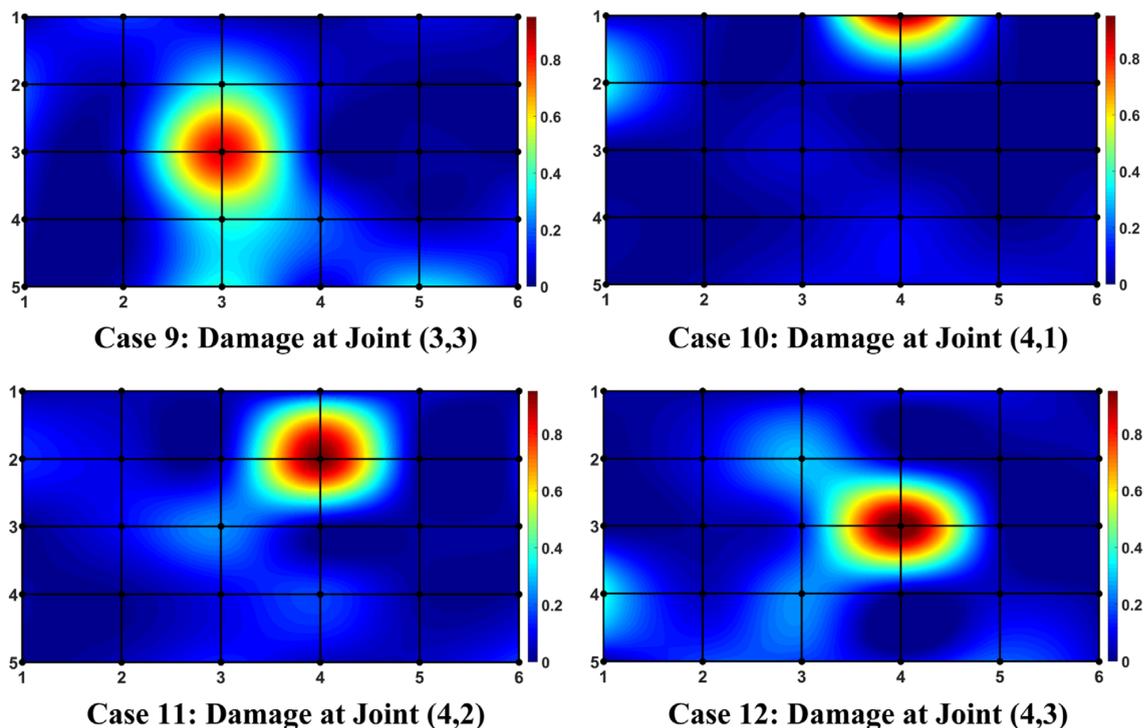


Fonte: Abdeljaber et al (2017).

O conjunto de dados para treino foi definido de modo que os dados intactos de uma determinada junta contenham os sinais medidos, enquanto as outras juntas estavam intactas e/ou também danificadas, de modo a minimizar a influência do efeito do dano de uma junta sobre as outras no momento da classificação.

O teste da metodologia é iniciado induzindo dano em um ou mais locais (ou ainda, mantendo intacto) e aplicando um vibrador com excitações aleatórias. Então, os sinais de aceleração de cada junta são medidos e, em seguida, cada sinal é dividido em amostras de intervalos menores. Posteriormente, as amostras são normalizadas entre -1 e 1 e usadas para alimentar a sua CNN correspondente de cada junta. Assim, para cada junta i , a probabilidade de dano é dada por $PoD_i = \frac{D_i}{T_i}$, onde T_i é o número total de amostras de intervalos de sinais processados pela CNN_i e D_i é o número de amostras classificadas como danificadas. Note que o resultado final é ponderado pelos resultados intermediários de cada amostra para maior representatividade dos dados. Desse modo, é esperado que o valor de PoD_i seja mais próximo de 0 em juntas intactas e mais próximo de 1 em juntas danificadas. Alguns dos resultados desse método são ilustrados na Figura 5.

Figura 5 - Parte dos resultados de localização usando CNN.



Fonte: Abdeljaber et al. (2017).

A fim de avaliar o desempenho das 30 CNNs que foram produzidas, o algoritmo foi testado em 24 cenários estruturais (1 caso intacto, 18 casos de dano único e 5 casos de dano duplo). O erro médio de classificação das 30 CNNs foi determinado como sendo de apenas 0,54% nos dados treinados. Os testes demonstram um excelente desempenho para SHM em tempo real e detecção de danos estruturais.

Utilizando a mesma base de dados QUGS e adicionalmente a de uma ponte em escala real, o trabalho de Sony *et al.* (2022) propôs uma arquitetura de rede neural que utiliza camadas de *Long Short-Term Memory* (LSTM). Estas são redes com *loops*, permitindo que as informações persistam. Dessa maneira, a técnica de DL é treinada e aplicada com excelente precisão para classificar sinais de séries temporais em níveis de danos múltiplos e em multiclases. Por comparação, naquela pesquisa, a implementação da nova abordagem por LSTM apresentou resultados de localização de dano superiores a uma CNN equivalente.

Os métodos de detecção de anomalias possuem desafios referentes à operação sob condições variáveis. A maioria dos métodos existentes é baseada em uma suposição estacionária e constante, podendo ser levada ao erro devido a efeitos externos ou a mudanças de utilização das estruturas. Com isso, Luo *et al.* (2018) propuseram um novo método que permite a detecção de falhas precoces em condições de trabalho variáveis no tempo utilizando DL que utiliza camadas de *Stacked Auto-Encoders* (AE) e *Back Propagation Neural Network* (BPNN). Um modelo foi desenvolvido com o propósito de automatizar a seleção das respostas de impulso a partir de grandes conjuntos de dados de vibração coletados durante o funcionamento em longo prazo. Com base na análise da similaridade das propriedades dinâmicas, um índice de integridade foi construído para indicar o processo lento e gradual de deterioração da estrutura estudada. O trabalho validou a metodologia em um estudo experimental envolvendo uma máquina de usinagem por controle numérico computadorizado (CNC), que não tem um padrão de funcionamento constante, permitindo a adequada validação da metodologia proposta.

De maneira semelhante, Finotti *et al.* (2021) explorou uma proposta híbrida de uso de um *Sparse Auto-Encoder* (SAE) associado ao SVM para caracterizar os sinais de vibração, dessa vez com o objetivo de detectar anomalias em estruturas de engenharia civil. O SAE foi empregado para extrair características de maneira não-supervisionada diretamente das acelerações no domínio do tempo, e essas informações foram utilizadas como entradas para treinar um modelo supervisionado de classificação baseado no tradicional SVM. Inicialmente, a metodologia proposta foi testada em respostas estruturais de um modelo numérico de uma viga simplesmente apoiada, sujeita a diferentes níveis de dano. Em seguida, para verificar a eficácia do SAE/SVM em uma estrutura real, foram analisados dados experimentais do viaduto Várzea Nova em João Pessoa, Brasil. Neste estudo, foram realizados testes dinâmicos no viaduto antes e depois de um procedimento de reforço. O método alcançou mais de 99% de acurácia em ambos os casos.

O estudo de Alazzawi e Wang (2022) propôs uma Rede Residual Profunda (DRN, do inglês *Deep Residual Network*) para extrair e aprender automaticamente as características dos sinais brutos de aceleração. Um algoritmo de otimização Bayesiano foi utilizado para melhorar a eficiência dessa rede neural tanto em questão de precisão, quanto na escolha de parâmetros. O método sugerido foi capaz de efetuar detectar, localizar e quantificar o dano. Aplicações numéricas e experimentais foram realizadas em dois pórticos e uma ponte, alcançando precisão de 100% nos dados de teste empregados.

Particularmente, os métodos DL funcionam excepcionalmente bem, mas, como limitação, requerem uma grande quantidade de dados para operar. Para contornar esse problema, o estudo recente de Chamangard *et al.* (2022) propôs uma técnica baseada em transferência de aprendizado (TL, do inglês *Transfer Learning*) para lidar com essa questão. O trabalho foi dividido em duas etapas. A primeira etapa tenta criar uma CNN compacta que, quando recebe dados suficientes de um modelo numérico, pode identificar com precisão os danos estruturais. A segunda parte examina a questão dos dados de treinamento em quantidades insuficientes, *i.e.*, inadequados ao SHM de estruturas experimentais e do mundo real. Para resolver esse problema, o TL é empregado. A rede

neural final obtém todo o conhecimento de uma CNN compacta treinada previamente em outra estrutura, que é usada como fonte. Assim, a informação extra obtida por esta rede pode ser utilizada para compensar a falta de dados. Ou seja, quando se inicia a aplicação em uma nova estrutura, o uso de TL tende a diminuir o volume de dados de treino necessário. O método foi avaliado somente quanto à classificação da existência ou não de dano (SHM nível I). A CNN compacta pode atingir 100% de precisão quando os dados estão disponíveis para treinamento. Além disso, para o caso de dados insuficientes, o uso de uma rede compacta, bem como o aprendizado de transferência, proporciona melhorias consideráveis (cerca de 95%) na precisão da detecção de danos.

Uma alternativa ao grande volume de dados de treino foi elaborada na pesquisa de Luleci, Catbas e Avci (2023a) baseada nas Redes Adversariais Generativas (GAN, do inglês *Generative Adversarial Network*) Convolucionais Profundas de Wasserstein Unidimensionais usando Penalidade de Gradiente, a qual foi denominada 1-D WDCGAN-GP, para gerar dados sintéticos extras de aceleração do estado danificado da estrutura, ou seja, dados de dano que não foram adquiridos experimentalmente. A estratégia consiste fundamentalmente em duas redes neurais: uma chamada de geradora, que cria sinais de vibração, enquanto a outra, a discriminadora, avalia a sua autenticidade. Durante certo momento do aprendizado, a geradora passa a criar réplicas com comportamentos indistinguíveis das originais. A partir disso, os autores validaram os conjuntos de dados gerados com métodos quantitativos e qualitativos.

Em um avanço mais recente, Luleci, Catbas e Avci (2023b) empregaram uma variante inovadora do modelo GAN, o 1-D CycleWDCGAN-GP. Este modelo não apenas aprende a gerar amostras de dados semelhantes dentro de um único domínio, mas também domina o mapeamento complexo entre dois domínios de dados – não danificados e danificados. Um aspecto fascinante desse modelo é a sua capacidade de obter respostas “saudáveis” de uma estrutura e traduzi-las em respostas danificadas, preenchendo a lacuna entre os dois domínios. Embora as comparações no domínio do tempo tenham demonstrado excelente desempenho, há espaço para aprimoramento adicional nas comparações no domínio da frequência, possivelmente por meio de

treinamento mais diversificado. Para realizar essa proposta, os pesquisadores compilaram uma coleção de conjuntos de dados de resposta dinâmica de uma estrutura de aço, abrangendo conjuntos de dados danificados (afrouxamento de parafusos da junta) e não danificados, para treinar o modelo variante CycleGAN. Posteriormente, eles empregaram o conjunto de dados não danificado para tradução no domínio danificado e vice-versa. Os indicadores de desempenho usados no processo de avaliação garantiram que os resultados gerados em ambos os domínios se assemelhavam aos domínios verdadeiros, afirmando a eficácia do modelo na geração de dados autênticos.

Apesar de seus esforços, o resultado da tradução de domínio das juntas de teste foi limitado, pois apesar de conseguir traduzir o domínio para a junta treinada, não tinha o mesmo sucesso com os domínios das outras juntas. Assim, em um estudo inovador, Luceli, Avci e Catbas (2023c) investigaram uma versão melhorada do modelo CycleGAN para obter maior precisão. Algumas das melhorias envolveram: um procedimento de treinamento mais abrangente para aumentar o conhecimento de domínio do modelo e a função de perda total do gerador foi complementada com uma nova perda baseada no domínio de frequência para melhor capturar o conteúdo de frequência dos dados. Este estudo inovador abriu possibilidades empolgantes para o monitoramento de integridade estrutural, com aplicações potenciais na previsão e simulação de respostas estruturais sob condições variadas. A tradução bem-sucedida de respostas de domínios saudáveis para domínios não saudáveis pode desempenhar um papel fundamental no avanço da compreensão do comportamento estrutural e, finalmente, no aprimoramento das medidas de segurança em infraestruturas críticas.

3.3 DISCUSSÃO DA INTERPRETABILIDADE DOS MODELOS

Conforme observado, as técnicas de ML e DL têm sido aplicadas com sucesso em diversos casos reais. No entanto, os algoritmos adotados nesses estudos para estruturas de monitoramento de integridade com base em vibrações (VSHM, do inglês *Vibration Structural Health Monitoring*) são frequentemente chamados de modelos "caixas-pretas" por oferecerem poucas informações sobre o processo de tomada de decisão (ARRIETA *et*

al., 2020). A falta de interpretabilidade e compreensão sobre como esses modelos detectam alterações na integridade estrutural e como utilizam as características obtidas dos dados para fazer previsões é uma das razões que dificultam a adoção generalizada dessas técnicas em aplicações industriais. Possibilitar a interpretabilidade em metodologias de VSHM baseadas em ML/DL pode fornecer evidências importantes para uma tomada de decisão confiável em aplicações de monitoramento de integridade estrutural. Em particular, a capacidade de distinguir entre anomalias causadas pela influência de variáveis operacionais externas ou danos reais na estrutura pode ajudar a reduzir falsos alarmes e aprimorar a precisão geral do sistema.

Segundo Arrieta *et al.* (2020), para definir os modelos de IA explicáveis, surgiram dois grupos principais de abordagens: (a) modelos transparentes, que oferecem explicabilidade direta por meio do próprio modelo ou de sua estrutura, incluindo árvores de decisão, modelos Bayesianos, modelos para k-vizinhos mais próximos e modelos de regressão logística ou linear. Alguns destes, já mencionados em aplicações no presente artigo. (b) Explicabilidade pós-hoc, dividida em métodos agnósticos ao modelo (*model-agnostic* ou *generalistas*) e métodos específicos do modelo (*model-specific*), permite a explicabilidade subsequente dos modelos de ML. Métodos agnósticos ao modelo oferecem explicações usando ferramentas gerais aplicáveis a uma ampla variedade de algoritmos de ML. Por outro lado, os métodos específicos do modelo concentram-se em fornecer explicações para resultados obtidos por algoritmos de ML específicos, limitados a alguns algoritmos como redes neurais artificiais e máquinas de vetores de suporte.

Sob essa conjuntura, Amin *et al.* (2023) enfrentaram o desafio de interpretar modelos CNN “caixas-pretas” no contexto do monitoramento de condições para turbinas eólicas sob diversas condições de carga, especialmente cenários de vento turbulento. Para lançar luz sobre as previsões feitas pelo classificador, eles empregaram técnicas de explicações agnósticas de modelos interpretáveis locais (*Local Interpretable Model-Agnostic Explanations* - LIME). Ao fazer isso, eles desenvolveram um classificador interpretável baseado em física, oferecendo informações valiosas sobre o raciocínio por trás das decisões do modelo. A pesquisa se concentrou na detecção de falhas nos componentes

rotativos da caixa de engrenagens, que deixam assinaturas de vibração distintas mensuráveis por meio de acelerômetros. Em seus experimentos, as falhas foram detectadas com sucesso.

O estudo de Brusa *et al.* (2023) usou uma técnica de interpretabilidade chamada *SHapley Additive exPlanation* (SHAP) com o objetivo para identificar as características mais relevantes na detecção e classificação de falhas em programas de monitoramento de condições para máquinas rotativas. Os pesquisadores investigaram especificamente rolamentos de tamanho médio de interesse industrial, coletando dados de vibração para diferentes estados de saúde em um equipamento de teste de rolamentos industriais disponível no Laboratório de Engenharia Mecânica do Politécnico de Turim. Os modelos de diagnóstico SVM e kNN (do inglês, *k-Nearest Neighbour*) foram explicados utilizando o SHAP e alcançaram acurácias superiores a 98,5% para ambos os modelos, ao utilizá-lo como critério para seleção das características.

As técnicas baseadas em IA discutidas neste artigo têm as suas características resumidas no Quadro 1. Ademais, entende-se como uma limitação geral dos métodos de detecção de dano baseados em vibração a disposição dos sensores instalados na estrutura. Dessa maneira, se o dano ocorrer em um local afastado dos sensores, não seria possível detectá-lo. Entretanto, essa desvantagem se torna cada dia menos expressiva com o desenvolvimento de tecnologias de sensores, tornando-os mais baratos e possibilitando o seu uso em maior quantidade. Adicionalmente, diversas pesquisas recentes visam otimizar o posicionamento de sensores (Tan; Zhang, 2020) para maior eficiência no processo de detecção.

Quadro 1 – Revisão de métodos de vibração de detecção de dano baseado em AI.

| Referência | Abordagem | Estruturas testadas | Tipo de dano | Estratégias | Nível de SHM |
|---------------------|-----------|-------------------------|---|---------------------------------------|--------------|
| Alves e Cury (2021) | DS | Viga, pórticos e ponte. | Furos, remoção de parafusos e rachaduras. | Características extraídas manualmente | I e II |

| | | | | | |
|--|----|---|---|--|-------------|
| Alves e Cury (2023) | DS | Viga, pórticos e pontes | Furos, rachaduras assentamento de fundação | Características extraídas manualmente e FS | I, II e III |
| Ghiasi, Ghasemi e Chan (2020) | ML | Pórticos, barras e ponte. | Não linearidades, adição de massa e retirada de intertravamentos. | FS e SVM | I |
| Finotti, Barbosa, Cury e Gentile (2017) | ML | Torre Gabbia (Itália) | Terremoto | SVM | I |
| Mariniello et al (2021) | ML | Pórtico, treliça e QUGC. | Retirada de intertravamento e afrouxamento de parafusos. | DT | I e II |
| Gui et al (2017) | ML | Pórtico. | Não-linearidades. | AR, SVM, GA, PSO | I e II |
| Zacharakis e Giagopoulos (2022) | ML | Chassi de veículo e barra de material compósito. | Massa adicional e diminuição de rigidez. | PSO | I e II |
| Brusa <i>et al.</i> (2023) | ML | Máquinas rotatórias | Falhas no rolamento | SVM e kNN | I |
| Abdeljaber et al (2017) | DL | QUGS. | Afrouxamento de parafusos. | CNN | I e II |
| Luo <i>et al.</i> (2018) | DL | CNC | Falha precoce | Stacked AE, BPNN | I |
| Finotti, Barbosa, Cury e Pimentel (2021) | DL | Viga numérica e viaduto Várzea Nova em João Pessoa (Brasil) | Redução do módulo de elasticidade e reforço estrutural | SAE e SVM | I |
| Sony et al (2022) | DL | Ponte e QUGS. | Assentamento de fundação e afrouxamento de parafusos. | LSTM | I, II e III |
| Alazzawi e Wang (2022) | DL | Pórtico e Ponte. | Retirada de intertravamento e Cortes. | DRN | I, II e III |

| | | | | | |
|---|----|------------------|--------------------------------------|----------|---|
| Chamangard (2022) | DL | QUGS e pontes. | Trincas e afrouxamento de parafusos. | CNN e TL | I |
| Luceli, Avci e Catbas (2023a) (2023b) (2023c) | DL | QUGS | Afrouxamento de parafusos. | CycleGAN | I |
| Amin <i>et al.</i> (2023) | DL | Turbinas eólicas | Falhas nas engrenagens | CNN | I |

Fonte: Elaboração própria.

4. CONSIDERAÇÕES FINAIS

Esta pesquisa buscou apresentar estudos relevantes e recentes acerca das aplicações de AI no âmbito do SHM, utilizando unicamente dados de vibração para a detecção de danos estruturais. O presente trabalho se ateve a apresentar as diferenças entre abordagens de ML e DL, bem como as suas respectivas vantagens e limitações. Outrossim, destacou-se como os pesquisadores estão lidando atualmente com esses fatores adversos, o que elucida possibilidades de lacunas para trabalhos futuros. Note que em uma primeira abordagem ML, é necessário extrair características manualmente a partir dos sinais de aceleração, enquanto a segunda abordagem (DL) realiza a extração de maneira automática. Entende-se que diversos métodos implementados com AI foram bem-sucedidos quanto aos paradigmas de identificação da existência de dano, localização e/ou quantificação os quais se propuseram a solucionar.

No entanto, a dificuldade em coletar e rotular amostras válidas frequentemente leva a um pequeno conjunto de dados na identificação prática de danos, reduzindo o desempenho do modelo treinado. Para essa questão, foi relatada a implementação de modelos em elementos finitos, aprendizado por transferência e até redes neurais generativas. Além disso, modelos convencionais de aprendizado profundo muitas vezes carecem de um certo grau de interpretabilidade física. Tais desafios foram mencionados e discutidos como os pesquisadores têm lidado para eliminar ou mitigar essas limitações, por exemplo o uso de técnicas de IA explicáveis como LIME e SHAP.

Um aspecto comumente observado na literatura é o particionamento dos sinais de aceleração para gerar as amostras a serem treinadas pelo classificador com uma representatividade significativa. Outra similaridade encontrada é a recorrência das estruturas testadas. Isso se deve ao fato de serem estruturas do tipo *benchmark*, bem conhecidas e com dados disponíveis à comunidade científica. A seguir, são listadas as bases de dados mais comumente utilizadas em artigos dessa área e notadas pelos autores:

- IASC-ASCE (Johnson *et al.*, 2004);
- Viaduto Z24 (Maeck; De Roeck, 2003);
- Pórtico de três andares - Laboratório Nacional de Los Alamos (Figueiredo *et al.*, 2009);
- Ponte Tianjin Yonghe (Li *et al.*, 2012);
- QUGS (Abdeljaber *et al.*, 2017) ilustrado na Figura 5.

Assim, a utilização dessas bases possibilita a fácil comparação com outras metodologias de detecção, além de apresentar maior credibilidade e confiabilidade à pesquisa, pois já foram validadas anteriormente. Portanto, os autores recomendam, como boa prática, a utilização de alguma das estruturas listadas em trabalhos futuros que investiguem novas estratégias de SHM. Entretanto, novos dados de vibração experimentais de estruturas específicas são sempre necessários e relativamente difíceis de serem encontrados, como o caso de estruturas *offshore*, aeroespaciais, turbinas de geração de energia eólica, entre outras, o que revela uma ampla gama de setores da indústria ainda pouco explorados.

5. AGRADECIMENTOS

Os autores deste trabalho agradecem à UFJF (Universidade Federal de Juiz de Fora), à FAPEMIG (Fundação de Amparo à Pesquisa no Estado de Minas Gerais, projeto

PPM-00001-18) e ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico, projetos 303982/2022-5 e 402533/2023-2) pelo auxílio financeiro.

REFERÊNCIAS

ABDELJABER, O.; AVCI, O.; KIRANYAZ, S.; GABBOUJ, M.; INMAN, D. J. **Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks**. *Journal of Sound and Vibration*, v. 388, p. 154-170, 2017. DOI:10.1016/j.jsv.2016.10.043

ALAZZAWI, Osama; WANG, Dansheng. **A novel structural damage identification method based on the acceleration responses under ambient vibration and an optimized deep residual algorithm**. *Structural Health Monitoring*, v. 21, n. 6, p. 2587-2617, 2022. DOI:10.1177/14759217211065009

ALVES, Victor; CURY, Alexandre. **A fast and efficient feature extraction methodology for structural damage localization based on raw acceleration measurements**. *Structural Control and Health Monitoring*, v. 28, n. 7, p. e2748, 2021. DOI:10.1002/stc.2748

ALVES, Victor; CURY, Alexandre. **An automated vibration-based structural damage localization strategy using filter-type feature selection**. *Mechanical Systems and Signal Processing*, v. 190, p. 110145, 2023. DOI:10.1016/j.ymssp.2023.110145

AMIN, A.; BIBO, A.; PANYAM, M.; TALLAPRAGADA, P. **Wind Turbine Gearbox Fault Diagnosis Using Cyclostationary Analysis and Interpretable CNN**. *Journal of Vibration Engineering & Technologies*, p. 1-11, 2023. DOI: 10.1007/s42417-023-00937-1

ARRIETA, Alejandro Barredo *et al.* **Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI**. *Information fusion*, v. 58, p. 82-115, 2020. DOI: 10.1016/j.inffus.2019.12.012

AVCI, O.; ABDELJABER, O.; KIRANYAZ, S.; HUSSEIN, M.; GABBOUJ, M.; INMAN, D. J. **A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications**. *Mechanical systems and signal processing*, v. 147, p. 107077, 2021. DOI:10.1016/j.ymssp.2020.107077

AZIMI, Mohsen; ESLAMLLOU, Armin Dadras; PEKCAN, Gokhan. **Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review**. *Sensors*, v. 20, n. 10, p. 2778, 2020. DOI: 10.3390/s20102778

BRUSA, E.; CIBRARIO, L.; DELPRETE, C.; DI MAGGIO, L. G. **Explainable AI for machine fault diagnosis: understanding features' contribution in machine learning models for industrial condition monitoring**. *Applied Sciences*, v. 13, n. 4, p. 2038, 2023. DOI: 10.3390/app13042038

CHAMANGARD, M.; GHODRATI AMIRI, G.; DARVISHAN, E.; RASTIN, Z. **Transfer Learning for CNN-Based Damage Detection in Civil Structures with Insufficient Data.** Shock and Vibration, v. 2022, 2022. DOI: 10.1155/2022/3635116

CIREŞAN, D. C.; MEIER, U.; GAMBARDELLA, L. M.; SCHMIDHUBER, J. **Deep, big, simple neural nets for handwritten digit recognition.** Neural computation, v. 22, n. 12, p. 3207-3220, 2010. DOI: 10.1162/NECO_a_00052

CURY, Alexandre; CRÉMONA, Christian; DIDAY, Edwin. **Application of symbolic data analysis for structural modification assessment.** Engineering Structures, v. 32, n. 3, p. 762-775, 2010. DOI:10.1016/j.engstruct.2009.12.004

CURY, Alexandre; RIBEIRO, Diogo; UBERTINI, Filippo; TODD, Michael D. **Structural health monitoring based on data science techniques.** Springer, 2022. DOI:10.1007/978-3-030-81716-9

DANESHJOO, Z.; SHOKRIEH, M. M.; FAKOOR, M. **A micromechanical model for prediction of mixed mode I/II delamination of laminated composites considering fiber bridging effects.** Theoretical and Applied Fracture Mechanics, v. 94, p. 46-56, 2018. DOI: 10.1016/j.tafmec.2017.12.002

DONG, Chuan-Zhi; CATBAS, F. Necati. **A review of computer vision-based structural health monitoring at local and global levels.** Structural Health Monitoring, v. 20, n. 2, p. 692-743, 2021. DOI: 10.1177/1475921720935585

FINOTTI, R. P.; DE SOUZA BARBOSA, F.; CURY, A. A.; GENTILE, C. **A novel natural frequency-based technique to detect structural changes using computational intelligence.** Procedia engineering, v. 199, p. 3314-3319, 2017. DOI:10.1016/j.proeng.2017.09.438

FINOTTI, R. P.; BARBOSA, F. D. S.; CURY, A. A.; PIMENTEL, R. L. **Numerical and Experimental Evaluation of Structural Changes Using Sparse Auto-Encoders and SVM Applied to Dynamic Responses.** Applied Sciences, v. 11, n. 24, p. 11965, 2021. DOI:10.3390/app112411965

FIGUEIREDO, E.; PARK, G.; FIGUEIRAS, J.; FARRAR, C.; WORDEN, K. **Structural health monitoring algorithm comparisons using standard data sets.** Los Alamos National Lab.(LANL), Los Alamos, NM (United States), 2009. DOI: 10.2172/961604

GHIASI, Ramin; GHASEMI, Mohammad Reza; CHAN, Tommy HT. **Optimum feature selection for SHM of benchmark structures using efficient AI mechanism.** Smart Struct. Syst, v. 27, p. 623-640, 2021. DOI: 10.12989/sss.2021.27.4.623

GUI, G.; PAN, H.; LIN, Z.; LI, Y.; YUAN, Z. **Data-driven support vector machine with optimization techniques for structural health monitoring and damage detection.** KSCE Journal of Civil Engineering, v. 21, p. 523-534, 2017. DOI: 10.1007/s12205-017-1518-5

- JOHNSON, E. A.; LAM, H. F.; KATAFYGIOTIS, L. S.; BECK, J. L. **Phase I IASC-ASCE structural health monitoring benchmark problem using simulated data.** Journal of engineering mechanics, v. 130, n. 1, p. 3-15, 2004. DOI: 10.1061/(ASCE)0733-9399(2004)130:1(3)
- Li, H.; Li, S.; Ou, J.; Li, H. **Reliability assessment of cable-stayed bridges based on structural health monitoring techniques.** Structure and Infrastructure Engineering, v. 8, n. 9, p. 829-845, 2012. DOI: 10.1080/15732479.2010.496856
- LULECI, Furkan; CATBAS, F. Necati; AVCI, Onur. **Generative adversarial networks for labeled acceleration data augmentation for structural damage detection.** Journal of Civil Structural Health Monitoring, v. 13, n. 1, p. 181-198, 2023a.
- LULECI, Furkan; AVCI, Onur; CATBAS, F. Necati. **Improved undamaged-to-damaged acceleration response translation for Structural Health Monitoring.** Engineering Applications of Artificial Intelligence, v. 122, p. 106146, 2023c. DOI: 10.1016/j.engappai.2023.106146
- LULECI, Furkan; CATBAS, F. Necati; AVCI, Onur. **CycleGAN for undamaged-to-damaged domain translation for structural health monitoring and damage detection.** Mechanical Systems and Signal Processing, v. 197, p. 110370, 2023b. DOI:10.1016/j.ymsp.2023.110370
- LUO, B; WANG, H.; LIU, H.; LI, B.; PENG, F. **Early fault detection of machine tools based on deep learning and dynamic identification.** IEEE Transactions on Industrial Electronics, v. 66, n. 1, p. 509-518, 2018. DOI: 10.1109/TIE.2018.2807414
- MARINIELLO, G.; PASTORE, T.; MENNA, C.; FESTA, P.; ASPRONE, D. **Structural damage detection and localization using decision tree ensemble and vibration data.** Computer-Aided Civil and Infrastructure Engineering, v. 36, n. 9, p. 1129-1149, 2021. DOI:10.1111/mice.12633
- MEIXEDO, A.; SANTOS, J.; RIBEIRO, D.; CALÇADA, R.; TODD, M. **Damage detection in railway bridges using traffic-induced dynamic responses.** Engineering Structures, v. 238, p. 112189, 2021. DOI:10.1016/j.engstruct.2021.112189
- MORALES, Fabricio A. O.; CURY, Alexandre A. Analysis of thermal and damage effects over structural modal parameters. Structural engineering and mechanics: An international journal, v. 65, n. 1, p. 43-51, 2018. DOI:10.12989/sem.2018.65.1.043
- MAECK, Johan; DE ROECK, Guido. Damage assessment using vibration analysis on the Z24-bridge. Mechanical Systems and Signal Processing, v. 17, n. 1, p. 133-142, 2003. DOI: 10.1006/mssp.2002.1550

MOUGHTY, John J.; CASAS, Joan R. A state of the art review of modal-based damage detection in bridges: Development, challenges, and solutions. *Applied Sciences*, v. 7, n. 5, p. 510, 2017. DOI: 10.3390/app7050510

RYTTER, A. Vibrational based inspection of civil engineering structures. 1993. Tese de doutorado - Denmark: Department of Building Technology and Structural, Aalborg University, Aalborg, 1993.

SONY, S.; GAMAGE, S.; SADHU, A.; SAMARABANDU, J. Vibration-based multiclass damage detection and localization using long short-term memory networks. *Structures*, v. 35, p. 436-451, 2022. DOI: 10.1016/j.istruc.2021.10.088

TAN, Yi; ZHANG, Limao. **Computational methodologies for optimal sensor placement in structural health monitoring: A review**. *Structural Health Monitoring*, v. 19, n. 4, p. 1287-1308, 2020. DOI: 10.1177/1475921719877579

TIAN, W.; CHENG, X.; LIU, Q.; YU, C.; GAO, F.; CHI, Y. **Meso-structure segmentation of concrete CT image based on mask and regional convolution neural network**. *Materials & Design*, v. 208, p. 109919, 2021. DOI:10.1016/j.matdes.2021.109919

WANG, Teng; LU, Guoliang; YAN, Peng. **A novel statistical time-frequency analysis for rotating machine condition monitoring**. *IEEE Transactions on Industrial Electronics*, v. 67, n. 1, p. 531-541, 2019. DOI: 10.1109/TIE.2019.2896109

YUAN, Fuh-Gwo (Ed.). **Structural health monitoring (SHM) in aerospace structures**. Woodhead Publishing, 2016. DOI: 10.1016/C2014-0-00994-X

ZACHARAKIS, Ilias; GIAGOPOULOS, Dimitrios. **Vibration-Based Damage Detection Using Finite Element Modeling and the Metaheuristic Particle Swarm Optimization Algorithm**. *Sensors*, v. 22, n. 14, p. 5079, 2022. DOI: 10.3390/s22145079

ZHANG, Yixiao; LEI, Ying. **Data anomaly detection of bridge structures using convolutional neural network based on structural vibration signals**. *Symmetry*, v. 13, n. 7, p. 1186, 2021. DOI: 10.3390/sym13071186