

USO DE AUTOCODIFICADORES VARIACIONAIS PARA MONITORAMENTO DE INTEGRIDADE ESTRUTURAL DETECÇÃO E QUANTIFICAÇÃO DE ALTERAÇÕES ESTRUTURAIS UTILIZANDO AUTOCODIFICADORES VARIACIONAIS COMBINADOS COM CARTAS DE CONTROLE T²

USE OF VARIATIONAL AUTOENCODERS FOR STRUCTURAL HEALTH MONITORING DETECTION AND QUANTIFICATION OF STRUCTURAL CHANGES USING VARIATIONAL AUTOENCODERS COMBINED WITH T² CONTROL CHARTS

Marcos Rezende Spínola Neto¹
Rafaelle Piazzaroli Finotti²
Flávio de Souza Barbosa²
Alexandre Abrahão Cury³

DOI: 10.34019/2179-3700.2024.v24.46198

ENVIADO EM:

APROVADO EM:

RESUMO

O monitoramento da integridade estrutural (SHM) tem como objetivo garantir a segurança e a confiabilidade de infraestruturas civis. Autocodificadores, modelos de aprendizado de máquina não supervisionado, mostram-se promissores para o SHM ao aprender características dos dados e reduzir a dimensionalidade. No entanto, estudos abrangentes comparando modelos de autocodificadores no SHM são escassos. Este estudo investiga a eficácia do autocodificador variacional (VAE), combinado às Cartas de Controle T², para detectar e quantificar mudanças estruturais em três estruturas de engenharia civil. Sinais de aceleração coletados por acelerômetros são utilizados como entrada para o autocodificador, com o objetivo de realizar uma classificação não supervisionada. Os dados das camadas latentes geradas pelo VAE são aplicados na análise com a ferramenta estatística T² e os valores obtidos são comparados entre os subgrupos de sinais para identificar alterações estruturais. O estudo conclui que o modelo VAE combinado com o T² é eficaz tanto para identificar quanto

¹Universidade Federal de Juiz de Fora, <http://lattes.cnpq.br/1253246928328841>, marcos.neto@estudante.ufjf.br

²Universidade Federal de Juiz de Fora, <http://lattes.cnpq.br/5335487988375951>, rafaelle.finotti@gmail.com, <http://lattes.cnpq.br/3967943593612229>, flavio.barbosa@ufjf.br

³Orientadores do Projeto de IC. Professor do Departamento de Engenharia Civil da UFJF. Endereço profissional: Universidade Federal de Juiz de Fora, Faculdade de Engenharia. <http://lattes.cnpq.br/1092810690505352>, alexandre.cury@ufjf.br

para quantificar alterações nas estruturas. O desenvolvimento contínuo dessa técnica pode contribuir para avanços no SHM, promovendo maior segurança, redução de custos e durabilidade a longo prazo em estruturas civis.

Palavras-chave: Monitoramento de Integridade Estrutural. Detecção de danos. Autocodificador Variacional. SHM. Aprendizado de máquina.

ABSTRACT

Structural Health Monitoring (SHM) aims to ensure the safety and reliability of civil infrastructures. Autoencoders, unsupervised machine learning models, have shown promise for SHM by learning data features and reducing dimensionality. However, comprehensive studies comparing autoencoder models in SHM are scarce. This study investigates the effectiveness of the Variational Autoencoder (VAE), combined with T^2 Control Chart, to detect and quantify structural changes in three civil engineering structures. Acceleration signals collected by accelerometers were used as input for the autoencoder to perform unsupervised classification. The latent layer data generated by the VAE were applied to T^2 analysis, and the obtained values were compared between signal subgroups to identify structural changes. The study concludes that the VAE model combined with T^2 is effective in both identifying and quantifying changes in structures. The ongoing development of this technique can contribute to advancements in SHM, promoting greater safety, cost reduction, and long-term durability of civil engineering structures.

Keywords: Structural Health Monitoring. Damage Detection. Variational Autoencoder. SHM. Machine Learning.

1 INTRODUÇÃO

A integridade estrutural e a segurança dos usuários estão entre as maiores preocupações dos engenheiros ao longo do ciclo de vida das construções. Para minimizar problemas decorrentes de desgaste, envelhecimento ou uso indevido, o monitoramento contínuo das condições estruturais é indispensável para detectar anomalias precocemente, principalmente em grandes edifícios, pontes e viadutos. Embora inspeções visuais apresentem limitações, o monitoramento da integridade estrutural (SHM) se destaca como uma solução promissora para a identificação de falhas estruturais (Sousa et al, 2021).

A implementação do SHM pode seguir abordagens supervisionadas ou não supervisionadas, sendo esta última preferível pois, em estruturas reais, apenas o estado atual da estrutura é geralmente conhecido, sem que outros comportamentos estruturais de referência estejam disponíveis. Portanto, é recomendável definir um modelo robusto e não supervisionado para a avaliação eficaz de danos estruturais em construções reais.

Dentre as diferentes metodologias para identificação de danos estruturais, métodos que utilizam diretamente dados brutos vibracionais estão se tornando cada vez mais utilizados (Avci et al, 2021). Essas abordagens podem detectar alterações estruturais processando sinais adquiridos da estrutura, extraindo características relevantes e fazendo classificações com custos computacionais relativamente baixos (Alves e Cury, 2023).

Um autocodificador é um modelo de aprendizado não supervisionado projetado para reconstruir dados de entrada e reduzir a dimensionalidade. Ele reduz as informações em uma representação latente compacta e, em seguida, busca reconstruir os dados originais dessa forma reduzida. Existem variações específicas, como os autocodificadores variacionais, que incorporam uma abordagem probabilística para modelar a distribuição de dados. Os autocodificadores são reconhecidos não apenas por sua capacidade de lidar com grandes volumes de dados, mas também por fornecer soluções robustas, especialmente em problemas não lineares, como detecção de anomalias estruturais.

Nesse contexto, este artigo tem como objetivo analisar a eficácia de um autocodificador variacional para identificar e quantificar alterações estruturais. Para avaliar a metodologia, três estruturas são consideradas: (i) um pórtico biengastado ensaiado no Laboratório de Imagens e Sinais da Universidade Federal de Juiz de Fora (UFJF), submetido a cinco cenários diferentes de danos (Finotti et al, 2023); (ii) um pórtico de aço de quatro andares localizado no Laboratório de Engenharia Sísmica da Universidade de Colúmbia Britânica (UBC), que sofreu dois tipos de alterações - remoção de contraventamentos e afrouxamento de parafusos (Dyke et al, 2003 e Mou et al, 2015); (iii) a Ponte Z24, que ligava as cidades de Koppigen e Utzenstorf na Suíça; essa ponte foi submetida a vários testes de danos progressivos simulando situações reais de degradação em diferentes condições de temperatura para fins científicos (Peeters e De Roeck, 2001 e Teughels e De Roeck, 2004). Para todas as aplicações, um indicador de danos foi criado a partir da ferramenta estatística denominada Carta de Controle T^2 (Montgomery, 2009), que foi calculado usando os dados das camadas latentes dos autocodificadores, permitindo a identificação de danos em todas as estruturas analisadas.

2 FUNDAMENTAÇÃO TEÓRICA

A identificação de alterações estruturais é um desafio complexo que requer a aplicação de técnicas avançadas de processamento de sinais e estatísticas. Este artigo propõe uma metodologia robusta e eficiente, composta por duas etapas principais para

abordar essa tarefa. Primeiramente, foi utilizado o Autocodificador Variacional (VAE) para extrair e reduzir as características dos sinais dinâmicos monitorados. Na segunda etapa, foi aplicada a Carta de Controle T de Shewhart (T^2), uma ferramenta gráfica estatística amplamente utilizada para monitorar processos multivariados, permitindo a detecção de mudanças estruturais ao comparar os parâmetros extraídos das camadas latentes do VAE com limites estatisticamente estabelecidos. Essa combinação de técnicas proporciona uma abordagem eficaz para a detecção de anomalias e mudanças nos sinais analisados, facilitando a identificação precoce de problemas estruturais.

Uma breve discussão dessas duas etapas é apresentada nas seções a seguir. Mais detalhes estão disponíveis em Montgomery et al (2009) e Goodfellow (2016).

2.1 Autocodificador Variacional (VAE)

O VAE é uma variação do autocodificador que se destaca pela capacidade de extrair características significativas dos sinais analisados. Esses modelos têm sido amplamente adotados em diversas aplicações, desde a geração de imagens até a detecção de danos estruturais, podendo ser usadas as camadas latentes nessa detecção. O VAE utiliza a distribuição normal para modelar a distribuição dos dados das camadas latentes, introduzindo uma variabilidade estocástica na codificação dos sinais. Durante o treinamento, o VAE é otimizado para minimizar a diferença, ou divergência, entre os sinais de entrada originais (\mathbf{x}) e os sinais reconstruídos (\mathbf{x}'), ao mesmo tempo que mantém a distribuição dos dados das camadas latentes próxima de uma distribuição normal.

O processo de treinamento do VAE utilizou o Erro Médio Quadrático (MSE) como a função de perda. O MSE é preferido por sua capacidade de avaliar a precisão da reconstrução ao calcular a média das diferenças quadradas entre os valores previstos y_i gerados pelo VAE e os valores reais de entrada x_i , conforme definido na Equação (1). Minimizar o MSE durante o treinamento aprimora a capacidade do modelo de reduzir efetivamente a discrepância entre a entrada e a saída reconstruída, melhorando, assim, sua capacidade de capturar características essenciais e significativas dos dados.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2 \quad (1)$$

2.2 Carta de Controle T^2

As Cartas de Controle T^2 são ferramentas gráficas estatísticas amplamente utilizadas para monitorar a variação de múltiplos parâmetros em um sistema ao longo do tempo. Sua simplicidade na interpretação dos resultados permite uma análise rápida e

intuitiva, auxiliando na tomada de decisões pelos usuários para resolver eventuais falhas. Devido à sua robustez e aplicabilidade em diversos cenários, o T^2 se destaca como uma metodologia poderosa para auxiliar na detecção e na quantificação de alterações estruturais nos sinais monitorados, contribuindo para a eficiência e precisão no SHM.

Neste estudo, o T^2 foi calculado com base nos parâmetros extraídos das camadas latentes do VAE, normalizados e considerados no domínio da frequência. A aplicação dessa métrica possibilitou a detecção de alterações nos sinais ao comparar os valores observados com limites predefinidos. A estatística T^2 quantifica a distância entre uma nova observação e o vetor média amostral correspondente, sendo que valores elevados de T^2 indicam uma maior discrepância em relação à média. Essa métrica é baseada na correlação entre as variáveis e a dispersão dos dados, podendo contribuir para a identificação de anomalias.

Dada uma matriz $H_{N \times M}$ representando um conjunto de dados ao longo de um certo período, que, neste estudo, são as características extraídas das camadas latentes do VAE, a estatística T^2 pode ser calculada de acordo com a Equação (2):

$$T^2 = R(\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}})^T \mathbf{S}^{-1}(\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}}), \quad (2)$$

onde $\bar{\mathbf{h}}$ é o vetor-média da amostra das M características disponíveis, obtido a partir de uma submatriz de \mathbf{H} com R observações ($H_{N \times M}$, $R < N$); $\bar{\bar{\mathbf{h}}}$ e \mathbf{S} são, respectivamente, o vetor-média de referência e a média das matrizes de covariância de referência. Em todos os estudos conduzidos, o Limite Superior de Controle (UCL) foi definido como imediatamente acima de 95% dos valores de T^2 dos dados de treinamento. Valores de T^2 acima do UCL indicam mudanças nos dados, o que pode sugerir a presença de anomalias na estrutura.

3 METODOLOGIA

A metodologia proposta tem como objetivo avaliar a eficiência do VAE combinado com a Carta de Controle T^2 na classificação não supervisionada de sinais de vibração de três diferentes estruturas. Em cada análise, o modelo é treinado exclusivamente com dados da estrutura intacta e posteriormente testado com dados de diversas condições. Este processo permite comparar cada sinal com um estado de referência, identificando variações entre sinais de diferentes cenários estruturais, enquanto mantém semelhanças entre sinais de mesmos cenários. Avaliações

semelhantes com resultados satisfatórios nestas estruturas e mais detalhes são encontrados em Spínola Neto et al, 2024.

Os dados foram divididos em três conjuntos: treinamento, validação e monitoramento. Na fase de treinamento, um conjunto de dados extraído do estado intacto da estrutura foi usado para treinar o modelo VAE. Na fase de validação, outro conjunto de dados, também extraído do mesmo estado estrutural da fase de treinamento, foi aplicado ao modelo treinado na etapa anterior, com o objetivo de verificar a capacidade do modelo de classificar novos dados. Espera-se que sejam produzidos valores de T^2 estatisticamente semelhantes para os conjuntos de treinamento e validação, já que pertencem ao mesmo estado estrutural. Na fase de monitoramento, conjuntos de dados extraídos de outros casos estruturais, diferentes daqueles usados nas fases de treinamento e validação, foram apresentados ao modelo, sendo esperado que sejam produzidos valores de T^2 maiores do que os obtidos nas fases anteriores, pois pertencem a um estado estrutural diferente daquele usado para treinamento.

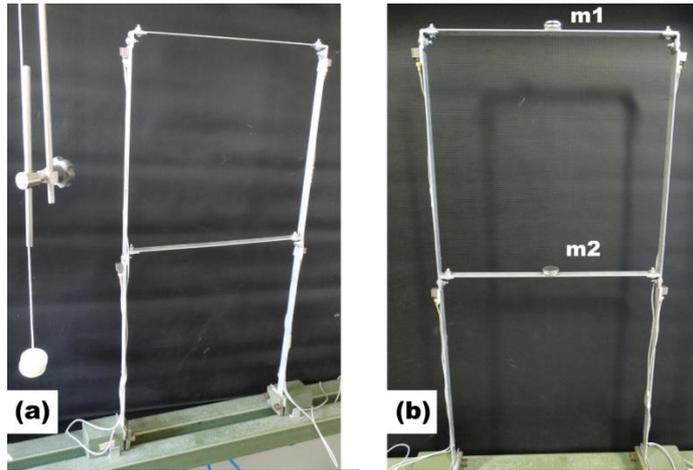
4 APLICAÇÕES

4.1 Pórtico Biengastado (Análise 1)

A primeira estrutura analisada trata-se de um pórtico biengastado (Figura 1) ensaiado no Laboratório de Imagem e Sinais da UFJF (Finotti et al, 2023).

Neste pórtico, quatro acelerômetros piezoelétricos unidirecionais (100 mV/g) foram fixados na estrutura para medir acelerações horizontais. Uma carga de impacto foi aplicada usando um pêndulo com massa de 14g. Para se obter as respostas dinâmicas, o pêndulo foi liberado do repouso a partir de uma posição constante, sendo sujeito à ação da gravidade até a sua colisão com a estrutura. No total, cinco cenários de danos simulados através da adição de massas nas posições m1 e m2 (de acordo com a Figura 1) foram avaliados, conforme mostrado na Tabela 1.

Figura 1 - Pórtico biengastado ensaiado no Laboratório de Imagem e Sinais da UFJF. (a) Vista frontal da estrutura no cenário 1; (b) Vista frontal da estrutura no cenário 4.



Adaptado de Finotti et al, 2023

Tabela 1 – Cenários de dano avaliados no pórtico.

Cenário	Configuração
1	Nenhuma massa adicionada à estrutura. $m1 = m2 = 0$;
2	Uma massa de 7,81g adicionada à estrutura. $m1 = 7,81g$ e $m2 = 0$;
3	Duas massas de 7,81g adicionadas à estrutura. $m1 = 15,62g$ e $m2 = 0$;
4	Três massas de 7,81g adicionadas à estrutura. $m1 = 15,62g$ e $m2 = 7,81g$;
5	Quatro massas de 7,81g adicionadas à estrutura. $m1 = 15,62g$ e $m2 = 15,62g$.

Fonte: Finotti et al, 2023

Os dados utilizados para o treinamento referem-se ao cenário 1, sendo esperado, portanto, que as reconstruções apresentem melhor desempenho para esse caso. Ao aplicar os modelos de reconstrução aos sinais dos demais cenários, com base no treinamento realizado no cenário 1, é previsível que ocorra um maior erro nas reconstruções.

4.2 Pórtico Tridimensional – “Yellow Frame” (Análises 2 e 3)

Foram realizadas simulações na Yellow Frame, ensaiada no Laboratório de Pesquisa em Engenharia Sísmica da UBC (Dyke et al, 2015). Como ilustrado na Figura 2, esse pórtico de quatro pavimentos foi instalado sobre uma laje de concreto externa ao laboratório, com o objetivo de replicar condições ambientais reais.

Nessa estrutura, foram realizadas duas análises distintas: a primeira, denominada Análise 2, focou na remoção dos contraventamentos; a segunda, Análise 3, avaliou os efeitos do afrouxamento dos parafusos. Em ambas as análises, as condições

de teste foram mantidas constantes, com o uso de quinze acelerômetros operando a uma frequência de amostragem de 200 Hz e com a aplicação de um filtro *anti-aliasing* com frequência de corte de 50 Hz. A Tabela 2 apresenta os cenários testados em cada uma dessas análises.

Figura 2 - "Yellow Frame" (a) com contraventamentos e (b) sem contraventamentos.



Fonte: Dyke et al (2015)

Tabela 2: Cenários estruturais avaliados nas análises 1 e 2

Cenário	Configuração
1	Estrutura completamente contraventada;
2	Remoção dos contraventamentos do 1º pavimento de uma baia no canto sudeste;
3	Remoção dos contraventamentos dos 1º e 4º pavimentos de uma baia no canto sudeste;
4	Remoção dos contraventamentos de todos os pavimentos de uma baia no canto sudeste;
5	Remoção de todos os contraventamentos do lado leste;
6	Remoção dos contraventamentos do 2º pavimento na face norte;
7	Remoção de todos os contraventamentos de todas as faces;
8	Não contraventada + parafusos afrouxados nos pavimentos 1 e 2 - face leste, lado norte;
9	Não contraventada + parafusos afrouxados nas extremidades na face leste, lado norte.

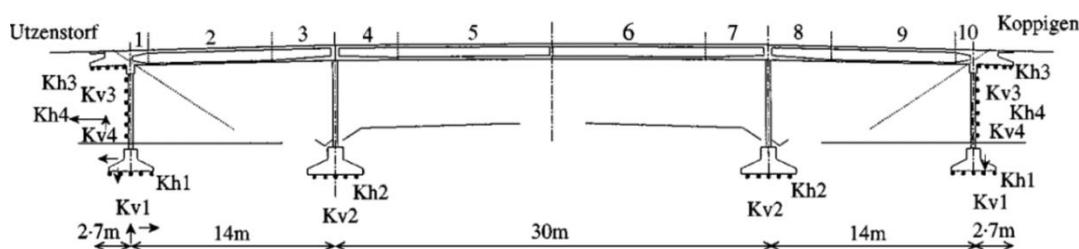
Fonte: Dyke et al, 2015

Para a Análise 2, os cenários de 1 a 5 simulam danos progressivos, enquanto o cenário 6 simula um reparo na estrutura. Para a Análise 3, os cenários de 7 a 9 representam danos crescentes.

4.3 Ponte Z24 (Análise 4)

Após os testes das análises anteriores, o modelo foi avaliado usando dados de uma estrutura real (Análise 4), a Ponte Z24 (Figura 3). Durante a demolição dessa ponte, foi feita uma instrumentação e suas respostas dinâmicas foram coletadas. Acelerômetros foram posicionados no tabuleiro da ponte ao longo de três linhas de medição paralelas: uma localizada na linha central e as outras duas nas margens laterais.

Figura 3: Esboço da Ponte Z24.



Fonte: Peeters & De Roeck (2001)

Para a simulação dos danos, o pilar localizado no lado de Koppigen foi seccionado, e o concreto foi substituído por placas de aço, juntamente com a instalação de três macacos hidráulicos. Esse sistema permitiu o rebaixamento controlado do pilar, simulando causas reais de danos, como o assentamento diferencial e a erosão do subsolo. Sob essas condições, foram investigados os cenários descritos na Tabela 3.

Tabela 3: Cenários estruturais avaliados na Ponte Z24.

Cenário	Configuração
1	Estrutura não danificada;
2	Estrutura não danificada (com a adição de macacos hidráulicos);
3	Assentamento de 40 mm no pilar indicado;
4	Assentamento de 80 mm no pilar indicado.

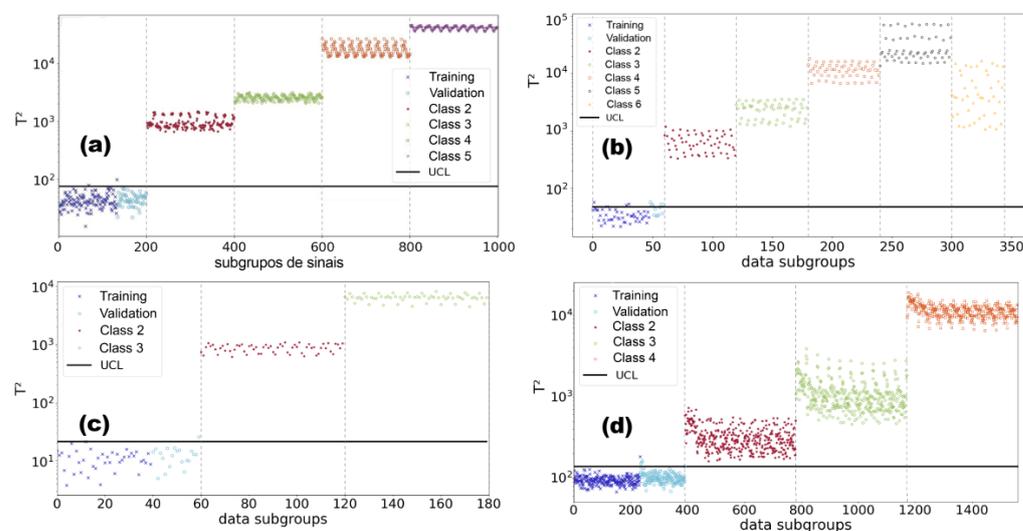
Fonte: Peeters & De Roeck (2001)

5 RESULTADOS

Esta seção apresenta alguns dos resultados obtidos pela metodologia apresentada. Conforme ilustrado na Figura 4, todos os valores de T^2 nas análises das classes de treinamento e validação se mostraram semelhantes, demonstrando a

capacidade do modelo em classificar dados novos em todas as quatro análises. Isso ocorre porque ambos os conjuntos (validação e treinamento) representam o mesmo estado estrutural, o que resulta em valores de T^2 próximos. Adicionalmente, a metodologia identificou com precisão a ocorrência de alterações estruturais, uma vez que todas as classes de monitoramento ultrapassaram o limite superior de controle previamente estabelecido. Na Figura 4b, observa-se que a classe 6 apresentou valores de T^2 mais baixos que os das classes anteriores, o que era esperado, pois ela corresponde a um cenário de reparo na estrutura, indicando a restauração do estado estrutural. Por fim, o VAE, em conjunto com a Carta de Controle T^2 , demonstrou habilidade em quantificar as alterações estruturais, com os valores de T^2 aumentando à medida que as alterações progressivas ocorriam nas estruturas, sem sobreposição de valores entre cenários distintos. Na Figura 4, os resultados dos demais acelerômetros foram omitidos por apresentarem padrões semelhantes.

Figura 4: Cartas de Controle T^2 para as estruturas avaliadas. (a) Análise 1, Acelerômetro 1; (b) Análise 2, Acelerômetro 4 (c) Análise 3, Acelerômetro 4; (d) Análise 4, Acelerômetro 2.



Fonte: Produzido pelo autor

6 CONCLUSÕES

Este estudo investigou a eficácia do Autocodificador Variacional (VAE) combinado com a Carta de Controle T^2 na detecção e na quantificação de danos estruturais. Os resultados demonstraram que o VAE, treinado de forma não supervisionada com dados das estruturas intactas, foi capaz de identificar com precisão

as anomalias estruturais introduzidas em todas as análises. A aplicação do T^2 permitiu uma detecção robusta das alterações, mostrando a capacidade do modelo de distinguir entre estados saudáveis e danificados da estrutura. Dessa forma, a combinação de técnicas de aprendizado não supervisionado com métodos estatísticos, como o VAE e o T^2 , oferece uma abordagem promissora para os sistemas SHM.

REFERÊNCIAS

ALVES, V.; CURY, A. **An automated vibration-based structural damage localization strategy using filter-type feature selection.** *Mech. Syst. Signal Process.* 2023, 190, 110145.

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.** *Mech. Syst. Signal Process.* 2021, 147, 107077.

DYKE, J.; BERNAL, D.; BECK, J.; VENTURA, C. **Experimental Phase II of the Structural Health Monitoring Benchmark Problem.** 2003.

FINOTTI, R.P.; SILVA, C.F.; OLIVEIRA, P.H.E.; BARBOSA, F.d.S.; CURY, A.A.; SILVA, R.C. **Novelty detection on a laboratory benchmark slender structure using an unsupervised deep learning algorithm.** *Lat. Am. J. Solids Struct.* 2023, 20, e512.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning.** MIT Press: Cambridge, MA, USA, 2016.

MONTGOMERY, D. **Introduction to Statistical Quality Control;** John Wiley & Sons: Hoboken, NJ, USA, 2009.

MOU, M.; ZHAO, X.; LIU, K.; HUI, Y. **NEES: Database for Structural Control and Monitoring Benchmark Problems.** 2015.

SOUSA, H.; COURAGE, W. **Value of information of a pro-active SHM-based tool supported by advanced FE models and Bayesian statistics towards efficiency in bridge management.** Struct. Infrastruct. Eng. 2021, 18, 554–572.

SPÍNOLA NETO, M.; FINOTTI, R.; BARBOSA, F.; CURY, A. **Structural Damage Identification Using Autoencoders: A Comparative Study.** Buildings 2024, 14, 2014.

PEETERS, B.; DE ROECK, G. **One year monitoring of the z24-bridge: Environmental influences versus damage events.** Earthq. Eng. Struct. Dyn. 2001, 30, 149–171.

TEUGHEL, A.; DE ROECK, G. **Structural damage identification of the highway bridge Z24 by FE model updating.**J. SoundVib. 2004, 278, 589–610.