

# Estudo Comparativo da Eficácia de Autocodificadores na Identificação de Danos Estruturais<sup>☆</sup>

## Comparative study of the effectiveness of autoencoders in identifying structural damage

Marcos Spínola Neto<sup>1,†</sup>, Luiz Tadeu Dias Júnior<sup>1</sup>, Rafaelle Piazzaroli Finotti<sup>1</sup>, Flávio de Souza Barbosa<sup>1</sup>, Alexandre Abrahão Cury<sup>1</sup>

<sup>1</sup> Universidade Federal de Juiz de Fora, Faculdade de Engenharia - Juiz de Fora, MG, Brasil

<sup>†</sup> Autor correspondente: marcosrsneto@gmail.com

### Resumo

O monitoramento de integridade estrutural (SHM, do inglês Structural Health Monitoring) tem como objetivo garantir a segurança e o funcionamento das estruturas. Nos últimos anos, diversas técnicas baseadas em aprendizado de máquina têm sido utilizadas para esse fim. Dentre elas, destacam-se os autocodificadores (AE, do inglês Autoencoder), que são modelos capazes de extrair características a partir de dados de vibração, reduzindo a sua dimensionalidade, constituindo-se como ferramentas eficazes para aplicações de SHM. Este trabalho investiga a eficácia de quatro metodologias baseadas em autocodificadores, combinadas a uma ferramenta estatística para detectar e quantificar mudanças estruturais em três diferentes estruturas. Os sinais de vibração das estruturas são utilizados como dados de entrada e os valores da camada latente dos autocodificadores como parâmetros no teste  $T^2$  de Hotelling para avaliar mudanças estruturais. Observou-se nos resultados obtidos que o modelo de autocodificador de melhor desempenho, Variacional AE –  $T^2$ , supera os outros na identificação e quantificação das mudanças estruturais. Embora os modelos AE, AE Esparso e AE Convolutacional tenham apresentado limitações quanto a quantificação das alterações, eles apresentaram desempenho relevante para a detecção de anomalias.

### Palavras-chave

Monitoramento de Integridade Estrutural • Detecção de Danos • Autocodificadores

### Abstract

Structural Health Monitoring (SHM) aims to ensure the safety and functionality of structures. In recent years, various machine learning techniques have been employed for this purpose. Among them, autoencoders (AE) stand out as models capable of extracting features from vibration data, reducing dimensionality and proving to be effective tools for SHM applications. This work investigates the effectiveness of four methodologies based on autoencoders, combined with a statistical tool to detect and quantify structural changes in three different structures. The vibration signals from the structures are used as input data, and the values from the latent layer of the autoencoders are used as parameters in the Hotelling  $T^2$  test to evaluate structural changes. The results obtained indicate that the autoencoder model with the best performance, Variational AE –  $T^2$ , outperforms the others in identifying and quantifying structural changes. Although the AE, Sparse AE, and Convolutional AE models exhibited limitations regarding the quantification of alterations, they showed relevant performance for anomaly detection.

<sup>☆</sup> Este artigo é uma versão estendida do trabalho apresentado no XXVII ENMC Encontro Nacional de Modelagem Computacional e XV ECTM Encontro de Ciência e Tecnologia de Materiais, ocorridos em Ilhéus – BA, de 1 a 4 de outubro de 2024.

**Keywords**

Structural Health Monitoring • Damage Detection • Autoencoders

## 1 Introdução

Dentre as principais preocupações dos engenheiros ao longo do ciclo de vida das construções, destacam-se o bom funcionamento dos sistemas estruturais e a segurança dos usuários. Considerando-se que as inspeções humanas, quando conduzidas visualmente, podem ser suscetíveis à imprecisões e erros, o monitoramento de integridade estrutural (SHM, do inglês *Structural Health Monitoring*) tem surgido como uma abordagem potencial para a identificação precoce de falhas em estruturas [1]. Esta metodologia depende principalmente do uso de acelerômetros conectados às estruturas para registrar dados de vibração ao longo do tempo. Com avanços significativos em aprendizado de máquina (ML, do inglês *Machine Learning*) e Inteligência Artificial (IA), esses dados se tornaram não apenas mais precisos, mas também mais acessíveis, possibilitando sua aplicação generalizada [2]. Como resultado, sistemas de SHM oferecem uma abordagem mais confiável e econômica para a manutenção estrutural, permitindo a detecção remota de sinais de deterioração com base em limiares predefinidos, o que pode reduzir significativamente os custos de reparo [3] [4].

Com os avanços computacionais, métodos que utilizam diretamente dados vibracionais brutos estão se tornando mais dominantes [4] [5]. Essas abordagens podem detectar alterações estruturais processando sinais adquiridos da estrutura ao longo do tempo, extraíndo características relevantes e realizando classificações com custos computacionais relativamente baixos. Um autocodificador (AE, do inglês *Autoencoder*) é um modelo de aprendizado não supervisionado projetado para reconstruir dados de entrada e reduzir a dimensionalidade. Ele comprime informações em uma representação latente e reconstrói os dados originais a partir desta forma reduzida. Composto por um codificador e um decodificador, ele minimiza a diferença entre a entrada e a saída reconstruída. Existem variações específicas, como autocodificadores esparsos (SAEs, do inglês *Sparse Autoencoder*), que introduzem restrições de regularização para forçar a rede a aprender representações mais eficientes; autocodificadores variacionais (VAEs, do inglês *Variational Autoencoder*), que incorporam uma abordagem probabilística para modelar a distribuição dos dados; e autocodificadores convolucionais (CAEs, do inglês *Convolutional Autoencoder*), que são adaptados para processar dados de imagem capturando características espaciais [6].

Neste contexto, este artigo avalia comparativamente o desempenho de quatro diferentes autocodificadores (AE, SAE, VAE e CAE) na identificação de alterações estruturais. Para avaliar a metodologia, três estruturas diferentes 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 [7]; (ii) um pórtico de aço de quatro andares localizado no Laboratório de Engenharia Sísmica da Universidade da Colúmbia Britânica (UBC), que sofreu dois tipos de alterações - remoção de contraventamentos e afrouxamento de parafusos [8]; (iii) a Ponte Z24, que ligava as cidades de Koppigen e Utzenstorf na Suíça e que foi submetida a vários testes de danos progressivos simulando situações reais de degradação em diferentes condições de temperatura para fins científicos [9]. Para todas as aplicações, foi construído um índice baseado na estatística *Shewhart T Control Chart* (estatística *Hotelling T<sup>2</sup>*) [10], que foi calculada usando os dados da camada latente dos autocodificadores, permitindo a identificação e a quantificação de danos em todas as estruturas analisadas.

## 2 Metodologia

A metodologia proposta busca avaliar a capacidade dos AEs de separar, de maneira não supervisionada, sinais de vibração pertencentes a diferentes comportamentos dinâmicos estruturais. Isso é alcançado treinando o modelo com apenas uma parte dos dados das estruturas intactas e, posteriormente, testando-o com os restantes. Durante esse processo, o modelo compara cada sinal com a classe de referência, ou seja, estado de dano, derivando um erro específico de reconstrução, aqui usada a métrica  $T^2$  para essa avaliação, que aumenta gradualmente entre as classes, mas permanece relativamente constante dentro de cada uma delas. Dessa forma, todos os dados são divididos em três conjuntos da seguinte forma:

- **Fase de Treinamento:** Nesta etapa, um conjunto de dados extraídos do estado não danificado da estrutura é usado para treinar o modelo de autocodificador. Este conjunto de dados é chamado de conjunto de treinamento;
- **Fase de Validação:** Durante esta fase, outro conjunto de dados (de validação), também extraído do mesmo estado estrutural da fase de treinamento, é aplicado ao modelo treinado na fase anterior. O objetivo é verificar a capacidade de classificar novos dados. Espera-se que o modelo resulte em valores  $T^2$  estatisticamente similares para os conjuntos de treinamento e validação, uma vez que pertencem ao mesmo estado estrutural;

- **Fase de Monitoramento:** Nesta fase, conjuntos de dados (de monitoramento) extraídos de outros casos estruturais, diferentes dos utilizados nas fases de treinamento e validação, são apresentados ao modelo. Espera-se que sejam produzidos valores de  $T^2$  mais altos do que os obtidos nas fases anteriores, já que pertencem a um estado estrutural diferente daquele usado para treinamento.

Para todas as estruturas analisadas, a Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*) dos sinais dinâmicos estruturais foi utilizada como entrada para os modelos do autocodificador. Essa escolha foi motivada pelo fato de que as compressões e reconstruções realizadas pelos AE foram mais precisas nesse domínio em comparação ao domínio temporal [11].

Para garantir a variabilidade estatística dentro do conjunto de dados avaliado, utilizou-se de um esquema de validação cruzada com 10 *folds* para cada estrutura, a fim de obter avaliações mais homogêneas e precisas. A ordem dos dados dentro das classes também foi modificada aleatoriamente no início de cada repetição, alterando-se, assim, a porção e a sequência de dados de estrutura íntegra usados para treinamento e validação. Após realizar a FFT sobre os dados de aceleração, todos os resultados foram padronizados usando a padronização *z-score*.

Todos os modelos de AE dependem dos seguintes parâmetros e hiperparâmetros: taxa de aprendizado, número de épocas, tamanho do lote (*batch size*), dimensão original, dimensão latente e algoritmo otimizador. No entanto, para o SAE, também é necessário definir o parâmetro de esparsidade  $\lambda$ ; para o VAE, é utilizada a dimensão intermediária; para o CAE, como a camada latente não é unidimensional, é preciso definir o número de filtros e seus tamanhos para essa camada.

Os hiperparâmetros dos AEs foram selecionados utilizando o otimizador de parâmetros *Optuna* [12]. Esta é uma ferramenta automatizada e eficiente de otimização que emprega técnicas de busca inteligente para encontrar as melhores combinações de hiperparâmetros para um determinado modelo de aprendizado de máquina, a partir de uma abordagem de busca e seleção baseada em amostragem eficiente. Para isso, basta que o usuário insira intervalos de busca para cada item a ser otimizado, os quais neste trabalho foram escolhidos com base em práticas estabelecidas na literatura e experimentos preliminares [13] [7] [11] [14] [15], além do objetivo da otimização. Esses hiperparâmetros otimizados foram posteriormente utilizados para treinar os autocodificadores.

Todos os dados das fases de treinamento e validação das aplicações são compostos pelo cenário 1 (estrutura sem dano). Após o treinamento, validação e otimização, os resultados passam pela fase de monitoramento. Nessa fase, há reconstrução dos sinais dos demais cenários para, nesse momento, realizar o cálculo usando a estatística *Hotelling*  $T^2$ . Por fim, foi usado um limiar pré-fixado (UCL) acima dos 95% desses valores obtidos durante a fase de treinamento para separar os dados com e sem dano.

### 3 Aplicações

#### 3.1 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 [7].




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 [7].

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 14 g. 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  $m_1$  e  $m_2$  (ver Figura 1) foram avaliados, conforme mostrado na Tabela 1.

Tabela 1: Cenários de dano avaliados no pórtico.

Cenário	Configuração
1	Nenhuma massa adicionada à estrutura. $m_1 = m_2 = 0$ ;
2	Uma massa de 7,81 g adicionada à estrutura. $m_1 = 7,81$ g e $m_2 = 0$ ;
3	Duas massas de 7,81 g adicionadas à estrutura. $m_1 = 15,62$ g e $m_2 = 0$ ;
4	Três massas de 7,81 g adicionadas à estrutura. $m_1 = 15,62$ g e $m_2 = 7,81$ g;
5	Quatro massas de 7,81 g adicionadas à estrutura. $m_1 = 15,62$ g e $m_2 = 15,62$ g.

Os dados do cenário 1 foram utilizados para a fase de treinamento, sendo, portanto, esperado que as reconstruções desse cenário apresentem maior precisão. Nos demais cenários, ao aplicar o modelo treinado com dados do cenário 1, é previsível que as diferenças de reconstrução sejam mais acentuadas. A Figura 2 ilustra esses resultados, apresentando quatro gráficos do índice *Hotelling*  $T^2$ , gerados com diferentes tipos de AE aplicados ao acelerômetro ac1. Resultados similares foram observados para os demais acelerômetros e por isso foram omitidos.

Todas as metodologias avaliadas geraram valores de  $T^2$  similares entre as classes de validação e treinamento, evidenciando a capacidade dos modelos em classificar novos dados dessa estrutura, uma vez que os conjuntos de validação e treinamento pertencem ao mesmo estado estrutural e, portanto, deveriam apresentar  $T^2$  semelhantes. Além disso, todas as metodologias identificaram corretamente a presença de mudanças estruturais, pois todas as classes de monitoramento excederam o limite superior de controle pré-estabelecido.

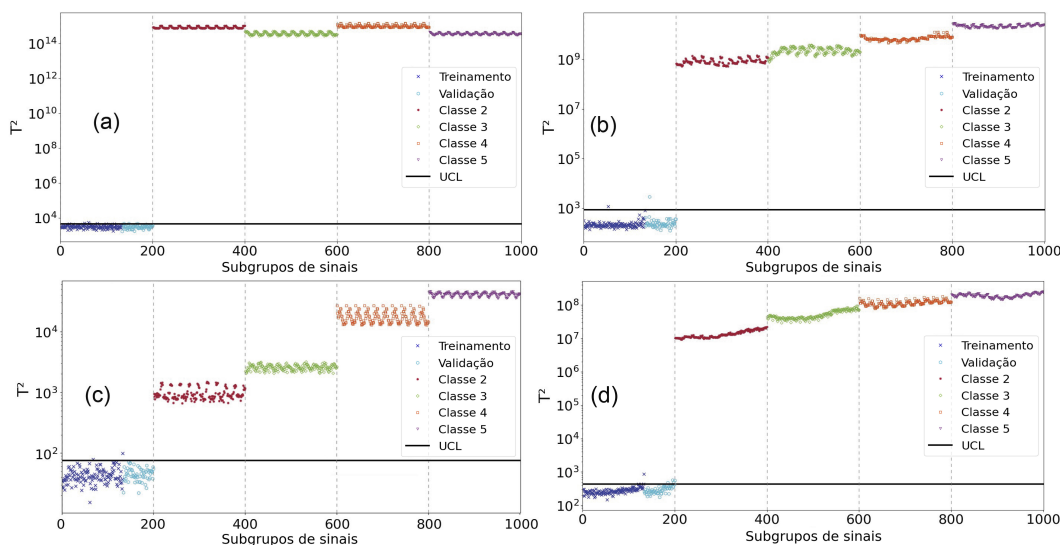


Figura 2: Resultados do pórtico biengastado (Análise 1 - Acelerômetro 1). (a) AE; (b) SAE; (c) VAE; (d) CAE.

Contudo, apenas o VAE conseguiu quantificar precisamente as alterações estruturais, com os valores de  $T^2$  aumentando conforme a massa era adicionada ao pórtico, sem que pontos de diferentes cenários compartilhassem a mesma faixa de valores. Apesar de os resultados do SAE e do CAE (Figuras 2b e 2d, respectivamente) também demonstrarem aumento nos valores de  $T^2$  com a adição de massa, ainda houve casos em que diferentes cenários apresentaram  $T^2$  dentro da mesma faixa. Assim, as metodologias AE, SAE e CAE (Figura 2a, b, d) exibiram valores de  $T^2$  similares entre sinais de classes distintas, não sendo capazes de quantificar com precisão os níveis de mudanças estruturais.

### 3.2 Pórtico Tridimensional - “Yellow Frame” (Análises 2 e 3)

Simulações semelhantes foram conduzidas no conhecido “Yellow Frame” ensaiado no Laboratório de Pesquisa em Engenharia Sísmica da UBC [8]. Conforme ilustrado na Figura 3, este pórtico consiste de quatro pavimentos e foi instalado sobre uma laje de concreto externa ao laboratório para simular condições ambientais.

Foram impostos diferentes cenários de danos (1-6) à estrutura, simulando a remoção ou adição gradual dos contraventamentos. Em seguida, danos progressivos foram simulados na estrutura sem contraventamentos, por meio do afrouxamento dos parafusos nas conexões viga-coluna (cenários 7-9). Com base nesses cenários, realizaram-se duas análises distintas: a primeira avaliou o impacto da remoção dos contraventamentos (Análise 2) e a segunda, os efeitos do afrouxamento dos parafusos (Análise 3). Em ambas as análises, manteve-se a mesma configuração de teste: quinze acelerômetros com frequência de amostragem de 200 Hz, além de um filtro *anti-aliasing* com corte em 50 Hz. A Tabela 2 lista todos os cenários considerados nas duas análises.



Figura 3: “Yellow Frame” (a) sem contraventamentos e (b) com contraventamentos. [8]

Tabela 2: Cenários estruturais avaliados nas análises 1 e 2

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

Nesta estrutura, assim como no caso precedente, todas as metodologias analisadas obtiveram valores de  $T^2$  similares entre as classes de validação e treinamento, confirmando a capacidade dos modelos de classificar novos dados, já que os de validação e treinamento pertencem ao mesmo estado estrutural.

Na ordem de aquisição, para a Análise 2, os cenários 1, 5, 4, 3 e 2 simulam danos progressivos, sendo renomeados de classes de 1 a 5, conforme a progressão dos danos, enquanto o cenário 6, que simula um reparo na estrutura, foi chamado de classe 6. Para a Análise 3, Os casos 7, 9 e 8, nessa ordem, representam danos crescentes, e foram renomeados de classes 1, 2 e 3 conforme o aumento dos danos.

Além disso, todos os métodos identificaram corretamente a presença de alterações estruturais, pois todas as classes de monitoramento excederam o UCL. A Figura 4 apresenta os resultados após a classificação dos dados da Análise 2 e a Figura 5 para a Análise 3. Em ambos os casos foram apresentados os resultados apenas para o acelerômetro 4, uma vez que os demais acelerômetros forneceram resultados semelhantes.

Na Análise 2, o AE e o SAE (Figura 4a,b) não foram capazes de identificar os dados de validação como sendo da mesma classe dos de treinamento, não atendendo os mínimos requisitos de classificação. O VAE e o CAE forneceram



bons resultados para a identificação das alterações estruturais, pois classificaram corretamente os sinais de validação como semelhantes aos de treinamento e, em ambos os modelos, todas as classes de monitoramento ficaram acima da UCL. Além disso, os dados pertencentes à Classe 6 ficaram com valores de  $T^2$  predominantemente inferiores aos da Classe 5, indicando correta identificação da adição de contraventamentos, simulando um reparo estrutural. Entre todas as metodologias avaliadas, o VAE (Figura 4c) se destacou novamente como o mais eficaz na quantificação das alterações, pelo aumento nos valores de  $T^2$  à medida que a remoção dos contraventamentos foi realizada.

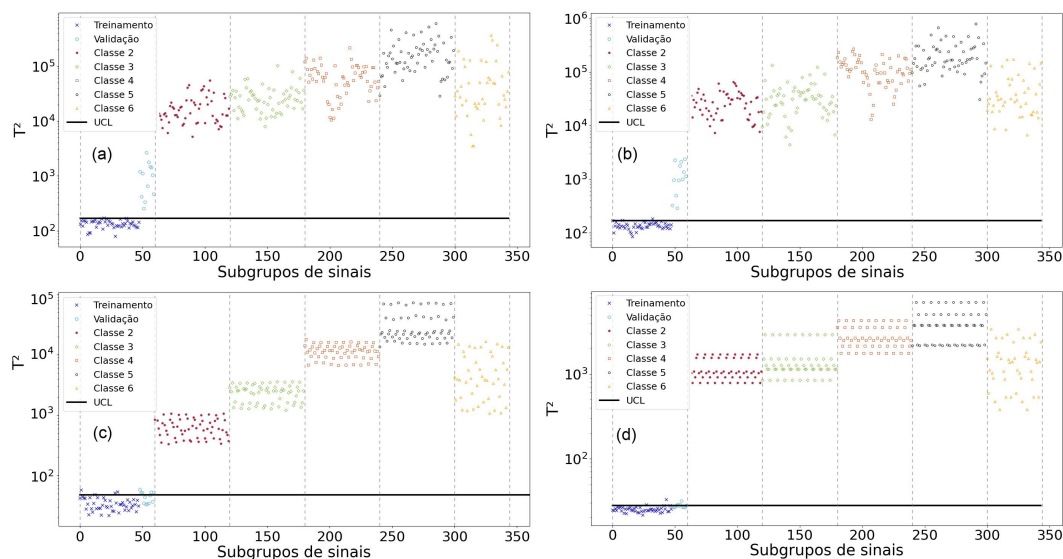


Figura 4: Resultados do pórtico tridimensional para remoção de contraventamento (Análise 2 - acelerômetro 4). (a) AE; (b) SAE; (c) VAE; (d) CAE.

Na Análise 3, todas as metodologias obtiveram valores de  $T^2$  semelhantes entre as classes de validação e treinamento em todos os 15 acelerômetros, confirmando a capacidade dos modelos de classificar novos dados. Além disso, todas as metodologias identificaram corretamente a presença de alterações estruturais, pois todas as classes de monitoramento excederam o UCL. Para quantificar as alterações, o VAE e o CAE (Figura 5c,d) foram mais eficazes, pois há uma maior diferença entre os valores de  $T^2$  de classes diferentes.

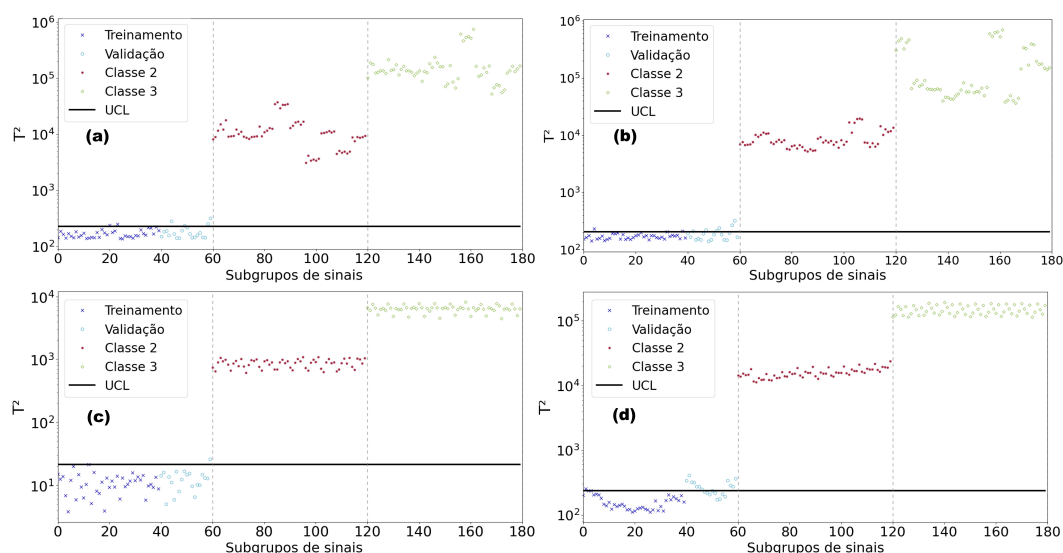


Figura 5: Resultados do pórtico tridimensional para o afrouxamento de parafusos (Análise 3 - acelerômetro 4). (a) AE; (b) SAE; (c) VAE; (d) CAE.



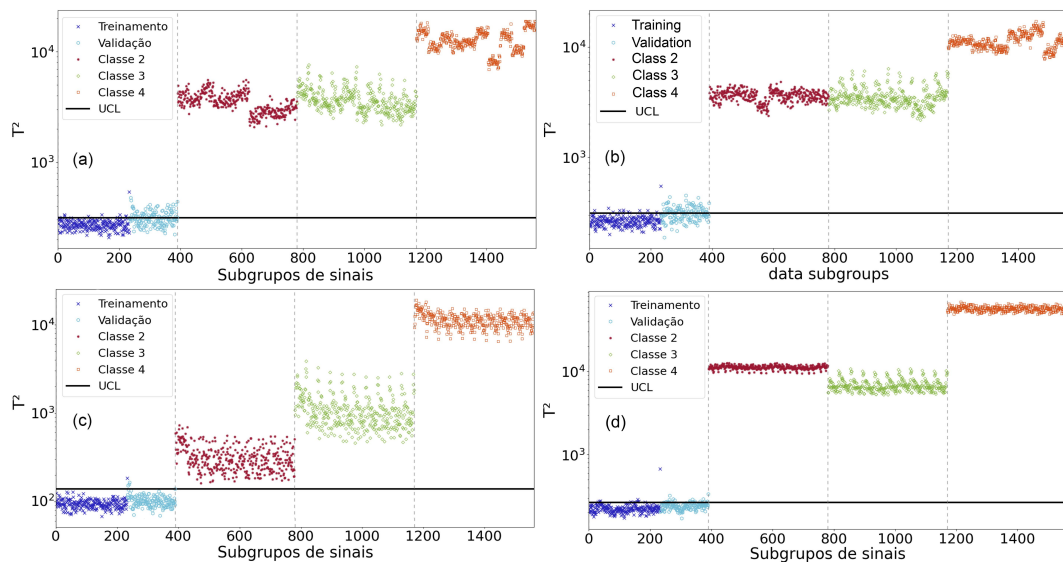


Figura 7: Resultados da Ponte Z24 (Análise 4 - Acelerômetro 2) (a) AE; (b) SAE; (c) VAE; (d) CAE.

## 4 Conclusões

Este trabalho avaliou a eficácia de quatro metodologias baseadas em autocodificadores, combinadas com a ferramenta estatística *Hotelling T<sup>2</sup>*, para a detecção e a quantificação de danos estruturais. Os resultados demonstram que o modelo que combina o Autocodificador Variacional com a ferramenta *-T<sup>2</sup>* superou os demais em precisão para quantificar alterações. Embora os modelos de Autocodificador Tradicional, Autocodificador Espasso e Autocodificador Convolutivo tenham exibido limitações na quantificação dos danos, todas as variações foram capazes de identificar anomalias estruturais, mostrando-se adequadas para as etapas iniciais de diagnóstico e detecção de falhas.

Por fim, os avanços contínuos nessas metodologias não apenas aprofundam o entendimento dos mecanismos de comportamento estrutural, mas também oferecem aplicações potenciais na localização de alterações estruturais e na avaliação da vida estrutural remanescente. Essa capacidade preditiva pode guiar decisões estratégicas e proativas, permitindo a implementação mais eficaz de medidas preventivas e corretivas.

## Agradecimentos

Este trabalho foi financiado pela CAPES (Código Financeiro 0001), Conselho Nacional de Desenvolvimento Científico e Tecnológico — CNPq (Brasil) — Projetos CNPq/ FNDCT/ MCTI 407256/2022-9, 402533/2023-2, 303982/2022-5 e 308008/2021-9 e Fundação de Amparo à Pesquisa do Estado de Minas Gerais — FAPEMIG — Processo BPD-00080-22.

## Referências

- [1] H. Sousa e W. Courage, “Value of information of a pro-active SHM-based tool supported by advanced FE models and Bayesian statistics towards efficiency in bridge management,” *Structure and Infrastructure Engineering*, vol. 18, pp. 554–572, 2021. Disponível em: <https://doi.org/10.1080/15732479.2021.1978507>
- [2] X. Wang, Y. Q. Ni, e K. C. Lin, “Comparison of statistical counting methods in SHM-based reliability assessment of bridges,” *Journal of Civil Structural Health Monitoring*, vol. 5, pp. 275–286, 2015. Disponível em: <https://doi.org/10.1007/s13349-015-0103-1>
- [3] A. Cury, D. Ribeiro, F. Ubertini, e M. D. Todd, *Structural Health Monitoring Based on Data Science Techniques*, 1a ed., Springer Cham, 2022.
- [4] F. J. Carrión, J. A. Quintana, e S. E. Crespo, “Techno-economical and practical considerations for SHM systems,” *Journal of Civil Structural Health Monitoring*, vol. 7, pp. 207–215, 2017. Disponível em: <https://doi.org/10.1007/s13349-017-0215-x>



- [5] V. Alves e A. Cury, “An automated vibration-based structural damage localization strategy using filter-type feature selection,” *Mechanical Systems and Signal Processing*, vol. 190, p. 110145, 2023. Disponível em: <https://doi.org/10.1016/j.ymssp.2023.110145>
- [6] M. Spínola Neto, R. Finotti, F. Barbosa, e A. Cury, “Structural Damage Identification Using Autoencoders: A Comparative Study,” *Buildings*, vol. 14, no. 7, p. 2014, 2024. Disponível em: <https://doi.org/10.3390/buildings14072014>
- [7] R. P. Finotti, C. F. Silva, P. H. E. Oliveira, F. S. Barbosa, A. A. Cury, e R. C. Silva, “Novelty detection on a laboratory benchmark slender structure using an unsupervised deep learning algorithm,” *Latin American Journal of Solids and Structures*, vol. 20, no. 9, p. e512, 2023. Disponível em: <https://doi.org/10.1590/1679-78257591>.
- [8] M. Mou, X. Zhao, K. Liu, e Y. Hui, “Database for Structural Control and Monitoring Benchmark Problems,” 2015. Disponível em: <https://datacenterhub.org/resources/257>
- [9] B. Peeters e G. De Roeck, “One year monitoring of the Z24-bridge: Environmental influences versus damage events,” *Earthquake Engineering Structural Dynamics*, vol. 30, no. 2, pp. 149-171, 2001. Disponível em: [https://doi.org/10.1002/1096-9845\(200102\)30:2<149::AID-EQE1>3.0.CO;2-Z](https://doi.org/10.1002/1096-9845(200102)30:2<149::AID-EQE1>3.0.CO;2-Z).
- [10] D. Montgomery, *Introduction to Statistical Quality Control*, 4a ed., Hoboken, NJ, EUA: John Wiley & Sons, 2007.
- [11] L. Resende, R. P. Finotti, F. S. Barbosa, e A. A. Cury, “Structural damage detection with autoencoding neural networks,” em *Proceedings of the XLIII Ibero-Latin American Congress on Computational Methods in Engineering*, Foz do Iguaçu, Brasil, 2022.
- [12] T. Akiba, S. Sano, T. Yanase, T. Ohta, e M. Koyama, “Optuna: A Next-generation Hyperparameter Optimization Framework,” em *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*, Anchorage, AK, EUA, 2019, pp. 2623–2631. Disponível em: <https://doi.org/10.1145/3292500.3330701>
- [13] L. Resende, R. Finotti, F. Barbosa, H. Garrido, A. Cury, e M. Domizio, “Damage identification using convolutional neural networks from instantaneous displacement measurements via image processing,” *Structural Health Monitoring*, vol. 23, no. 3, pp. 1627-1640, 2024. Disponível em: <https://doi.org/10.1177/14759217231193102>
- [14] R. P. Finotti, C. Gentile, F. Barbosa, e A. Cury, “Structural novelty detection based on sparse autoencoders and control charts,” *Structural Engineering and Mechanics*, vol. 81, no. 5, pp. 647-664, 2022. Disponível em: <https://doi.org/10.12989/sem.2022.81.5.647>.
- [15] R. P. Finotti, F. S. Barbosa, A. A. Cury, e R. L. Pimentel, “Numerical and experimental evaluation of structural changes using sparse auto-encoders and SVM applied to dynamic responses,” *Applied Sciences*, vol. 11, no. 24, p. 11965, 2021. Disponível em: <https://doi.org/10.3390/app112411965>