

Monitoramento da Integridade Estrutural de Turbinas Eólicas Utilizando Autocodificadores Esparsos[☆]

Structural Health Monitoring of Wind Turbine Towers Using Sparse Autoencoders

Mariana Passamai Alvarenga¹, Marcos Spínola Neto^{1,†}, Rodrigo Astroza², Rafaelle Finotti¹, Flávio Barbosa¹, Alexandre Cury¹

¹Universidade Federal de Juiz de Fora - Juiz de Fora, MG, Brasil

²Universidad de Los Andes - Facultad de Ingenieria y Ciencias Aplicadas

[†]**Autor correspondente:** marcosrsneto@gmail.com

Resumo

O monitoramento da integridade estrutural de torres eólicas é fundamental para garantir a segurança operacional e prolongar a vida útil dessas estruturas utilizadas na geração de energia renovável. As torres eólicas estão sujeitas a condições ambientais severas e a cargas dinâmicas significativas devido ao vento, podendo levar ao surgimento de danos. Dessa forma, o presente estudo explora a eficácia do uso de técnicas de aprendizado não supervisionado, mais especificamente os autocodificadores esparsos (SAE), para a detecção de danos estruturais em turbinas eólicas com base em sinais dinâmicos coletados durante operações de funcionamento simuladas em protótipos de pás de turbinas. O SAE é treinado utilizando dados de estruturas intactas e testado em cenários que incluem a introdução de fissuras e a adição de massas nas pás. Utilizando a Carta de Controle *Hotelling T²*, os modelos demonstraram ser robustos para identificar corretamente tanto a adição de massa quanto a presença de fissuras, independentemente da velocidade da turbina. As análises mostram que o SAE é eficaz na extração de características relevantes dos dados e na detecção de alterações estruturais, com boa precisão e confiabilidade. Os resultados evidenciam que o SAE, combinado com a estatística *T²*, oferece uma abordagem não supervisionada robusta para o monitoramento da integridade estrutural de turbinas eólicas, proporcionando uma ferramenta poderosa para a manutenção preditiva e a detecção precoce de danos.

Palavras-chave

Autocodificador Esparso • Monitoramento da Integridade Estrutural • Energia Eólica • Hotelling *T²*

Abstract

The structural health monitoring of wind turbine towers is essential to ensure operational safety and extend the lifespan of these structures used in renewable energy generation. Wind turbine towers are subjected to severe environmental conditions and significant dynamic loads due to wind, which may lead to the development of damage. Therefore, this study explores the effectiveness of using unsupervised learning techniques, specifically sparse autoencoders (SAE), for detecting structural damage in wind turbines based on dynamic signals collected during simulated operational scenarios of turbine blade prototypes. The SAE is trained using data from intact structures and tested in scenarios that include the introduction of cracks and the addition of masses to the blades. Using the Hotelling *T²* Control Chart, the models demonstrated robustness in correctly identifying both mass addition and the presence of

[☆] 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.

cracks, regardless of turbine speed. The analyses show that the SAE is effective in extracting relevant features from the data and detecting structural changes with good accuracy and reliability. The results highlight that the SAE, combined with T^2 statistics, offers a robust unsupervised approach to wind turbine structural health monitoring, providing a powerful tool for predictive maintenance and early damage detection.

Keywords

Sparse Autoencoder • Structural Health Monitoring • Wind Energy • Hotelling T^2

1 Introdução

A matriz energética brasileira é composta principalmente por usinas hidrelétricas. Embora seja considerada uma das matrizes energéticas mais limpas do mundo, em períodos de crise hídrica é necessário acionar usinas termelétricas - altamente poluentes e de custo elevado - para suprir as demandas de abastecimento. Nos últimos anos, a energia eólica tem ocupado uma parcela crescente na geração de energia renovável ao redor do mundo [1], representando, em 2023, 13,2% da energia gerada no Brasil. Por ser uma alternativa sustentável e renovável à geração baseada em combustíveis fósseis, é cada vez mais necessário garantir uma operação eficiente e segura das turbinas eólicas para maximizar seu desempenho e prolongar sua vida útil [2]. A integridade estrutural das pás das turbinas eólicas é um dos principais desafios para as usinas, devido à exposição a condições ambientais variáveis e cargas operacionais diversas. Nesse cenário, com a finalidade de detectar anomalias e reduzir problemas decorrentes de desgaste, variações climáticas ou mau uso, é importante realizar um monitoramento contínuo das condições de tais estruturas.

O Monitoramento da Integridade Estrutural (SHM, do inglês *Structural Health Monitoring*) engloba o conjunto de técnicas para a detecção precoce de falhas estruturais [3]. O processo de SHM envolve a utilização de sensores como acelerômetros e extensômetros, que são instalados nas estruturas para coletar dados vibracionais ao longo do tempo, e a partir disso inferir sobre o seu estado de conservação. Essa abordagem baseia-se na premissa de que a degradação altera propriedades físicas e, portanto, as características dinâmicas da estrutura. Com os avanços em aprendizado de máquina e inteligência artificial (IA), os dados tornaram-se mais precisos e acessíveis, facilitando a aplicação de SHM em larga escala [4]. Consequentemente, os 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 [5]. A implementação do SHM pode seguir abordagens supervisionadas ou não supervisionadas, sendo a última preferível, pois geralmente apenas o estado atual da estrutura é conhecido, sem que diversos comportamentos estruturais de referência estejam disponíveis de antemão [6].

Um autocodificador é um modelo de aprendizado não supervisionado projetado para reconstruir dados de entrada e reduzir sua dimensionalidade. Ele comprime informações em uma representação latente de dimensão menor do que os dados originais e os reconstrói a partir dessa forma reduzida. Existem variações específicas, como autocodificadores convolucionais (CAEs, do inglês *Convolutional Autoencoder*), adaptados para processar dados de imagem capturando características espaciais e autocodificadores variacionais (VAEs, do inglês *Variational Autoencoder*), que incorporam uma abordagem probabilística para modelar a distribuição dos dados [7].

Apesar de sua simplicidade, autocodificadores e suas variações são amplamente utilizados em diversas aplicações de aprendizado de máquina, pois identificam efetivamente padrões em dados não rotulados, como sinais dinâmicos coletados em estruturas. Outros trabalhos, como [8], [9] e [10] obtiveram bons resultados ao utilizarem autocodificadores para a detecção de alterações estruturais em turbinas eólicas, demonstrando que essa abordagem é promissora para o SHM. É destacado, no nosso estudo, o Autocodificador Esperso (SAE), um algoritmo de rede neural profunda de natureza de análise não supervisionada, que introduz restrições de regularização para forçar a rede a aprender representações mais eficientes [11]. Além da reconstrução eficiente de entradas, essa abordagem também melhora a capacidade de generalização, evitando overfitting e permitindo uma extração de características mais relevantes dos dados.

Portanto, este artigo busca avaliar a eficácia do SAE na detecção de danos estruturais em uma maquete de turbina eólica. Foram considerados dois tipos de alterações: a introdução de fissuras, representando pás danificadas, e a adição de diferentes quantidades de massa em três posições das pás, simulando o acúmulo de neve. Embora este fenômeno não seja comum no Brasil, é frequente em países frios. Para a análise da adição de massa, as turbinas operaram em cinco diferentes velocidades, enquanto para a análise de fissuras, foram utilizadas quatro velocidades. Nessas investigações, os sinais dinâmicos coletados da maquete de turbina eólica foram inicialmente processados pelo SAE. Um diferencial do nosso estudo é que os dados das camadas latentes do SAE foram utilizados para os cálculos do gráfico da Carta de Controle T^2 de Hotelling (T^2) [12], permitindo a identificação correta tanto da adição de massa quanto da presença de fissuras, independentemente da velocidade da turbina.

2 Fundamentação Teórica

A identificação de alterações estruturais em sistemas dinâmicos 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 Esparso (SAE) para extrair e reduzir as características dos sinais dinâmicos monitorados. Na segunda etapa, foi aplicada a Carta de Controle T de Hotelling (T^2), uma técnica estatística gráfica amplamente utilizada para monitorar processos multivariados, permitindo a detecção objetiva de mudanças estruturais ao comparar os parâmetros extraídos das camadas latentes do SAE com limites estatisticamente estabelecidos. Essa combinação de técnicas proporciona uma abordagem sistemática e 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 [11] e [12].

2.1 Autocodificador Esparso (SAE)

O SAE é uma variação do autocodificador convencional que, além da função de perda tradicional, introduz uma penalidade de esparsidade, o que ajuda o modelo a codificar de forma eficiente as características mais relevantes, enfatizando características distintivas. Essa abordagem é especialmente útil para destacar aspectos fundamentais dos dados, melhorando a capacidade do modelo em discriminar padrões significativos e ruídos.

Durante o treinamento, o SAE impõe uma penalidade de esparsidade $\Omega(\mathbf{h})$ na camada codificada $\mathbf{h}$, junto ao erro de reconstrução, conforme descrito na Eq. (1)

$$\mathcal{L}_{\text{SAE}}(\mathbf{x}) = L(\mathbf{x}, g(f(\mathbf{x}))) + \Omega(\mathbf{h}) \quad (1)$$

onde L é a função de perda que penaliza $g(f(\mathbf{x}))$ por ser diferente de $\mathbf{x}$, $g(f(\mathbf{x}))$ é a saída do decodificador, $\mathbf{h} = f(\mathbf{x})$ é a saída do codificador, e $\Omega(\mathbf{h})$ é a penalidade de esparsidade aplicada.

Ao promover a esparsidade, o SAE simplifica os sinais analisados, facilitando a detecção de mudanças estruturais. Sua habilidade em identificar características distintivas em dados de alta dimensão o torna uma ferramenta valiosa para diversas aplicações, como reconhecimento de padrões e detecção de anomalias em estruturas.

O processo de treinamento do SAE utilizou o Erro Quadrático Médio (MSE) como função de perda. O MSE foi escolhido por sua capacidade de avaliar a precisão da reconstrução ao calcular a média dos quadrados das diferenças entre os valores previstos y_i gerados pelo autocodificador e os valores de entrada reais x_i , conforme definido na Eq. (2). Esta métrica é escolhida por sua sensibilidade a erros maiores, os quais são amplificados pelo processo de elevação ao quadrado, impondo assim uma penalidade proporcional à magnitude do erro. Minimizar o MSE durante o treinamento melhora a capacidade do modelo de reduzir eficazmente a discrepância entre a entrada e a saída reconstruída, melhorando assim sua habilidade de capturar características essenciais e significativas dos dados.

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

2.2 Carta de Controle T de Hotelling (T^2)

As Cartas de Controle T^2 são ferramentas gráficas estatísticas usadas para avaliar a influência de vários parâmetros de um problema ao longo do tempo. Eles exibem múltiplos pontos de dados, compostos por uma característica estatística específica, chamada T^2 , com linhas horizontais separando diferentes classes de cenários estruturais. Neste caso, pontos fora dos intervalos esperados indicam mudanças no comportamento dinâmico da estrutura, sugerindo uma situação indesejada. Sua interpretação é direta e intuitiva, facilitando a interpretação dos resultados e a tomada de decisões pelos usuários. Portanto, dada a sua relevância e aplicabilidade em diversos contextos, o T^2 representa uma ferramenta robusta para identificar e quantificar mudanças estruturais nos sinais analisados, contribuindo para a melhoria da qualidade, eficiência e confiabilidade do SHM.

Neste estudo, o T^2 foi calculado com base nos parâmetros extraídos das camadas latentes do SAE, e sua aplicação permitiu a identificação de mudanças ou danos nos sinais analisados ao comparar os valores observados com limites estatisticamente estabelecidos. A estatística T^2 representa a distância entre uma nova observação de dados e o vetor média amostral correspondente: quanto maior o valor de T^2 , maior é a distância dos novos dados em relação à média. Essa métrica é baseada na relação entre variáveis e na dispersão dos dados (matriz de covariância).

Dada uma matriz $\mathbf{H}_{N \times M}$ representando um conjunto de dados ao longo de um certo período, que, neste estudo, são as características extraídas das camadas latentes do SAE, a estatística T^2 pode ser calculada de acordo com a Eq. (3):

$$T^2 = R(\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}})^T \mathbf{S}^{-1} (\bar{\mathbf{h}} - \bar{\bar{\mathbf{h}}}), \quad (3)$$

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 ($\mathbf{H}_{R \times M}$, $R < N$); $\bar{\mathbf{h}}$ 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 danos estruturais ou outras anomalias. Por esta definição, 5% dos valores de T^2 dos dados de treinamento estarão acima do UCL, o que é aceitável se estiverem próximos ao limite.

3 Metodologia

A metodologia proposta busca avaliar a capacidade do SAE, combinado ao T^2 , de separar, de forma não supervisionada, sinais de vibração pertencentes a diferentes comportamentos dinâmicos estruturais. Isso é feito treinando o modelo com apenas uma parte dos dados da turbina intacta, sem adições de massas ou de fissuras, e testando-o com os dados restantes.

Os dados são divididos em três conjuntos: treinamento, validação e monitoramento, da seguinte forma:

- Fase de treinamento: Nessa etapa, um conjunto de dados do estado intacto da estrutura foi utilizado para treinar o modelo SAE, sendo chamado de conjunto de treinamento.
- Fase de validação: Durante esta fase, um segundo conjunto de dados, também do estado estrutural intacto, foi usado para validar o modelo treinado. O objetivo foi verificar a capacidade do modelo em classificar novos dados, e esperava-se que os valores de T^2 fossem estatisticamente semelhantes para os conjuntos de treinamento e validação, já que ambos representam o mesmo estado estrutural.
- Fase de monitoramento: Nessa fase, conjuntos de dados provenientes de estados estruturais diferentes dos usados nas fases de treinamento e validação foram apresentados ao modelo. Esperava-se que os valores de T^2 fossem maiores, indicando um estado estrutural diferente do utilizado para treinamento.

Durante esse processo de detecção de danos, o modelo compara cada sinal com a classe de referência, derivando uma diferença específica que aumenta gradualmente entre as classes, mas permanece relativamente constante dentro de cada uma delas. Estudos semelhantes, que utilizam diferentes tipos de autocodificadores para a detecção de anomalias estruturais, como o de [7], demonstram resultados promissores para a aplicação da metodologia proposta.

Para garantir a variabilidade estatística no conjunto de dados analisado, foi utilizada a validação cruzada com 10 *folds* para cada estrutura, com o objetivo de obter avaliações mais consistentes e precisas. Como entrada do SAE, foi utilizada a Transformada Rápida de Fourier (*Fast Fourier Transform*, FFT) dos sinais dinâmicos estruturais. Esta escolha se deve ao fato de que as compressões e reconstruções dos sinais apresentaram melhor desempenho no domínio da frequência em comparação ao domínio do tempo. Após aplicar a FFT nas medições de aceleração, todos os dados foram padronizados utilizando a padronização z -score, conforme a Eq. (4):

$$\mathbf{z} = \frac{\mathbf{x} - \mu}{\sigma}, \quad (4)$$

onde $\mathbf{z}$ é o vetor de sinal padronizado, $\mathbf{x}$ é o vetor de sinal original, e μ e σ são o valor médio e o desvio padrão do sinal, respectivamente.

Os modelos do SAE dependem dos seguintes hiperparâmetros: taxa de aprendizado, número de épocas, tamanho do lote (*batch size*), dimensão original, dimensão latente, algoritmo otimizador e parâmetro de esparsidade λ . A seleção dos melhores valores para esses parâmetros foi realizada com o auxílio do *Optuna* [13], uma ferramenta avançada de otimização automática que aplica técnicas de busca inteligente para identificar combinações ideais de hiperparâmetros em modelos de aprendizado de máquina. O processo de otimização no *Optuna* é configurado a partir de intervalos de busca definidos pelo usuário, escolhidos neste trabalho com base em práticas consolidadas na literatura e em experimentos preliminares [7] [14] [15], de acordo com os objetivos da otimização. Após a otimização, os hiperparâmetros ajustados foram aplicados para o treinamento dos autocodificadores.

4 Aplicação em Turbinas Eólicas

Para a realização desse estudo de detecção de alterações estruturais, utilizou-se uma maquete de turbina eólica, ensaiada pelos autores, simulando as características gerais de uma turbina de baixa capacidade (Fig. 1). Essa configuração foi escolhida para facilitar o controle sobre a velocidade de rotação, danos, adição de massas e ângulos de inclinação das pás. A turbina é composta por uma torre de aço de 3 metros de altura e três pás (A, B e C) feitas de compósito de fibra de vidro e resina epóxi, cada uma com 2,4 metros de comprimento e pesando 12 kg. O sistema de rotação inclui um motor de 1 HP acoplado a uma caixa de engrenagens com redução de 1:10 e um eixo de transmissão que faz o

cubo girar. As pás estão conectadas ao mecanismo de rotação através de um cubo hexagonal de aço, que permite ajustes manuais de ângulos de inclinação em posições fixas de 36° . A velocidade de rotação é controlada por um inversor de frequência, com uma faixa de velocidade de 0 a 60 RPM [16].

O sistema de aquisição de dados instalado no cubo de aço inclui sensores de temperatura AM2302 / DS18B20 e sensores de aceleração ADXL345. Este sistema registra dados a uma frequência de amostragem de 200 Hz durante 10 minutos, seguido por um período de transmissão de dados de igual duração, totalizando um ciclo de medição de 20 minutos.

Foram realizadas duas análises distintas para avaliar a resposta dinâmica das pás de uma turbina eólica. Na primeira análise, foram adicionadas massas à pá C e observadas as respostas dinâmicas nas pás B e C. Na segunda análise, foram criadas fissuras na pá A e comparados os sinais de vibração da pá A intacta com os sinais após a introdução das fissuras, enquanto a pá B permaneceu intacta em ambas as análises. Cada pá foi equipada com uma tira de três sensores de aceleração. Na Fig. 2 são apresentadas as localizações das massas (P1 a P9), das fissuras e dos sensores de aceleração nas pás (S1, S2 e S3). Cada sensor mediu as acelerações em duas direções: x (na borda) e z (perpendicular ao plano de rotação da pá).



Figura 1: Maquete de turbina eólica ensaiada pelos autores.




Figura 2: Distribuição dos sensores de aceleração (S1, S2, S3), pontos de adição de massas na pá C (P1 a P9) e localizações das fissuras na pá A da turbina.

4.1 Adição de massas

Para investigar o impacto do acúmulo de neve nas pás de turbinas eólicas, foram adicionadas massas ao longo da pá C para replicar as condições reais enfrentadas em ambientes frios, onde o material acumulado pode aumentar significativamente a carga nas pás.

Com a finalidade de representar a distribuição desigual de neve, a análise incluiu 50 casos distintos de distribuições de massa (M1 a M50), conforme a Tabela 1. Em cada caso, foram realizadas três medições nas rotações de 15, 24, 32, 42 e 53 RPM, durante 10 minutos com uma taxa de amostragem de 200 Hz. Dessa forma, foram coletados 150 sinais com 120.000 pontos para cada rotação. Posteriormente, os sinais foram segmentados em 24 partes de 5.000 pontos cada, totalizando 3.600 sinais de 5.000 pontos para cada rotação. Um exemplo de sinal segmentado da estrutura sem massas para cada velocidade é apresentado na Fig. 3.




Figura 3: Cartas de Controle T^2 para a adição de massas. (a) 15 RPM. (b) 24 RPM. (c) 32 RPM. (d) 42 RPM. (e) 53 RPM.

Tabela 1: Casos de adição de massas

Caso	P1	P2	P3	P4	P5	P6	P7	P8	P9	Total	Caso	P1	P2	P3	P4	P5	P6	P7	P8	P9	Total
1	0.5	1.5	2.0	2.5	2.5	3.0	3.0	3.0	2.5	20.50	26	26.2	50.8	72.1	89.1	102.2	109.7	112.5	109.7	101.8	774.60
2	1.0	1.5	2.0	3.0	3.5	3.5	3.5	3.0	3.0	24.00	27	25.7	52.0	76.1	96.1	111.1	120.2	124.0	121.7	113.5	840.40
3	1.0	2.0	3.0	3.5	4.0	4.5	4.5	4.0	4.0	31.00	28	26.2	53.0	77.5	97.8	111.6	122.0	125.5	123.2	114.9	852.70
4	1.0	2.0	3.0	4.0	4.5	5.0	5.0	4.5	4.5	34.00	29	23.2	50.3	76.6	99.3	116.6	128.1	133.3	131.7	123.6	882.70
5	1.0	2.0	3.0	4.0	4.5	5.0	5.0	4.5	4.5	34.00	30	26.2	54.5	81.0	102.7	119.1	129.5	133.8	131.5	124.9	901.30
6	1.5	2.5	3.0	4.1	4.5	5.5	5.5	5.5	5.0	42.90	31	32.1	61.3	86.0	112.1	125.8	139.1	150.8	149.4	140.2	952.90
7	3.5	5.9	9.0	11.1	13.0	14.1	14.6	14.5	13.6	98.80	32	25.7	56.2	89.0	112.1	131.9	145.0	150.8	149.4	140.2	997.30
8	4.1	8.1	12.0	14.8	16.9	18.0	18.6	18.1	17.0	127.60	33	30.1	61.9	91.6	115.6	133.5	145.0	149.3	147.0	136.9	1,010.60
9	4.1	8.1	12.5	15.9	18.5	20.3	20.9	20.8	19.1	140.20	34	33.2	65.3	94.2	117.6	134.8	145.4	149.0	145.6	135.7	1,020.80
10	5.1	9.0	14.0	17.0	19.5	20.9	21.4	20.8	19.1	147.70	35	30.0	62.9	93.9	115.9	139.1	151.8	156.8	154.4	144.6	1,053.00
11	5.5	10.2	15.5	18.0	22.0	27.3	30.0	30.9	30.5	206.30	36	41.1	77.8	109.9	135.2	153.6	164.6	168.1	163.8	151.6	1,165.70
12	7.6	15.5	23.0	28.5	32.8	35.4	36.5	36.0	33.5	248.80	37	35.6	73.0	107.2	135.9	157.2	170.7	176.2	173.0	161.6	1,190.40
13	9.9	18.4	27.0	32.8	39.4	43.2	39.9	39.1	36.4	277.90	38	33.2	70.3	105.7	135.4	158.2	172.8	179.1	176.5	165.1	1,196.30
14	10.0	19.0	27.0	33.5	38.4	41.1	42.3	41.1	37.1	290.80	39	41.8	79.8	113.1	139.7	159.1	170.7	174.1	170.7	157.8	1,206.10
15	10.0	20.0	29.0	36.3	41.5	45.0	45.9	44.9	41.9	314.50	40	34.7	72.5	108.5	138.5	161.2	175.7	181.7	179.2	167.3	1,219.30
16	11.0	21.5	31.0	38.4	44.1	47.8	49.1	48.1	45.4	336.40	41	32.1	69.9	105.3	137.2	161.9	176.1	181.9	178.4	166.1	1,208.90
17	13.2	25.3	36.0	43.1	48.8	52.0	53.7	52.3	49.4	374.90	42	31.7	67.7	103.9	137.3	162.2	175.6	181.9	179.1	167.7	1,207.10
18	14.1	27.3	37.5	46.2	52.1	56.1	57.5	56.5	53.0	400.30	43	39.1	76.2	110.1	140.5	161.5	171.0	173.2	171.8	159.9	1,208.80
19	15.5	29.5	40.3	48.5	55.2	60.0	62.1	60.5	57.1	428.70	44	37.3	73.6	108.1	138.7	161.5	171.3	174.7	172.4	161.7	1,199.30
20	17.0	32.0	44.0	53.2	61.0	66.7	68.9	67.5	63.0	474.00	45	40.3	80.1	114.9	144.6	165.4	174.1	175.3	172.5	161.5	1,228.70
21	18.0	33.8	46.5	55.3	63.8	69.3	71.9	70.1	65.8	494.60	46	35.2	75.0	109.8	141.3	162.3	170.8	172.6	170.1	158.0	1,215.10
22	20.0	37.2	51.0	60.0	68.8	74.9	77.5	75.5	71.0	536.00	47	35.5	73.9	109.6	142.3	164.1	175.3	179.3	176.1	166.5	1,221.20
23	22.0	39.9	54.0	62.0	72.0	78.1	80.2	77.5	72.2	558.10	48	34.1	72.6	108.5	141.0	161.9	171.2	173.6	170.3	159.7	1,193.00
24	23.0	41.0	55.3	64.0	74.0	81.3	83.2	81.1	75.5	578.40	49	37.8	79.8	115.3	148.3	170.1	177.1	177.2	173.4	162.2	1,241.20
25	24.5	46.3	68.0	83.1	97.3	107.1	112.9	112.5	104.1	756.80	50	36.0	76.8	111.0	143.7	164.8	173.5	175.3	171.6	161.1	1,214.80

Inicialmente, para cada combinação específica de sensor, direção e velocidade, um modelo foi treinado utilizando 70% dos dados da pá B (sem dano), totalizando 2.520 sinais. Os 30% restantes dos dados, correspondendo a 1.080 sinais, foram reservados para validação. Para testar e analisar a identificação de danos, foram utilizados 3.600 sinais da pá A (com massas), mantendo as mesmas condições de sensor, direção e velocidade dos dados de treinamento. Essa abordagem permitiu avaliar o desempenho do modelo na detecção de alterações estruturais em uma única velocidade.

Em seguida, para cada combinação de sensor e direção, abrangendo todas as velocidades, um modelo foi treinado utilizando 70% dos dados da pá B (sem dano), totalizando 12.600 sinais. Os 30% restantes, correspondendo a 5.400 sinais, foram utilizados para validação. Para a análise de identificação de danos, foram utilizados 18.000 sinais da pá A (com massas), mantendo as mesmas condições de sensor e direção dos dados de treinamento. Essa abordagem permitiu avaliar o desempenho do modelo na detecção de alterações estruturais em todas as cinco velocidades.

4.2 Criação de fissuras

Para simular danos estruturais nas pás da turbina eólica, que podem ocorrer devido à fadiga do material, impactos de detritos ou outros fatores ambientais e operacionais, foram induzidas fissuras ao longo das pás. Esses danos foram avaliados em diferentes velocidades de rotação, conforme a Tabela 2 e a Fig. 2. Em cada velocidade, foram realizadas 65 medições durante 10 minutos com uma taxa de amostragem de 200 Hz. Assim, foram coletados 65 sinais, cada um com 120.000 pontos para cada rotação. Posteriormente, cada sinal foi dividido em 23 segmentos de 5.000 pontos, totalizando 1.472 sinais de 5.000 pontos para cada rotação.

Tabela 2: Casos de Teste de Fissuras.

Caso	Descrição	Velocidades
0	Estado saudável	15, 30, 45 e 60
1	Fissura 1 = 2 cm	15, 30, 45 e 60
2	Fissura 1 = 5 cm	15 e 45
3	Fissura 1 = 5 cm, Fissura 2 = 2 cm, Fissura 3 = 2 cm	15 e 45
4	Fissura 1 = 5 cm, Fissura 2 = 5 cm, Fissura 3 = 5 cm	15, 30, 45 e 60
5	Fissura 1 = 10 cm, Fissura 2 = 8 cm, Fissura 3 = 5 cm	15 e 45
6	Fissura 1 = 10 cm, Fissura 2 = 8 cm, Fissura 3 = 10 cm	15, 30, 45 e 60

Para cada combinação específica de sensor, direção e velocidade, um modelo foi treinado utilizando 70% dos dados da pá A, em condição intacta, resultando em um total de 1.030 sinais. Os 30% restantes dos dados, correspondendo a 442 sinais, foram reservados para validação. Para testar e analisar a eficácia na identificação de danos, foram utilizados 1.472 sinais da pá A, desta vez com fissuras, mantendo a mesma configuração de sensor, direção e velocidade aplicada durante o treinamento. Essa metodologia permitiu avaliar o desempenho do modelo na detecção de alterações estruturais sob uma condição de velocidade constante.

5 Resultados

Os resultados das análises foram representados utilizando a Carta de Controle T^2 , demonstrando a capacidade do modelo em identificar alterações estruturais em diferentes condições de operação e tipos de danos. A Fig. 4 (a) ilustra o gráfico para o acelerômetro 3 na direção Z sob uma velocidade de 60 RPM. Uma vez que os resultados das demais combinações de sensores, direções e velocidades apresentaram padrões semelhantes, seus gráficos não foram apresentados. Os valores de T^2 para os dados de treinamento e validação apresentam-se próximos, validando a confiabilidade do modelo, pois ambos os conjuntos representam o estado intacto da estrutura. Além disso, os valores de T^2 para a pá com massas são significativamente mais elevados, refletindo o impacto das massas na dinâmica estrutural das pás e evidenciando o aumento da carga e as mudanças nas propriedades vibracionais resultantes. No entanto, a diferença observada entre as condições de distribuição de massa é relativamente limitada, indicando que o modelo foi capaz de identificar a presença de danos, mas não conseguiu quantificar a gravidade ou a distribuição exata dos mesmos.

Na Fig. 4 (b), é apresentado o gráfico referente ao acelerômetro 1 na direção X para todas as velocidades. Resultados semelhantes foram observados para outras combinações de sensores e direções. Ainda segundo a Fig. 4, após

treinamento simultâneo com as cinco velocidades, o modelo foi capaz de identificar alterações em todas elas.




Figura 4: Cartas de Controle T^2 para a adição de massas. (a) Acelerômetro 3 na direção Z a 60 RPM. (b) Acelerômetro 1 na direção X para todas as velocidades.

As Figuras 5 e 6 corroboram com os resultados observados na Fig. 4, demonstrando que, de maneira semelhante ao que foi identificado com as massas, o modelo também foi capaz de detectar fissuras e manteve a proximidade dos valores de T^2 entre os dados de treinamento e os dados de validação. Porém, observa-se uma diferença nos valores de T^2 entre as classes de dano, como evidenciado na Fig. 5 (c). Esses resultados indicam que o modelo não só foi eficaz na identificação da presença das fissuras, mas também conseguiu quantificar a gravidade dos danos com precisão significativa.




Figura 5: Resultados da análise de fissuras para a direção X. (a) 15 RPM; (b) 30 RPM; (c) 45 RPM; (d) 60 RPM.




Figura 6: Resultados da análise de fissuras para a direção Z. (a) 15 RPM; (b) 30 RPM; (c) 45 RPM; (d) 60 RPM.

6 Conclusões

Este estudo explorou a aplicação do Autocodificador Esparso (SAE) em conjunto com a Carta de Controle T^2 de Hotelling como uma metodologia robusta e eficiente para a detecção de danos estruturais em turbinas eólicas. Por meio de simulações que incluíram a adição de massas e a introdução de fissuras em protótipos de pás das turbinas, foi possível avaliar o desempenho da metodologia proposta em diferentes cenários de operação e de falhas estruturais.

Este estudo investigou a eficácia do Autocodificador Esparso (SAE) combinado com a Carta de Controle T^2 de Hotelling (T^2) na detecção de danos estruturais em turbinas eólicas. Através de simulações que incluíram a adição de massas e a introdução de fissuras em protótipos de pás de uma turbina, foi possível avaliar o desempenho da metodologia proposta em diferentes cenários de funcionamento.

Os resultados demonstraram que o modelo SAE, treinado de forma não supervisionada com dados de turbinas intactas, apresentou alta precisão na identificação de anomalias estruturais introduzidas nas simulações. A aplicação do T^2 permitiu uma detecção eficiente das alterações, evidenciando a capacidade do modelo de diferenciar estados saudáveis e danificados, independentemente da velocidade de rotação analisada. Isso indica que a metodologia proposta é eficaz para detectar alterações estruturais, oferecendo uma abordagem promissora para sistemas SHM em turbinas eólicas.

Essa metodologia proporciona uma alternativa robusta para a manutenção preditiva, pois permite detectar danos em estágios iniciais e otimizar a tomada de decisões sobre intervenções de manutenção. Além disso, os resultados sugerem que essa metodologia pode ser expandida para monitorar diferentes tipos de estruturas sujeitas a condições adversas e variáveis.

Pesquisas futuras podem utilizar outras variações de autocodificadores e aplicar a metodologia em condições climáticas diversas, ampliando o entendimento sobre sua eficácia em cenários reais e diversos de operação. Dessa forma, a integração de autocodificadores esparsos com ferramentas de controle estatístico contribui para as práticas de manutenção preditiva, garantindo maior segurança e prolongamento da vida útil das turbinas eólicas, contribuindo para o monitoramento da integridade estrutural.

7 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] Y. Ou, E. N. Chatzi, V. K. Dertimanis, e M. D. Spiridonakos, “Vibration-based experimental damage detection of a small-scale wind turbine blade,” *Structural Health Monitoring*, vol. 16, no. 1, pp. 79–96, 2017. Disponível em: <https://doi.org/10.1177/1475921716663876>
- [2] Y. Lee, C. Park, N. Kim, J. Ahn, e J. Jeong, “LSTM-autoencoder based anomaly detection using vibration data of wind turbines,” *Sensors (Basel)*, vol. 24, no. 9, p. 2833, 2024. Disponível em: <https://doi.org/10.3390/s24092833>
- [3] 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: Maintenance, Management, Life-Cycle Design and Performance*, vol. 18, no. 4, pp. 554–572, 2022. Disponível em: <https://doi.org/10.1080/15732479.2021.1978507>
- [4] 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, no. 3, pp. 275–286, 2015. Disponível em: <https://doi.org/10.1007/s13349-015-0103-1>
- [5] 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, no. 2, pp. 207–215, 2017. Disponível em: <https://doi.org/10.1007/s13349-017-0215-x>
- [6] R. P. Finotti, F. d. 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 (Basel)*, vol. 11, no. 24, p. 11965, 2021. Disponível em: <https://doi.org/10.3390/app112411965>
- [7] 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>
- [8] A. Oliveira-Filho, R. Zemouri, P. Cambron, e A. Tahan, “Early detection and diagnosis of wind turbine abnormal conditions using an interpretable supervised variational autoencoder model,” *Energies*, vol. 16, no. 12, p. 4544, 2023. Disponível em: <https://doi.org/10.3390/en16124544>
- [9] J. E. Urrea Cabus, Y. Cui, e L. B. Tjernberg, “An anomaly detection approach based on autoencoders for condition monitoring of wind turbines,” em *2022 17th International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2022, pp. 1–6.
- [10] M. D. C. Feijóo, Y. Zambrano, Y. Vidal, e C. Tutivén, “Unsupervised damage detection for offshore jacket wind turbine foundations based on an autoencoder neural network,” *Sensors (Basel)*, vol. 21, no. 10, p. 3333, 2021. Disponível em: <https://doi.org/10.3390/s21103333>
- [11] I. Goodfellow, Y. Bengio, e A. Courville, *Deep Learning*. MIT Press, 2016, <http://www.deeplearningbook.org>.
- [12] D. C. Montgomery, *Introduction to Statistical Quality Control*. Wiley, 2019.
- [13] T. Akiba, S. Sano, T. Yanase, T. Ohta, e M. Koyama, “Optuna,” em *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York, NY, USA: ACM, Jul. 2019.
- [14] 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>
- [15] R. P. Finotti, C. F. d. Silva, P. H. E. Oliveira, F. d. 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, 2023. Disponível em: <https://doi.org/10.1590/1679-78257591>
- [16] J. M. Gutiérrez, R. Astroza, F. Jaramillo, M. Orchard, e M. Guarini, “Evolution of modal parameters of composite wind turbine blades under short- and long-term forced vibration tests,” *Journal of Civil Structural Health Monitoring*, vol. 14, no. 4, pp. 1059–1074, Apr. 2024. Disponível em: <https://doi.org/10.1007/s13349-024-00773-1>