

ESTRATÉGIA BASEADA EM SELEÇÃO DE CARACTERÍSTICAS PARA LOCALIZAÇÃO DE DETERIORAÇÃO ESTRUTURAL

FEATURE SELECTION-BASED STRATEGY FOR LOCATING STRUCTURAL DETERIORATION

VICTOR HIGINO MENEGUITTE ALVES¹
ALEXANDRE ABRAHÃO CURY²

DOI:

ENVIADO EM: FEBRUARY, 9, 2023

APROVADO EM: SEPTEMBER, 6, 2023

RESUMO

Recentemente, técnicas de detecção de danos estruturais têm sido impulsionadas pelos avanços nas tecnologias de ciência de dados. Neste contexto, o presente estudo apresenta uma metodologia automática de localização de danos baseada na extração de características de dados dinâmicos em multi-domínios associado a um processo de filtragem. A etapa de extração é realizada simultaneamente nos domínios do tempo, frequência e quefrência como forma de diversificar a aquisição de informações relevantes. Em aprendizado de máquinas, este procedimento de filtragem é chamado de “seleção de características” e é aplicado aqui com o objetivo de diminuir a redundância e aumentar a relevância do conjunto de características. O conceito principal é que o método proposto pode se adaptar à estrutura, fornecendo generalidade sobre o tipo de geometria, material e excitação. Um índice sensível ao dano é construído a partir de uma análise de *outliers*. O método mostrou-se promissor em localizar anomalias no viaduto Z24, uma das estruturas icônicas utilizadas para a avaliação de métodos de identificação de danos.

Palavras-chave: Monitoramento da Saúde Estrutural, Localização de Dano, Seleção de Características, Multi-domínio, Automático.

ABSTRACT

Recently, structural damage detection techniques have been boosted by advances in data science technologies. In this context, the present study presents an automatic damage localization methodology based on the extraction of features from dynamic data in multi-domains associated with a filtering process. The extraction step is performed simultaneously in time, frequency, and quefrency, to diversify the acquisition

¹ Graduando em Engenharia Civil. Bolsista do Programa PIBIC. Membro Grupo de Pesquisa em Ciência de Dados aplicada à Engenharia (CIDENG - CNPq). victor.meneguitte@engenharia.ufjf.br

² Orientador do projeto de IC. Professor do Departamento de Mecânica Aplicada e computacional da UFJF. Endereço profissional: Universidade Federal de Juiz de Fora, Faculdade de Engenharia, Departamento Mecânica Aplicada e Computacional, São Pedro, Rua José Lourenço Kelmer, CEP: 36.036-900 - Juiz de Fora, MG – Brasil. alexandre.cury@ufjf.br

of information. In machine learning, this filtering procedure is called “feature selection” and is applied here with the aim of decreasing redundancy and increasing the relevance of the feature set. The main concept is that the proposed method can adapt to the structure, providing generality about the type of geometry, material, and excitation it encounters. The damage-sensitive index is calculated from a proposed outlier analysis. The method showed promise in locating anomalies on the Z24 bridge, a full-scale construction.

Keywords: Structural Health Monitoring, Damage Localization, Feature Selection, Multi-domain, Automated.

1 INTRODUÇÃO

A vida útil de uma determinada estrutura depende de uma variedade de fatores, incluindo clima, uso, projeto, dentre outros fatores que são difíceis de prever e, às vezes, impraticáveis de avaliar. Como resultado, os sistemas de Monitoramento de Saúde Estrutural (*i.e.*, *Structural Health Monitoring* - SHM) em tempo real têm atraído atenção considerável de cientistas em uma variedade de áreas de pesquisa, incluindo engenharia civil, aeroespacial e estrutural. Desenvolvimentos recentes na tecnologia de sensores tendem a melhorar a robustez e oferecer preços cada vez mais acessíveis para a implementação em aplicações de grande escala. Esta é uma conquista notável, pois a localização se torna mais precisa quanto mais sensores forem dispostos em um determinado edifício.

“Orientado por modelo” ou “orientado por dados” são as duas classificações principais de SHM. Esta primeira envolve o desenvolvimento de um modelo em elementos finitos (MEF) da estrutura que frequentemente está relacionado a um procedimento de atualização do modelo (Alves et al., 2020). A abordagem baseada em dados, por outro lado, emprega medições de vibração (como aceleração ou deslocamento), frequentemente usando extração de características (também denominadas no presente trabalho pelos termos: características e recursos) combinada a um tipo de abordagem de reconhecimento de padrões. Os métodos baseados em dados geralmente fornecem uma solução mais viável para a identificação da deterioração devido à complexidade de se construir e atualizar modelos computacionais e às inevitáveis diferenças entre as propriedades de vibração da estrutura real e do modelo em elementos finitos (Alves, Cury e Cremona, 2016). Assim, esta

pesquisa propõe uma abordagem multi-domínio totalmente automatizada e baseada puramente em dados para localizar a deterioração estrutural. Esta abordagem é aprimorada com uma técnica de seleção de características concebida para funcionar de maneira não-supervisionada, isto é, sem qualquer conhecimento prévio acerca da condição da estrutura.

2 ABORDAGEM MULTI-DOMÍNIO

A eficácia da etapa de extração tem um grande impacto em todas as técnicas baseadas em características. Portanto, torna-se uma ideia atraente dividir o número de características em vários domínios, ou seja, domínios de tempo, frequência e quefrência. Espera-se que essa associação multi-domínio melhore a representação do conjunto de recursos das respostas dinâmicas (ou seja, sinais de aceleração), pois uma mudança estrutural (por exemplo, na rigidez, devido à deterioração local) pode influenciar todos esses domínios simultaneamente.

2.1 Características no domínio do tempo

Para reunir o máximo possível de informações e nuances sobre os sinais de vibração, este artigo usa uma variedade de estatísticas no domínio do tempo avaliadas diretamente dos dados de aceleração. Normalmente, seu cálculo possui baixa complexidade. Parte dessas estatísticas foram testadas e mostraram resultados promissores para a tarefa de detecção de danos na pesquisa recente de Nunes et al. (2020). No presente estudo, o desafio é a localização do dano, o qual necessita uma análise mais sofisticada dos dados; assim, aumentou-se o número de estatísticas usadas em relação ao trabalho anterior. Um total de 17 características do domínio do tempo são extraídas (listadas na Tabela 1).

Tabela 1 – Formulação das características no domínio do tempo

Característica	Formulação	Característica	Formulação
Pico (PE)	$Y_{PE} = \max(\mathbf{y}_i)$	Curtose (KU)	$Y_{KU} = \frac{\sum_{i=1}^N (\mathbf{y}_i - Y_{\mu})^4}{(N - 1)Y_{\sigma}^4}$
Raíz da média dos quadrados (RMS)	$Y_{RMS} = \left(\frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^2 \right)^{\frac{1}{2}}$	5º Momento (5th M)	$Y_{5^{th}m} = \frac{\sum_{i=1}^N (\mathbf{y}_i - Y_{\mu})^5}{(N - 1)Y_{\sigma}^5}$
Quadrado da média das raízes (SMR)	$Y_{SMR} = \left(\frac{1}{N} \sum_{i=1}^N \mathbf{y}_i ^{\frac{1}{2}} \right)^2$	6º Momento (6th M)	$Y_{6^{th}m} = \frac{\sum_{i=1}^N (\mathbf{y}_i - Y_{\mu})^6}{(N - 1)Y_{\sigma}^6}$
Alcance (RG)	$Y_{RG} = \max(\mathbf{y}_i) - \min(\mathbf{y}_i)$	7º Momento (7th M)	$Y_{7^{th}m} = \frac{\sum_{i=1}^N (\mathbf{y}_i - Y_{\mu})^7}{(N - 1)Y_{\sigma}^7}$
Média (M)	$Y_M = \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i$	Fator de forma (SF)	$Y_{SF} = \frac{Y_{RMS}}{\frac{1}{N} \sum_{i=1}^N \mathbf{y}_i }$
Média quadrada (MS)	$Y_{MS} = \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^2$	Fator de crista (CF)	$Y_{CF} = \frac{\max(\mathbf{y}_i)}{Y_{RMS}}$
Variância (VAR)	$Y_{\sigma^2} = \frac{1}{N - 1} \sum_{i=1}^N \mathbf{y}_i - Y_{\mu} ^2$	Fator de impulso (IF)	$Y_{IF} = \frac{\max(\mathbf{y}_i)}{\frac{1}{N} \sum_{i=1}^N \mathbf{y}_i }$
Desvio padrão (SD)	$Y_{\sigma} = \sqrt{Y_{\sigma^2}}$	Fator de latitude (LF)	$Y_{LF} = \frac{\max(\mathbf{y}_i)}{Y_{SMR}}$
Assimetria (SK)	$Y_{SK} = \frac{\sum_{i=1}^N (\mathbf{y}_i - Y_{\mu})^3}{(N - 1)Y_{\sigma}^3}$		

Fonte: Autores

2.2 Características no domínio da frequência

A metodologia proposta visa obter características valiosas das respostas no domínio da frequência, além daquelas no domínio do tempo. Portanto, as respostas de aceleração são usadas para calcular as conhecidas Densidades Espectrais de Potência (PSD, em inglês). Sendo uma ferramenta comumente utilizada no campo do processamento de sinais, as PSD são regularmente utilizadas para representar a distribuição de um sinal na frequência. O trabalho de Beskhyroun et al. (2005) é sugerido para um conhecimento mais profundo

acerca das PSD aplicadas ao SHM. Os recursos relacionados à frequência são recuperados das já mencionado PSD por meio de uma análise dos k picos mais altos. A hipótese chave é que mudanças nos k picos mais altos causam mudanças na PSD, frequentemente associadas a um comportamento anômalo de vibração estrutural, indicando possíveis pontos de dano. Um vetor de distância \mathbf{D} é calculado entre picos sucessivos como mostra a Equação 1, onde k é um número inteiro e h_i é a localização do i -ésimo pico no PSD (levando em conta a ordem de frequência ascendente).

$$\begin{aligned}\mathbf{D} &= [(h_2 - h_1), (h_3 - h_2), \dots, (h_{i-1} - h_i), \dots, (h_k - h_{k-1})]^T \\ &= [d_1, d_2, \dots, d_i, \dots, d_{k-1}]^T \\ &\text{para } i = 1, 2, \dots, k - 1.\end{aligned}\quad (1)$$

onde d_i é a distância euclidiana entre os picos $(i + 1)$ e i . Assim, um vetor \mathbf{D} de dimensão $(k-1)$ é produzido a partir de um dado conjunto de k picos.

Como resultado, cinco propriedades relacionadas à frequência são recuperadas de \mathbf{D} : média, desvio padrão, variação, assimetria e curtose. Este método é repetido duas vezes para aumentar a quantidade de detalhes na análise. Conforme mostrado em Alves e Cury (2021), ajustar o parâmetro k para 6 e 8 tende a produzir resultados aceitáveis. Por fim, são extraídas dez características relacionadas ao domínio da frequência. Observa-se que o mesmo pico pode ser calculado várias vezes devido à sua largura, e que picos pouco espaçados podem influenciar o resultado. Para resolver este problema, foi considerada uma distância mínima entre os picos igual a 50 pontos.

2.3 Características no domínio quefrência

O Coeficiente Cepstral de Frequência Mel (MFCC), que pertence ao domínio *quefrência*, é adicionado para completar a coleção de características para a abordagem multi-domínio. O uso inicial de recursos baseados em MFCC com foco na identificação de danos pode ser atribuído a Zhang, Harichandran e Ramuhalli (2011), que desenvolveram algoritmos de cancelamento de ruído e detecção de danos em tabuleiros de pontes de concreto. Naquela pesquisa, os MFCC superaram outros recursos examinados em termos de repetibilidade e separabilidade.

As etapas abaixo (Sahidullah e Saha, 2012) ilustram como calcular o MFCC resumidamente:

I. Janela: Uma janela de Hamming é usada para multiplicar o sinal.

II. Cálculo do espectro de potência: calcular os coeficientes discretos da transformada de Fourier (DFT) de um sinal (janela), que são subsequentemente utilizados para calcular o espectro de potência.

III. Banco de filtros de energia Log: O espectro de energia é processado através de um filtro triangular baseado na escala Mel.

IV. Transformada discreta de cosseno (DCT): calcular a DCT da lista de espectro de log Mel;

V. Obtenção das características MFCC.

Recomenda-se examinar a literatura (Sahidullah e Saha, 2012) para uma análise mais aprofundada dos cálculos necessários. Nesta pesquisa, nove características do domínio da *quefrência* são empregadas.

3 SELEÇÃO DE CARACTERÍSTICAS

É claro que a abordagem proposta depende da capacidade de as características extraídas representarem as mudanças locais no comportamento estrutural causadas por danos. Para resolver o problema de relevância, a técnica de Seleção de Características (FS, do inglês “*feature selection*”) é introduzida. O FS está se tornando uma solução indispensável para gerenciar projetos com bancos de dados extensos e em expansão (*Big Data*). Essa técnica é excelente para remover recursos desnecessários e evitar o superajuste de dados (do inglês, *overfitting*). Os métodos FS são frequentemente divididos em três categorias básicas: filtro, *wrapper* e *embedded*. Abordagens do tipo filtro escolhem recursos desprovidos de qualquer mecanismo de aprendizado e independente do modelo de classificação. Medidas da teoria da informação são usadas para examinar as variáveis nesta situação, e as melhores características são então escolhidas enquanto as menos importantes são descartadas. Esta categoria é utilizada no presente estudo, pois é conhecida por ser rápida e não ser afetada por um

classificador específico, o que a torna ideal para a implementação de FS em aplicações do mundo real envolvendo localização de danos estruturais.

3.1 Seleção infinita de características não-supervisionada (Inf-FS_U)

O Inf-FS_U é uma metodologia de seleção de recursos do tipo filtro não-supervisionado. Isso implica em tratar subconjuntos de características como um caminho em um grafo totalmente conectado, onde os nós são características e as arestas avaliam o relacionamento entre dois nós vinculados em termos de métricas de relevância e redundância. O processo de cálculo detalhado é demonstrado no estudo de Roffo et al. (2021), que realizou testes em vários conjuntos de dados de *benchmark* e indicou que Inf-FS_U superou várias outras abordagens FS bem conhecidas. Para a presente pesquisa, o conjunto de recursos selecionados é determinado pelos 80% superiores (forma truncada) em relação às suas pontuações.

4 METODOLOGIA

As 36 características multi-domínio escolhidas neste trabalho são filtradas aplicando Inf-FS_U, deixando as 28 características mais bem ranqueadas para avaliar o índice de dano. Observe-se que cada sensor tem a sua própria classificação. O sistema de identificação de *outliers* empregado nesta pesquisa é baseado naquele apresentado em Alves e Cury (2021).

4.1 Intervalos percentis

Os percentis podem ser usados para dividir uma distribuição de frequência de amostra em duas seções. Em essência, o percentil P_k é um número que $k\%$ de todas as amostras fica abaixo dele, onde $0 < k \leq 100$. Os mais comuns são o primeiro quartil, a mediana e o terceiro quartil, que correspondem a P_{25} , P_{50} e P_{75} , respectivamente. Vale notar que o intervalo interquartil é dado por $(P_{75} - P_{25})$. A medida percentil foi escolhida porque não é afetada por pontos *outliers*, que significam uma amostra de comportamento anormal. É uma métrica poderosa, pois tende a eliminar a influência do ruído no sinal induzido por

flutuações ambientais (por exemplo, temperatura e velocidade do vento) ou tráfego de veículos.

O intervalo percentil, $[P_L, P_U]$ é definido como critério para representar a tendência de comportamento saudável da estrutura no presente trabalho. De fato, para um intervalo definido por pares extremos P_L e P_U , a probabilidade de encontrar uma amostra específica dentro dele é $(U - L)\%$. Para uma técnica automatizada, um intervalo de 85% é empregado como linha de base, o que significa que para todos os testes analisados, o intervalo $[P_{7,5}, P_{92,5}]$ foi selecionado com base no padrão dos dados saudáveis. Este parâmetro é avaliado de acordo com pesquisas anteriores (Alves e Cury, 2021), nas quais experimentos em vários intervalos revelaram que uma pequena modificação ($\sim 5\%$) não influencia significativamente os resultados.

4.2 Índice de dano

Como já mencionado, os intervalos percentis são obtidos usando as características de estado saudável F^h . Portanto, o índice de deterioração é calculado para cada sensor (ou seja, acelerômetro) com base no número de características no estado danificado F^d que estão além do intervalo compreendido entre $[P_L, P_U]$. Para um determinado sensor, é essencial particionar todo o seu sinal em N amostras; assim, após a extração das características, há uma distribuição de amostras da mesma característica para oferecer a criação de seu intervalo e posterior análise de *outliers*. Na notação matricial, os recursos, ou seja, F^h e F^d , são descritos como na Equação 2.

$$F^h = [f_1^h, f_2^h, \dots, f_i^h, \dots, f_s^h] \text{ e } F^d = [f_1^d, f_2^d, \dots, f_i^d, \dots, f_s^d], \quad (2)$$

Para $i = 1, 2, \dots, s$.

onde s é o número total de sensores montados ao longo da construção, sendo as definições das matrizes f_i^h e f_i^d dadas pela Equação 3.

$$f_i^h = \begin{bmatrix} g_{1,1}^h & \cdots & g_{1,j}^h & \cdots & g_{1,nf}^h \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ g_{n,1}^h & \cdots & g_{n,j}^h & \cdots & g_{n,nf}^h \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ g_{N,1}^h & \cdots & g_{N,j}^h & \cdots & g_{N,nf}^h \end{bmatrix} \text{ e } f_i^d = \begin{bmatrix} g_{1,1}^d & \cdots & g_{1,j}^d & \cdots & g_{1,nf}^d \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ g_{n,1}^d & \cdots & g_{n,j}^d & \cdots & g_{n,nf}^d \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ g_{N,1}^d & \cdots & g_{N,j}^d & \cdots & g_{N,nf}^d \end{bmatrix} \quad (3)$$

para $j = 1, 2, 3, \dots, nf$ e $n = 1, 2, 3, \dots, N$.

onde nf é o número total de características extraídas de cada amostra de sinal (36 características para este trabalho), e $g_{n,j}$ é uma variável genérica que representa uma característica j de uma amostra de sinal n . Como resultado, F^h é usado para calcular o intervalo saudável padrão para cada recurso j , que também é explicado na seção anterior. Uma matriz contadora auxiliar AC é inicializada com componentes de valor zero, como na Equação 4. Seu objetivo é determinar o número de outliers para cada recurso j e sensor i considerando seus intervalos saudáveis correspondentes.

$$AC = \begin{bmatrix} ac_{1,1} & \cdots & ac_{1,i} & \cdots & ac_{1,s} \\ \vdots & & \vdots & & \vdots \\ ac_{j,1} & \cdots & ac_{j,i} & \cdots & ac_{j,s} \\ \vdots & & \vdots & & \vdots \\ ac_{nf,1} & \cdots & ac_{nf,i} & \cdots & ac_{nf,s} \end{bmatrix} \quad (4)$$

A matriz contadora AC é atualizada iterativamente. Um procedimento de normalização é usado para garantir que todas as características tenham o mesmo potencial para influenciar a saída. Finalmente, o índice de deterioração proposto DI_i é determinado pela Equação 5.

$$DI_i = \sum_{j=1}^{nf} ac_{j,i}, \text{ for } i = 1, \dots, s. \quad (5)$$

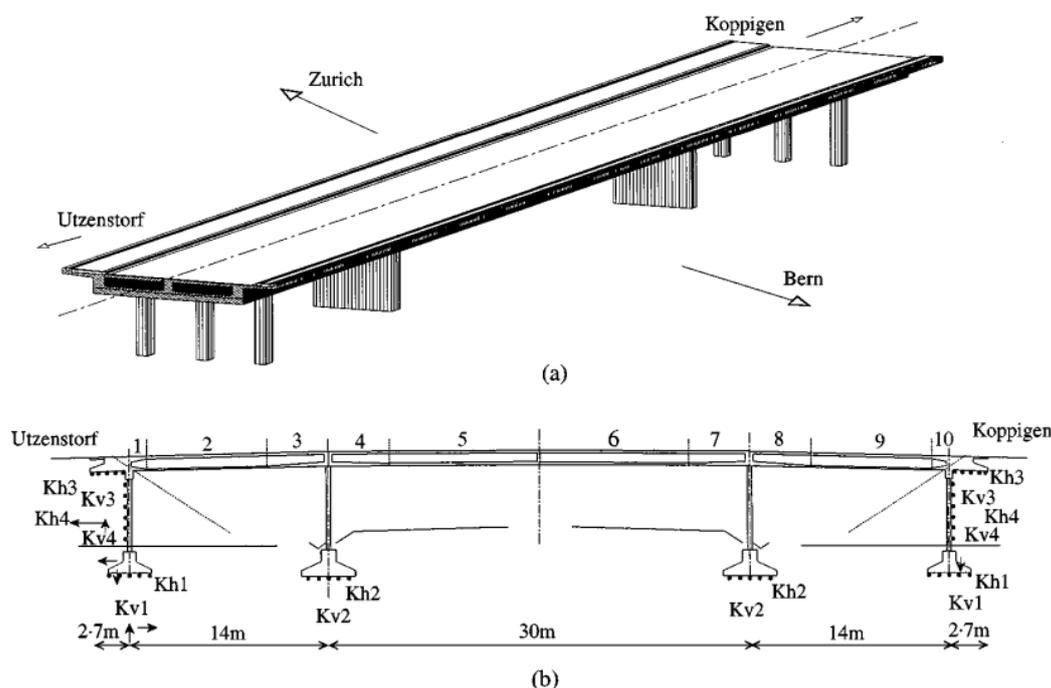
5 APLICAÇÃO: VIADUTO Z24

O Viaduto Z24 foi construído em 1963 nas proximidades de Berna, perto de Solothurn, na Suíça. Ele conectava as comunidades de Koppigen e Utzenstorf atravessando a rodovia A1, que liga Berna a Zurique (Figura 1.a). As dimensões geométricas do viaduto são ilustradas na Figura 1.b. Estudos de danos progressivos foram realizados antes que a construção fosse demolida no final de 1998. Os testes, que duraram um mês, foram projetados para simular a deterioração real do viaduto para objetivos científicos, de acordo com Wahab e De Roeck (1999). No entanto, alguns sensores, notadamente os do vão lateral de Berna, apresentaram-se defeituosos devido à existência de um

deslocamento anormal nos sinais de aceleração, que serão desconsiderados neste trabalho.

Para recriar danos reais no viaduto Z24, o cais do lado Koppigen foi cortado e reconstruído com placas de preenchimento de aço e três macacos hidráulicos (Wahab e De Roeck, 1999). Esse mecanismo instalado pode abaixar o piler para replicar situações de danos do mundo real, como assentamento e erosão no subsolo. O período após a instalação do sistema de descida é usado como uma linha de base para a condição saudável. Quatro diferentes cenários de danos são investigados: (I) assentamento de 20 mm; (II) assentamento de 80 mm; (III) assentamento de 95 mm; (IV) Elevação do pilar e inclinação da fundação. Observe-se que as condições de temperatura e vento neste viaduto em escala real variam ao longo do tempo, permitindo a avaliação da robustez do método proposto às condições operacionais/ambientais externas.

Figura 1 – Viaduto Z24: (a) Visão global, (b) Elevação



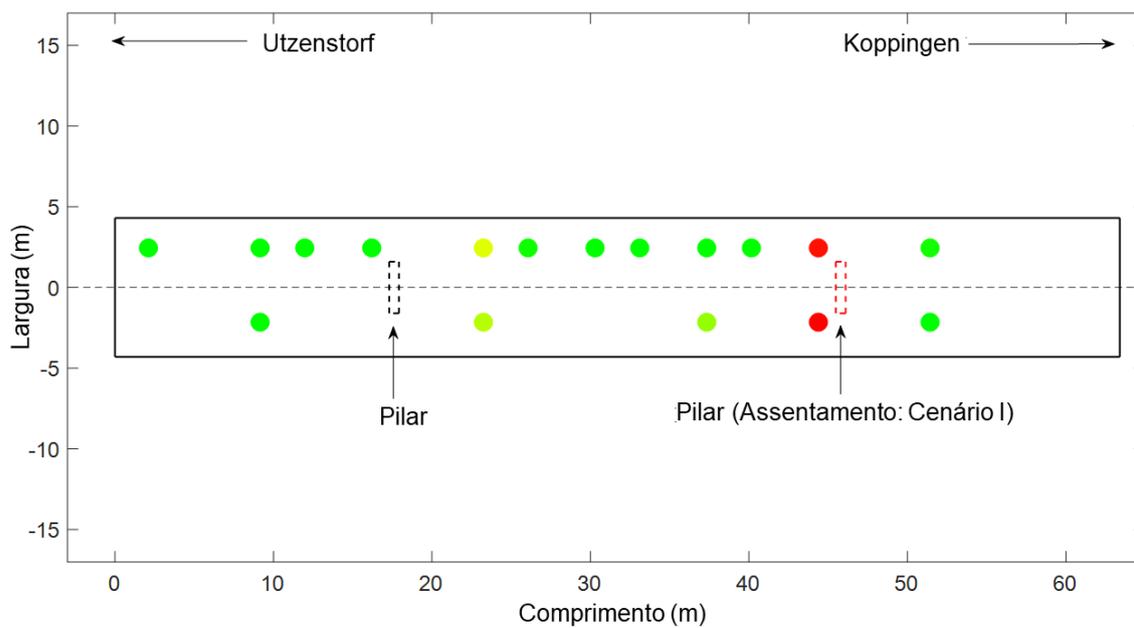
Fonte: Wahab e De Roeck (1999)

6 RESULTADOS E DISCUSSÃO

Reynders e De Roeck (2010) afirmam que a perda de rigidez local nesta área foi causada por fraturas que apareceram no meio do vão em uma área de 6,6 m do pilar do lado de Koppigen por causa dos recalques forçados. Portanto, a região próxima deste pilar deve ser identificada como o verdadeiro local do dano. A localização espacial é mostrada nas Figuras 2 a 5. Para índices negativos, ou seja, ausência de dano, a cor é verde; enquanto para índices positivos, há uma escala de cores que varia de verde ($DI_i = 0$) até vermelho (máximo DI_i). Outras cores são atribuídas proporcionalmente à magnitude do índice de deterioração proposto (por exemplo, amarelo, laranja, etc.). Os maiores índices de deterioração (em vermelho, Figuras 2 a 5) próximo ao pilar do lado de Koppigen demonstram que a abordagem localizou o dano no local real corretamente em todas as quatro situações de dano, um resultado encorajador para métodos SHM.

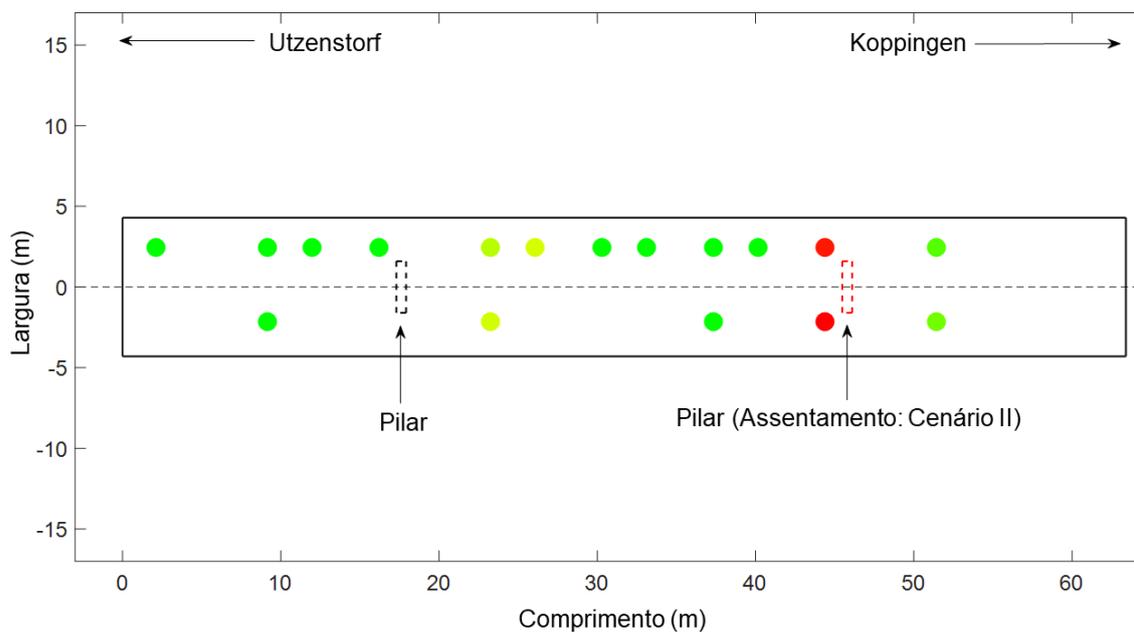
Ademais, os sensores localizados à direita do pilar de Utzenstorf (cerca de 5 metros em direção a Koppigen) mostram índices positivos baixos (conforme indicado pelos índices positivos fracos nos cenários I, II e III na Figuras 2, 3 e 4). Esse assentamento pode ter torcido o vão do viaduto ao longo daquele píer e causado pequenas fissuras naquela área. A avaliação da condição de elevação do pilar à sua altura original seguida de inclinação da fundação apoia essa teoria (ou seja, cenário IV). Tal levantamento tende a fechar fraturas no vão do viaduto, aumentando a rigidez da seção em que a técnica não mais identifica índice positivo naquela área (ver Figura 5). Este evento demonstra o grande potencial da metodologia no reconhecimento de reforço estrutural. Essa observação é um marco notável pela sua complexidade e é raramente investigada, ainda denota a qualidade das features em representar o comportamento estrutural.

Figura 2 – Visão espacial dos resultados - Cenário I: Assentamento de 20 mm



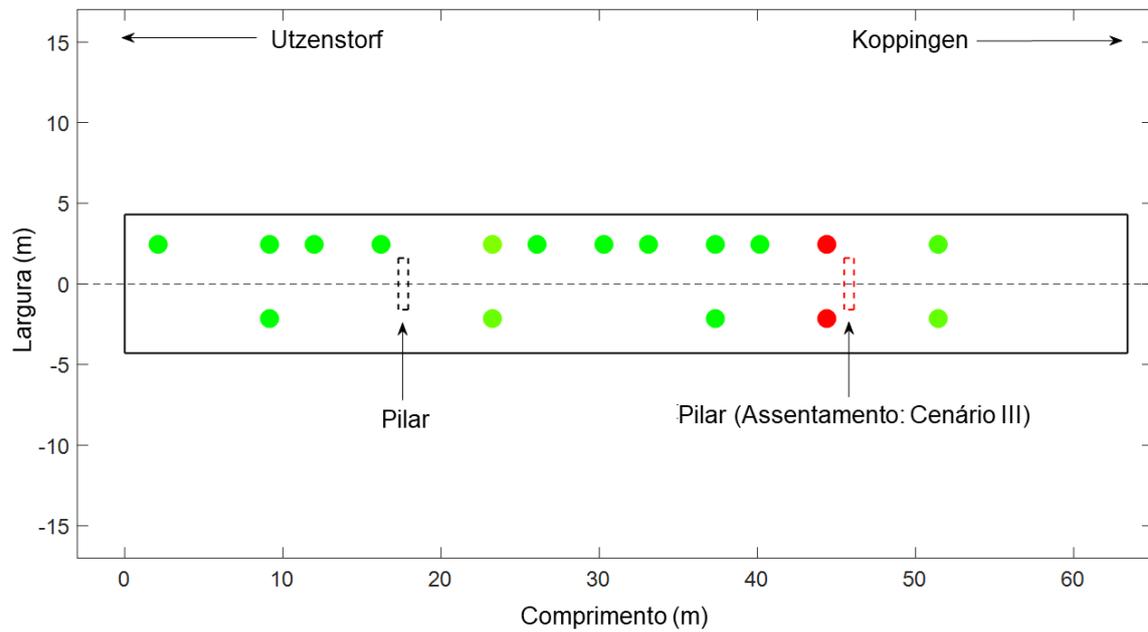
Fonte: Autores

Figura 3 – Visão espacial dos resultados - Cenário II: Assentamento de 80 mm



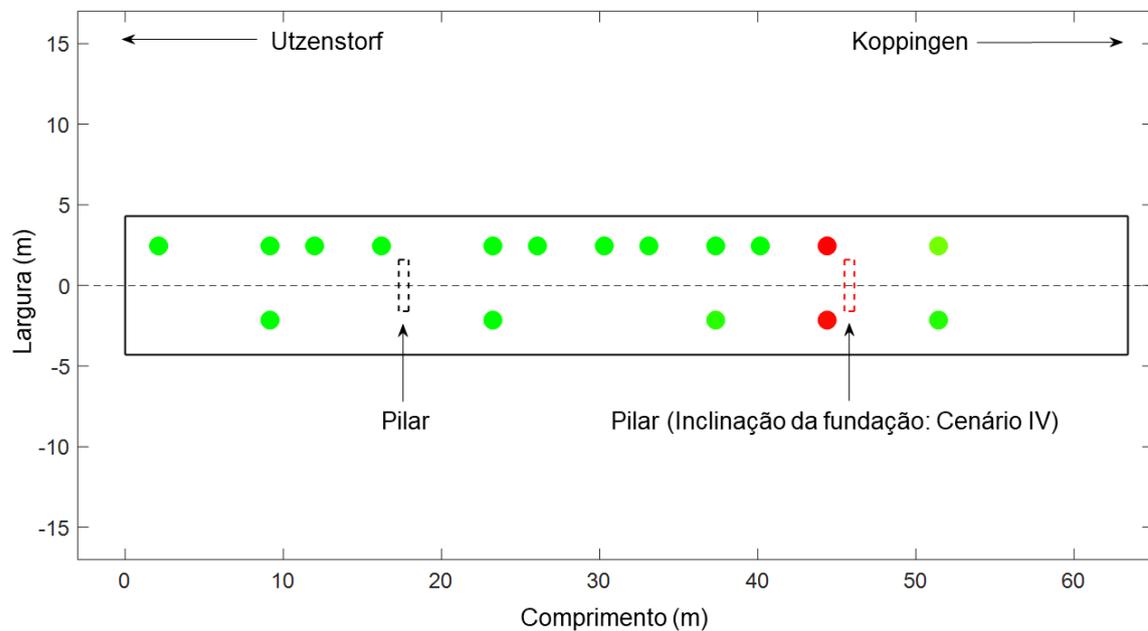
Fonte: Autores

Figura 4 – Visão espacial dos resultados - Cenário III: assentamento de 95 mm



Fonte: Autores

Figura 5 – Visão espacial dos resultados - Cenário IV: Inclinação da fundação



Fonte: Autores.

7 CONCLUSÕES

A técnica automatizada produziu resultados promissores na localização da deterioração em todos os cenários testados para o viaduto Z24. A estratégia de seleção de características (FS) empregada demonstrou ser um procedimento eficaz de filtragem de ruído. Mudanças nos fatores ambientais (por exemplo, vento e temperatura) foram observadas no experimento do viaduto em escala real e não interferiram na avaliação final da localização dos danos. Essa robustez está relacionada, em algum grau, ao FS não supervisionado. Além disso, durante um cenário específico, a abordagem identificou o reforço estrutural com base no ganho de rigidez devido ao fechamento da fissura. Isso se refletiu diretamente na redução dos índices de dano na zona reforçada. Portanto, este trabalho alcançou um resultado significativo na validação da sensibilidade das características à deterioração estrutural. Esse aspecto revela o potencial de diversas aplicações desta estratégia SHM, como: pontes, ferrovias e plataformas *off-shore* de petróleo.

Agradecimentos

Os autores agradecem à FAPEMIG (PPM-0001-18) e ao CNPq (304329/2019-3) pelo auxílio financeiro.

REFERÊNCIAS

ALVES, Vinicius; CURY, Alexandre; CREMONA, Christian. **On the use of symbolic vibration data for robust structural health monitoring**. Proceedings of the Institution of Civil Engineers-Structures and Buildings, v. 169, n. 9, p. 715-723, 2016.

ALVES, Vinicius; DE OLIVEIRA, Matheus; RIBEIRO, Diogo; CALÇADA, Rui; CURY, Alexandre. **Model-based damage identification of railway bridges using genetic algorithms**. Engineering Failure Analysis, v. 118, p. 104845, 2020.

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.

NUNES, Lorena; AMARAL, Rafaelle; BARBOSA, Flávio; CURY, Alexandre. **A hybrid learning strategy for structural damage detection.** Structural Health Monitoring, v. 20, n. 4, p. 2143-2160, 2021.

BESKHYROUN, Sherif.; OSHIMA, Toshiyuki; MIKAMI, Shuichi; TSUBOTA, Yutaka. **Structural damage identification algorithm based on changes in power spectral density.** Journal of applied mechanics, v. 8, p. 73-84, 2005.

REYNDERS, Edwin; DE ROECK, Guido. **A local flexibility method for vibration-based damage localization and quantification.** Journal of sound and vibration, v. 329, n. 12, p. 2367-2383, 2010.

ROFFO, Giorgio; MELZI, Simone; CASTELLANI, Umberto; VINCIARELLI, Alessandro; CRISTANI, Marco. **Infinite feature selection: a graph-based feature filtering approach.** IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 43, n. 12, p. 4396-4410, 2021.

SAHIDULLAH, Md; SAHA, Goutam. **Design, analysis and experimental evaluation of block-based transformation in MFCC computation for speaker recognition.** Speech communication, v. 54, n. 4, p. 543-565, 2012.

WAHAB, MM Abdel; DE ROECK, Guido. **Damage detection in bridges using modal curvatures: application to a real damage scenario.** Journal of Sound and vibration, v. 226, n. 2, p. 217-235, 1999.

ZHANG, Gang; HARICHANDRAN, Ronald S.; RAMUHALLI, Pradeep. **Application of noise cancelling and damage detection algorithms in NDE of concrete bridge decks using impact signals.** Journal of Nondestructive Evaluation, v. 30, p. 259-272, 2011.