

Identificação de dano baseada em métodos numéricos e de inteligência artificial

Damage identification based on numerical and artificial intelligence methods

João Santos
Paulo Silveira
Luís Calado
Christian Crémona

Resumo

O controlo da segurança de estruturas de engenharia civil baseado na Monitorização da Integridade Estrutural (MIE) tem sido levado a cabo, de um modo geral, *a posteriori* e por comparação com bases de referência nas quais se tem de assumir que as estruturas monitorizadas se encontram sãs e inalteradas. Para além desta limitação, a larga maioria destas metodologias baseia-se em métodos de inteligência artificial (reconhecimento de padrões) ou em análises numéricas. As primeiras apenas permitem detetar dano mas não conseguem localizá-lo ou classificá-lo, enquanto as segundas permitem extrair os três níveis de informação (deteção, localização e classificação do dano) mas são computacionalmente ineficientes, e portanto inapropriadas para aplicação em tempo real.

O presente trabalho apresenta uma metodologia inovadora para deteção, localização e classificação de dano em estruturas de engenharia civil sem recorrer à comparação com bases de referência e em tempo real, recorrendo para tal à combinação de métodos de inteligência artificial, como as redes neuronais e os algoritmos de *clusters*, com métodos numéricos. A aplicação da metodologia a um caso real no qual foram impostos cenários de dano a uma ponte permitiu concluir sobre a validade e aplicabilidade prática da metodologia desenvolvida.

Abstract

Safety control of civil structures based on Structural Health Monitoring (SHM) has been conducted, in general, with a posterior character and resorting to the comparison of data with reference baselines, in which the target structures must be assumed as undamaged and unchanged. In addition, the large majority of SHM methods are based on artificial intelligence methods (pattern recognition) or in numerical analyses. While the first type of methodologies only allows detecting damage, the second type allows detecting, locating and classifying damage but is computationally inefficient and thus inappropriate for real-time operation.

The present work presents an innovative methodology for detecting, locating and classifying damage in civil engineering structures, without resorting to baseline comparison and in real-time. It consists in the combination of artificial intelligence methods, such as the neural networks and the clustering methods, with numerical methods. Its application to a real case study in which damage was imposed to a bridge allowed concluding about its validity and practical applicability.

Palavras-chave: Simulações numéricas / Redes neuronais / Análise de *clusters* / Estatística robusta / Segurança estrutural

Keywords: Numerical simulations / Neural networks / Cluster analysis / Robust statistics / Structural safety

João Santos

Bolseiro de Pós-doutoramento
Laboratório Nacional de Engenharia Civil
Lisboa, Portugal
josantos@lnec.pt

Paulo Silveira

Investigador Principal
Laboratório Nacional de Engenharia Civil
Lisboa, Portugal

Luís Calado

Professor Catedrático
Instituto Superior Técnico
Lisboa, Portugal

Christian Crémona

Investigador-Coordenador
CEREMA
Paris, França

Aviso legal

As opiniões manifestadas na Revista Portuguesa de Engenharia de Estruturas são da exclusiva responsabilidade dos seus autores.

Legal notice

The views expressed in the Portuguese Journal of Structural Engineering are the sole responsibility of the authors.

SANTOS, J. P. [et al.] – Identificação de dano baseada em métodos numéricos e de inteligência artificial. **Revista Portuguesa de Engenharia de Estruturas**. Ed. LNEC. Série III. n.º 1. ISSN 2183-8488 (julho 2016) 81-89.

1 Introdução

Monitorização da integridade de estruturas (MIE) pode ser definida como a implementação de estratégias de identificação de dano em sistemas estruturais, de engenharia civil ou outros [1]. Este tema tem sido tratado através de dois tipos de abordagens distintas [2,3]: a abordagem inversa, ou *model updating*, e a abordagem direta, baseada em técnicas de inteligência artificial. A primeira consiste em encontrar os modelos numéricos que melhor se ajustam às respostas estruturais [4]. As soluções deste tipo de abordagens não são, em geral, únicas e a sua obtenção requer o uso de algoritmos de otimização e envolve grande complexidade computacional [5]. Não são, por isso, apropriadas à identificação de dano em tempo real. As abordagens baseadas em métodos de inteligência artificial são computacionalmente mais eficientes e apresentam-se como as melhores candidatas à identificação de dano em tempo real [6,7]. No entanto, o facto de não incluírem informação de carácter estrutural faz com que apenas permitam detetar dano, ao passo que as anteriores permitem também localizá-lo e classificá-lo.

O presente trabalho descreve uma abordagem original de monitorização da integridade estrutural que inclui modelos numéricos e algoritmos de inteligência artificial para deteção, localização e classificação de dano em tempo real. A abordagem proposta baseia-se em duas vertentes principais. A primeira consiste na geração numérica de uma base de dados de cenários de dano que se considera poderem pôr em causa a segurança de uma estrutura alvo. As entradas desta base de dados consistem em conjuntos de incrementos gerados nos sensores instalados *in situ*. A segunda vertente consiste na aplicação de redes neuronais, de algoritmos de *cluster* e de estatística robusta aos dados adquiridos para definir, em tempo real, um conjunto de incrementos experimentais que possam ser eficazmente comparados com os da base de dados.

Após esta breve introdução, a secção 2 descreve o caso prático estudado e a secção 3 os principais conteúdos teóricos. A secção 4 consiste na descrição da metodologia original desenvolvida através da aplicação ao caso prático. Finalmente, na secção 5 tecem-se algumas considerações finais.

2 Caso prático – a passagem superior Z24

A passagem superior Z24 foi construída em 1963 sobre a autoestrada Suíça A1 e localiza-se no cantão de Berna, próximo de Solothurn. A estrutura compreende um tabuleiro em caixão bicelular pré-esforçado com um vão central de 30 m e dois laterais de 14 m (Figura 1). Os dois pilares e os dois encontros têm 5,5 m de altura e encontram-se enviesados de 8,5° em relação ao eixo da ponte. A secção do tabuleiro tem 8,6 m de largura e 1,1 m de altura (Figura 2), com almas e banzos de 0,45 m e 0,2 m de espessura, respetivamente. Sobre os pilares existem dois diafragmas e junto aos encontros duas lajes de aproximação com 2,7 m de comprimento.

A passagem superior Z24 foi demolida em 1998 para permitir a construção de uma linha de caminho de ferro adjacente à autoestrada A1. Antes da demolição, a passagem superior foi sujeita a um extenso programa de monitorização estrutural entre novembro

de 1997 e agosto de 1998, durante o qual a estrutura permaneceu inalterada. Em setembro de 1998, foram impostos diversos cenários de dano ao sistema estrutural [8,9]. Estes cenários consistiram em perdas de rigidez em diversos elementos estruturais e consequentes imposições de deslocamentos e rotações, e encontram-se identificados no Quadro 1 e descritos em [9].

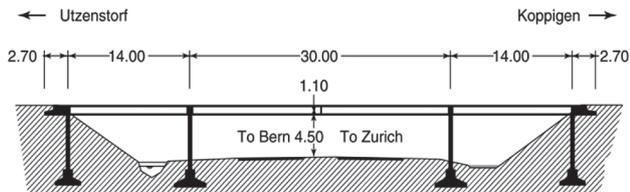


Figura 1 Seção longitudinal da passagem superior Z24 [9]

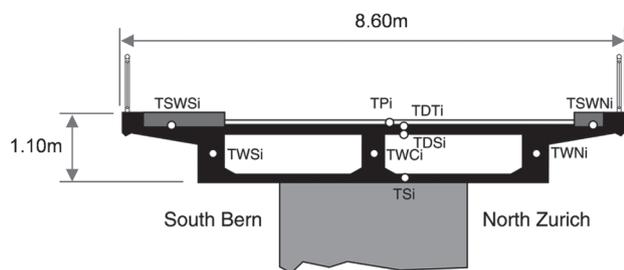


Figura 2 Seção transversal do tabuleiro [9]

Quadro 1 Cenários de dano impostos à passagem superior Z24

Cenário de dano	Data	Vulnerabilidade	Redução de rigidez	Deslocamento
1	9 a 18 ago 1998	Erosão interna	Fundação do pilar	Abaixamento do pilar
2	19 ago 1998	Erosão interna	Fundação do pilar	Rotação da fundação do pilar
3	25 e 26 ago 1998	Destacamento de betão	Tabuleiro	Incremento das flechas
4	27 ago 1998	Escorregamento de terras no encontro	Encontro	Rotação do encontro
5 e 6	2 a 9 set 1998	Corrosão nos cordões de pré-esforço	Tabuleiro	Incremento das flechas

Durante o período de monitorização foram registadas acelerações em 16 acelerómetros assim como a temperatura: (i) no pavimento, (ii) nos banzos e (iii) nas almas do tabuleiro (TP, TW e TS, Figura 2). As séries temporais de temperaturas e das primeiras quatro frequências de vibração encontram-se apresentadas na Figura 3 e na Figura 4, e foram obtidas nos extensos estudos experimentais descritos e referidos em [8,9]. Nestas figuras, as linhas ponteadas verticais dividem o período no qual a estrutura permaneceu inalterada daquele em que a estrutura foi submetida ao cenário de dano 1 (Quadro 1), que consistiu na redução de rigidez de um pilar. Dados recolhidos durante os restantes cenários não foram considerados no presente artigo.

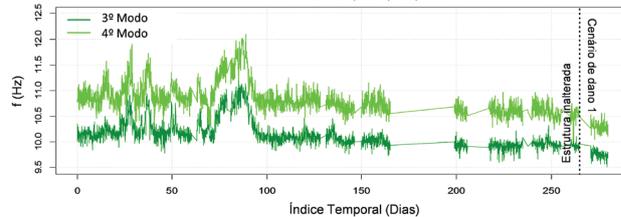
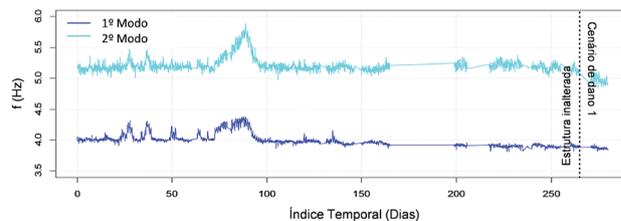


Figura 3 Frequências correspondentes aos primeiros quatro modos de vibração obtidas na passagem superior Z24. Linha vertical pontuada divide a condição estrutural inalterada da correspondente ao cenário 1 do Quadro 1 [8,9]

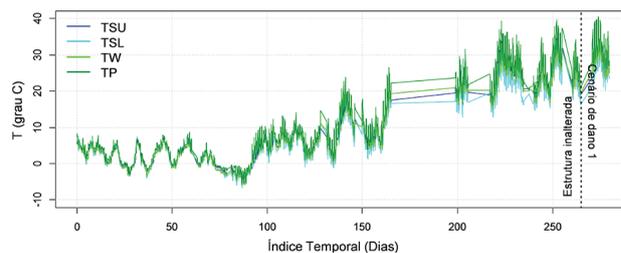


Figura 4 Temperaturas adquiridas na passagem superior Z24. Linha vertical pontuada divide a condição estrutural inalterada da correspondente ao cenário 1 do Quadro 1

3 Conteúdos teóricos

3.1 Redes neuronais artificiais

As redes neuronais artificiais são usadas no presente artigo com o objetivo de modelar o comportamento estrutural sob ação dos efeitos ambientais e operacionais, com especial ênfase na temperatura apresentada no ponto anterior, para em seguida obter respostas estruturais que sejam livres desses mesmos efeitos. Esta tarefa é apelidada, no âmbito de MIE, de normalização de dados (ou supressão de efeitos) e a escolha de redes neuronais artificiais para a levar a cabo justifica-se por:

- se pretender modelar a resposta estrutural sem quaisquer premissas relativamente à relação entre esta e as ações (as redes neuronais encontram, por si, estas relações);
- por se pretender um algoritmo com capacidade para modelar e “aprender” relações altamente não lineares.

O modelo de estimação da resposta estrutural de redes neuronais aqui utilizado consiste no Perceptrão Multi-Camada [10] que é definido com grandezas ambientais e operacionais (que neste caso

prático consiste na temperatura – Figura 4) como *input* e com as respostas estruturais (que neste caso prático consistem nas frequências – Figura 3) como *output*. As primeiras são identificadas com a letra *x* e as segundas com a letra *y* no grafo que representa os modelos usados (Figura 5).

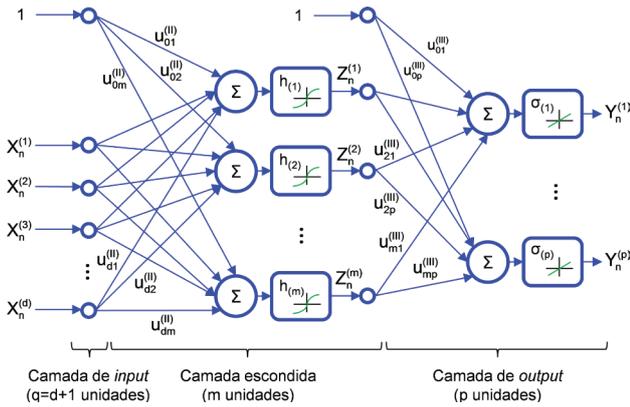


Figura 5 Grafo de modelo matemático Perceptron Multi-Camada

O modelo de rede neuronal artificial usado é constituído por três camadas de unidades neuronais artificiais, tendo a de *output* um carácter linear e a camada escondida (ou intermédia – ver Figura 5) um carácter não linear fornecido por funções de tangente hiperbólica. Esta arquitetura foi escolhida por se saber que permite modelar de forma eficaz e computacionalmente eficiente qualquer relação contínua não linear [10]. A formulação matemática destes modelos pode ser colocada, de forma simples, através da expressão:

$$y_{iv} = \sigma \left(\sum_{s=1}^m z_{ik}^{(s)} u_{sv}^{(s)} \right) + re_{iv}, \quad v=1..p \quad (1)$$

na qual *h* é a função tangente hiperbólica utilizada nos neurónios artificiais da camada intermédia, σ a relação linear das unidades neuronais de *output*, *x* uma leitura de temperatura, *y* um valor de frequência, *re* os erros residuais associados à estimativa gerada pela rede neuronal e *z* o valor de saída das unidades neuronais da camada escondida. A grandeza *u* consiste nos pesos definidores do modelo de rede neuronal e divide-se em pesos da camada escondida (índice *II*) e pesos da camada de *output* (com índices *III*).

Tal como em modelos de regressão linear, também o modelo ótimo de rede neuronal artificial se pode obter através da minimização dos erros quadrados de estimação. No entanto, ao contrário dos modelos mais simples, nas redes neuronais não é possível obter uma solução analítica para este problema [11]. Para obviar esta incapacidade, é costume recorrer-se a métodos numéricos para obter a estimativa dos erros quadrados. De entre os vários existentes na literatura, os mais comumente utilizados são baseados na obtenção do gradiente dos erros através da retropropagação do erro ao longo da rede neuronal. De entre estes, foi utilizado no presente trabalho o *gradient descent* [10], que consiste em fazer variar os valores dos pesos, *u*, a cada iteração Ψ , de acordo com o simétrico do gradiente dos erros, como se mostra na Eq.(2):

$$U^{(\Psi+1)} = U^{(\Psi)} - \eta \nabla SSR^{(\Psi)}(U) \quad (2)$$

Nesta equação $U^{(\Psi)}$ e $U^{(\Psi+1)}$ representam os valores de erros obtidos na iteração Ψ e $\Psi + 1$, respetivamente, ao passo que ∇SSR é o gradiente da soma dos erros quadráticos e η denomina-se de taxa de aprendizagem e é um fator que define qual o “passo” dado na direção do gradiente, em direção ao mínimo da curva de erro.

A escolha da arquitetura de rede e a garantia de que esta “aprende” as relações entre grandezas em vez de as “memorizar” foram obtidas através de técnicas de regularização quadrática, que se encontram convenientemente descritas em [10,11].

3.2 Análise de clusters

A identificação de comportamentos estruturais distintos num conjunto de dados adquiridos de um sistema estrutural é levada a cabo, no presente trabalho, através de análise de *clusters* [12,13]. A família de métodos de inteligência artificial apelidados de *clusters* é classificada de não supervisionada, o que significa que permitem classificar respostas estruturais sem qualquer premissa sobre a condição estrutural presente ou passada [12]. O objetivo de um método de análise de *clusters* pode ser definido como a divisão de um conjunto de dados, uni ou multivariado, em subconjuntos que devem ser tão compactos e estar tão afastados entre si quanto possível. Para tal é necessário definir distâncias entre pares de objetos de dados, cujos valores elevados indicam pares discrepantes, ao passo que valores baixos indicam pares de objetos semelhantes, de acordo com as suas distribuições reais.

Matematicamente, o objetivo de um método de análise de *clusters* pode ser definido como a tentativa de minimização da distância global intra-cluster, $W(C_k)$,

$$W(C_k) = \frac{1}{2} \sum_{k=1}^K \sum_{C(i)=k} \sum_{C(j)=k} d_{ij} \quad (3)$$

em que $C(i)$ é uma regra de alocação, que atribui o objeto *i* ao cluster k , e d_{ij} a distância entre os objetos de dados *i* e *j*. A minimização da distância $W(C_k)$ tem como consequência direta a maximização da distância inter-cluster $B(C_k)$,

$$B(C_k) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N d_{ij} - W(C_k) \quad (4)$$

na qual *N* é o número total de objetos considerados na análise. Várias famílias de métodos de análise de *cluster* podem ser encontradas na literatura, sendo os mais conhecidos e utilizados os partitivos e os hierárquicos. No presente trabalho optou-se por utilizar o método partitivo *Dynamic Cloud* [14] para poder definir *clusters* justapostos de dados, aumentando assim a sensibilidade a anomalias e minimizando o esforço computacional.

O método *Dynamic Cloud* é iterativo por natureza e começa por uma fase de inicialização onde o número de objetos de dados a analisar é definido e os protótipos de cada *cluster* aleatoriamente colocados no espaço de dados a analisar (Figura 6a). Cada iteração começa pela fase de alocação, onde os objetos de dados são atribuídos ao *cluster* mais próximo (Figura 6b), à qual se segue a representação, sendo os protótipos de cada *cluster* definidos como os centros geométricos dos objetos que lhes foram atribuídos (Figura 6c). Este processo repete-se então até que os protótipos não sejam alterados

durante um número predefinido de iterações sucessivas. Em geral o método converge em menos de dez iterações.

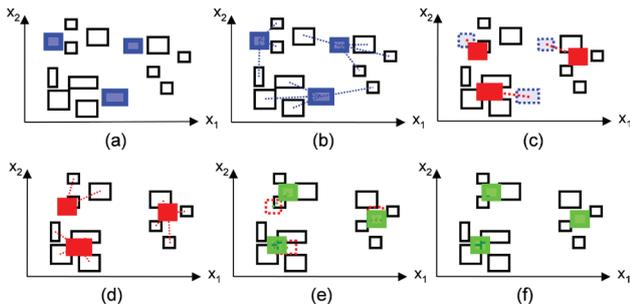


Figura 6 Método *Dynamic Cloud*: (a) inicialização, (b) alocação da iteração 1, (c) representação da iteração 1, (d) alocação da iteração 2, (e) representação da iteração 2 e (f) conjunto final de protótipos de *clusters*

A utilização deste método de análise de *clusters* requer a definição de objetos de dados simbólicos que, em vez de consistirem em leituras individuais relativas a sensores distintos, são definidos através de conceitos, como por exemplo intervalos de tempo de leituras, elementos estruturais ou mesmo até sistemas estruturais integrais. Uma descrição detalhada da utilização deste tipo de dados em análise de *clusters* pode ser encontrada em [18]. Este tipo de dados é mais genérico que os dados “clássicos” (leituras) e permite realizar uma grande compressão do volume de dados sem perda de informação estrutural [12]. Cada objeto simbólico é descrito por um ou mais histogramas ou intervalos interquartilhos (um por grandeza em análise, que no presente caso consistem em frequências), o que lhe confere elevada precisão na representação dos dados que o constituem. No presente trabalho foi decidido utilizar intervalos interquartilhos para descrever objetos simbólicos. A distância simbólica usada neste trabalho, para quantificar a similaridade entre pares de objetos simbólicos, é a distância de Hausdorff [14] devido à sua simplicidade computacional e à sua eficiência demonstrada em trabalhos anteriores [13,15]. A distância de Hausdorff definida entre dois objetos simbólicos, T_i e T_j , pertencentes a um conjunto de dados com N objetos descritos por $r = 1, \dots, p$ intervalos, respetivamente $(T_{i,inf}^{(r)}, T_{i,sup}^{(r)})$ e $(T_{j,inf}^{(r)}, T_{j,sup}^{(r)})$, é definida por:

$$d_{ij} = \left(\sum_{r=1}^p \left[\frac{\Phi_r(T_i, T_j)}{H_r} \right]^2 \right)^{1/2} \quad (5)$$

em que Φ_r é a dissimilaridade univariada de Hausdorff, que é dada por:

$$\Phi_r(T_i, T_j) = \max \left(\left| T_{i,inf}^{(r)} - T_{j,inf}^{(r)} \right|, \left| T_{i,sup}^{(r)} - T_{j,sup}^{(r)} \right| \right) \quad (6)$$

ao passo que o termo de normalização pode ser obtido através de:

$$H_r^2 = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^N \left[\Phi_r(T_i, T_j) \right]^2 \quad (7)$$

A análise de *clusters* permite separar um conjunto de dados em

qualquer número de *clusters*, quer estes existam realmente nos dados analisados ou não. Para verificar qual o número de *clusters* que de facto existe no conjunto de dados em análise, podem ser usados índices de validação de *clusters* [16]. No presente trabalho foi utilizado o índice de validação Calinski and Harabasz, por ter exibido desempenho superior no estudo [13,15].

4 Metodologia desenvolvida

4.1 Detecção de dano em tempo real baseada em janelas móveis

A primeira tarefa da metodologia desenvolvida para identificação de dano consiste na deteção de anomalias em tempo real. Para que uma estratégia deste tipo seja bem-sucedida, tem de ser executada imediatamente após a aquisição (e transmissão remota) de cada conjunto de dados e não pode fornecer falsos alertas. Em acréscimo, a metodologia deve ser tão sensível quanto possível, por forma a detetar anomalias antes de estas constituírem dano, ou seja, antes de estas poderem influenciar o bom desempenho estrutural, presente ou futuro [13].

No presente trabalho, a elevada sensibilidade foi conseguida através da utilização de algoritmos de *clusters* que, por oposição aos restantes métodos de análise de dados, avaliam compacidade / densidade em vez de valores absolutos ou relativos. A robustez a alertas falsos foi conseguida através da utilização de modelos de redes neuronais para suprimir efeitos ambientais ou operacionais e, como se verá adiante neste ponto, através do estabelecimento de limites de confiança robustos, cujos valores não dependem da existência de valores anómalos (*outliers*). A capacidade de análise em tempo real foi conseguida através da aplicação de todos estes métodos em janelas móveis, de forma idêntica a um simples cálculo de médias móveis, mas com uma base teórica mais complexa.

4.1.1 Supressão dos efeitos ambientais

A supressão dos efeitos ambientais em janelas móveis foi levada a cabo usando as redes neuronais Perceptrão Multi-Camada. Estes algoritmos foram definidos e treinados para cada janela de forma independente e deles foram obtidos os erros residuais que, tal como foi referido no ponto 3.1, consistem em respostas estruturais não influenciadas por efeitos externos como os ambientais ou operacionais. Para o caso de estudo da passagem superior Z24 foram definidas janelas móveis com duração de 60 dias e sobreposição de 50, resultando assim numa capacidade de detetar dano a cada 10 dias. A dimensão de objetos simbólicos e janelas ao longo do tempo foi escolhida para ilustrar de forma clara e simples os métodos aqui propostos. No entanto, estes parâmetros foram alvo de estudos detalhados em [13,17,18], tendo sido possível atingir-se resoluções temporais de deteção de 3 minutos para aquisição dinâmica [13] e de 1 dia para aquisição com carácter estático [18].

A escolha de janelas móveis realizada para o presente caso de estudo resultou em 27 janelas de dados analisadas independentemente. Destas 27 janelas, mostram-se na Figura 7 as últimas 20 contendo duas séries temporais da terceira frequência de vibração: a cor azul a

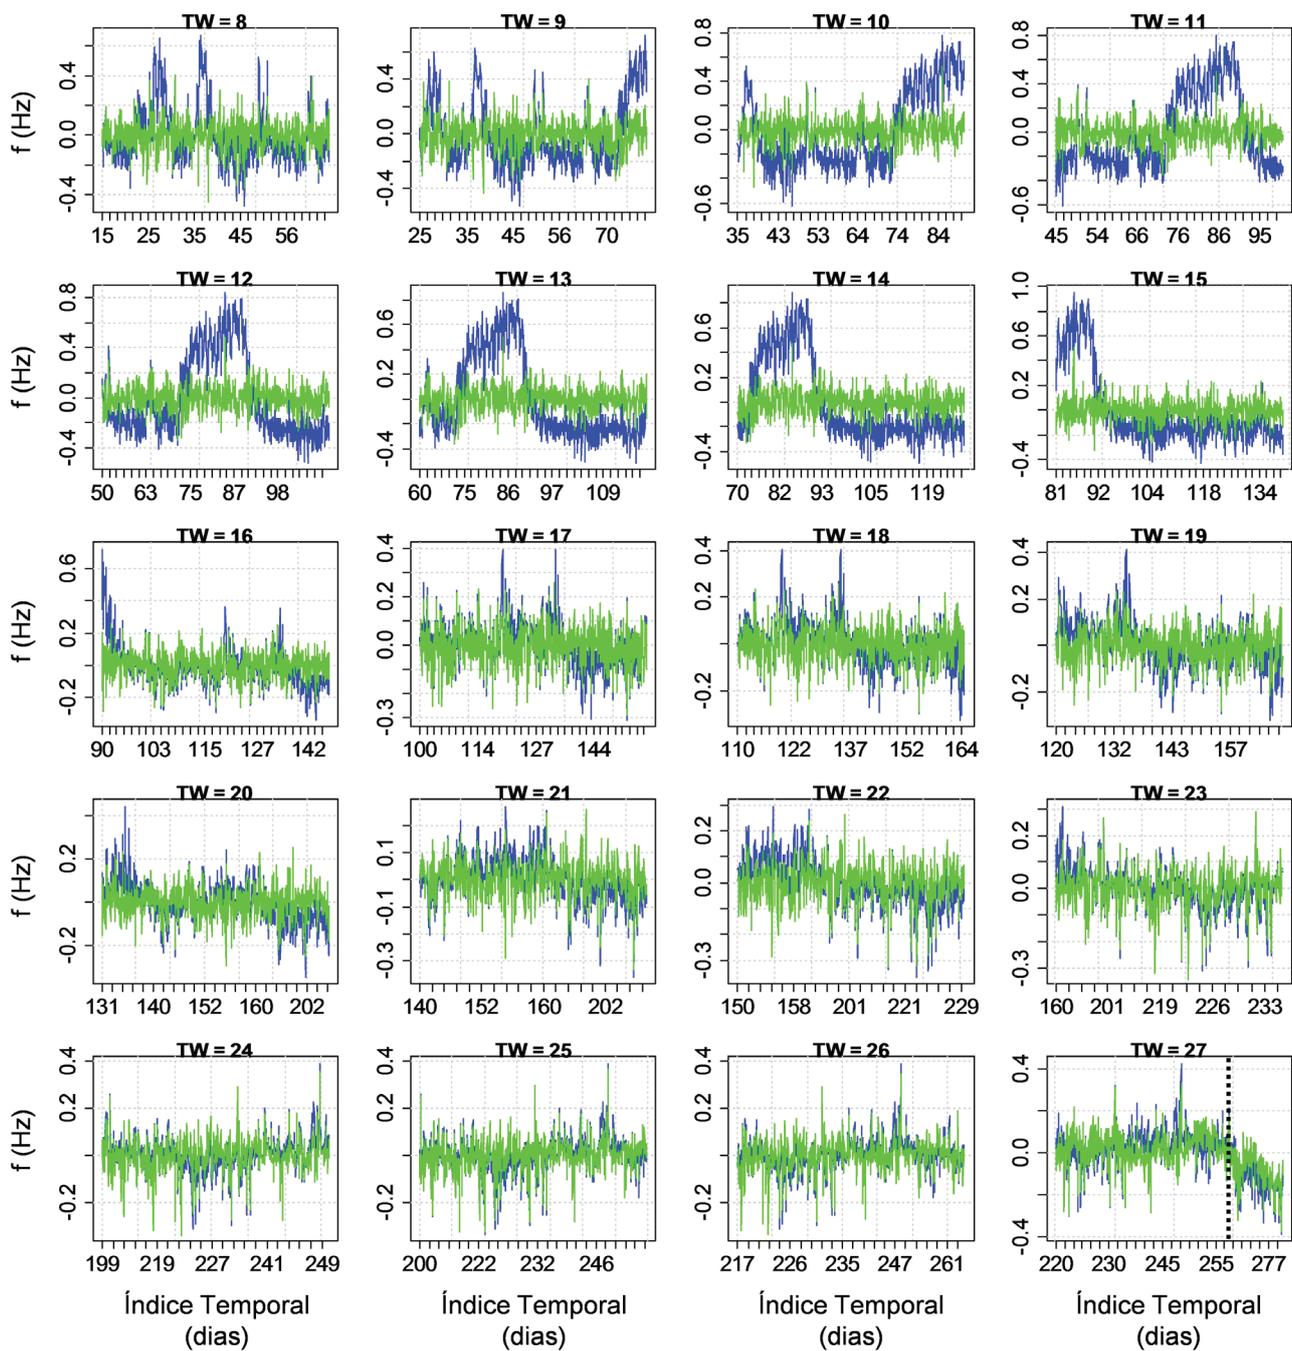


Figura 7 Supressão dos efeitos ambientais numa estratégia de janelas móveis. A cor azul apresenta-se a 3ª frequência influenciada pela temperatura e a cor verde já com o efeito desta ação suprimido. Na janela TW=27 encontra-se a linha vertical pontuada indicando o instante em que foi imposto o cenário de dano 1: redução de rigidez do pilar. Valores de frequência centrados na média de cada janela

série obtida *in situ*, contendo os efeitos da temperatura, e a cor verde a série de erros residuais de frequência, livre de efeitos externos, obtida com recurso à rede neuronal. Na janela $TW = 27$ encontra-se a linha vertical pontuada indicando o instante em que foi imposto o cenário de dano 1: redução de rigidez do pilar.

Como pode ser observado na Figura 7, existe uma grande variabilidade nos dados adquiridos *in situ* (cor azul), que pode ser geradora de inúmeros e importantes falsos alertas. No entanto, após aplicação das redes neuronais estes dados mostram tendência nula e fraca variabilidade, assemelhando-se a um sinal com variações de carácter aleatório. A exceção a esta constatação consiste na janela $TW = 27$, onde se observa que a rede neuronal não removeu a tendência clara gerada pela imposição do cenário de dano 1. Este facto mostra que a rede neuronal é capaz de distinguir, por si, comportamentos anómalos e regulares sem recorrer a qualquer *input* humano ou a bases de referência nas quais a estrutura tenha de ser considerada sã e inalterada.

4.1.2 Classificação robusta de dados

O *output* obtido na secção anterior consiste na obtenção, em cada janela, de séries temporais de respostas estruturais livres de efeitos externos ambientais. Este tipo de informação mostra se a estrutura foi ou não danificada no período correspondente a cada janela: os gráficos de cor verde representados na Figura 7 mostram média nula e carácter aleatório em todas as janelas com exceção da última, ao longo da qual ocorreu, de facto, o cenário de dano 1. No entanto, não fornece informação binária do tipo VERDADEIRO / FALSO sobre a existência de dano. A extração de informação binária torna-se crucial para uma deteção em tempo real e para a obter recorreu-se, no presente trabalho, a algoritmos de classificação estatística e, de entre estes, a algoritmos de *clusters* por não requererem bases de referência para classificar informação de MIE, quanto a relacionada com estruturas sãs ou alteradas.

O método *Dynamic Cloud* foi aplicado, no presente trabalho, de forma independente aos dados pertencentes a cada janela (apresentadas na Figura 7). Cada uma destas análises compreendeu várias inicializações com números diferentes de *clusters*. De entre estas, as que produziram maior valor do índice de Calinski and Harabasz foram automaticamente escolhidas para análise. Cada janela foi definida por forma a conter 6 objetos de dados simbólicos, descritos pelos seus intervalos interquartilhos, dos quais se obtiveram as distâncias de Hausdorff.

Dos *clusters* obtidos de cada uma das análises descritas no parágrafo anterior foi definido um índice de dano que, apesar de ter valor único, é capaz de descrever a condição estrutural observada durante o período correspondente a uma janela de dados com comprimento e número de sensores arbitrário. Este índice, intitulado *DI* – índice de dano, é definido como a distância entre *clusters* automaticamente definidos pelo *Dynamic Cloud* e encontra-se formulado matematicamente na Eq.(8), na qual K é o número de *clusters* encontrado no conjunto de dados em análise e d_{ck} a distância entre o objeto c e o *cluster* k .

$$DI = \frac{1}{K(K-1)} \sum_{k=1}^K \sum_{c=1}^K d_{ck} \quad (8)$$

Os testes de hipótese estatísticos são então feitos diretamente no índice *DI*, resultando assim num processo mais simples e eficiente quando comparado com o teste estatístico dos dados adquiridos *in situ*. Tal como a normalização de dados, também a classificação se definiu baseada em janelas móveis: o limite de confiança foi definido recorrendo a um conjunto de índices *DI* igual ao número de dados simbólicos existentes em cada janela. Esta estratégia foi já usada com sucesso noutras aplicações [13,15,17,28] e neste trabalho resultou em amostras de índices *DI* com dimensão 6. Com o objetivo de evitar a comparação com bases de referência, as amostras testadas são usadas para definir os próprios limites de teste / confiança. Para garantir que estes são robustos (ausência de falsos alertas) e que os danos são detetados, estes limites foram definidos com base em grandezas estatísticas robustas, nomeadamente na mediana (para estimar o centro de cada amostra de *DI*) e na *MAD* (mediana do desvio à mediana – para estimar a variabilidade das amostras). Assim, os limites de confiança, *CB*, de cada janela são definidos de acordo com a expressão apresentada na Eq.(9):

$$CB_i = med[DI_{i-w+1} DI_i] + X_{1-\alpha}^2 MAD[DI_{i-w+1} DI_i] / \sqrt{w} \quad (9)$$

na qual o índice i representa o objeto simbólico considerado, w representa o número de objetos simbólicos existentes em cada janela, *med* representa o valor mediano e $X_{1-\alpha}$ representa o percentil $1 - \alpha$ da distribuição chi-quadrado.

Das janelas apresentadas na Figura 7 foram obtidas as séries temporais de *DI* e *CB* apresentadas na Figura 8 com as cores correspondentes. Nestas pode observar-se o carácter adaptativo (variável ao longo do tempo) dos limites de confiança, necessário para identificação em tempo real. Na mesma figura pode observar-se também que sem a utilização de redes neuronais para modelar e normalizar os dados, a deteção de dano fornece falsos alertas nas janelas onde se verificam maiores variações de temperatura ($TW = 10$ a 15 – Figura 8a). Estes falsos alertas assumem valores de *DI* maiores que os gerados pelo dano imposto na janela $TW = 27$. Pelo contrário, caso sejam utilizadas redes neuronais, os falsos alertas desaparecem e a deteção “verdadeira” ($TW = 27$) é a única obtida (Figura 8b).

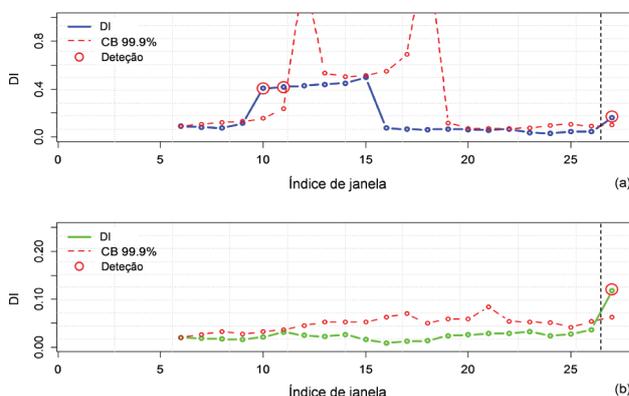


Figura 8 Séries de *DI* e *CB* (a) com recurso a redes neuronais MLP e (b) sem recurso a estas

4.2 Localização e classificação de dano em tempo real

A metodologia de localização e classificação de dano em tempo real baseia-se na de deteção apresentada no ponto anterior, é também realizada em janelas móveis e requer que o dano a localizar e classificar tenha sido já detetado. Assim, as rotinas desenvolvidas para localização e classificação permanecem em modo de suspensão durante a aquisição de dados até que o valor de DI exceda, nalguma janela, o valor correspondente de CB . Quando tal acontece, a metodologia avalia, de forma instantânea, o ajuste entre as variações das respostas estruturais obtidas *in situ*, na janela em que $DI > CB$, e as variações pertencentes a uma base de dados de cenários de dano, previamente gerada com recurso a análises numéricas.

4.2.1 Geração de base de dados com cenários de dano numéricos

A geração de bases de danos de cenários é realizada com o objetivo de simular os cenários mais graves para a segurança da estrutura alvo. No caso de estudo da passagem superior Z24, esta base de dados foi definida com os cenários de dano descritos no programa experimental [8,9] e apresentados no Quadro 1. Assim, foram simulados seis cenários, três dos quais consistiram em variações de rigidez num dos pilares (cenário 1, Figura 9) e em duas secções do tabuleiro (cenários 5 e 6, Figura 9) e outras três em rotações impostas nas fundações do pilar (cenários 3 e 4, Figura 9) e de um dos encontros (cenário 4, Figura 9).

Para cada um dos cenários foram obtidas as variações, ou incrementos, das frequências de vibração medidas *in situ*, que consistem nas primeiras quatro frequências de vibração. Estes incrementos, denominados no presente trabalho de incrementos numéricos, NI , encontram-se apresentados para as quatro frequências de vibração e para cada um dos seis cenários sob a forma de gráficos de barras, na Figura 10. A sua obtenção consistiu na subtração das frequências de vibração da estrutura sã pelas frequências de vibração obtidas em cada um dos cenários de dano. A magnitude das variações de rigidez consideradas em cada um dos cenários foi unitária, razão pela qual os incrementos apresentados na Figura 10 foram normalizados para um valor máximo absoluto de 1.

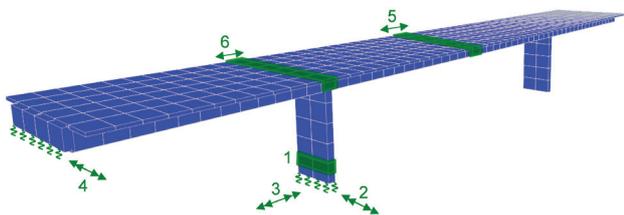


Figura 9 Modelo numérico tridimensional da passagem superior Z24 e cenários de dano impostos ao mesmo para geração da base de dados de danos

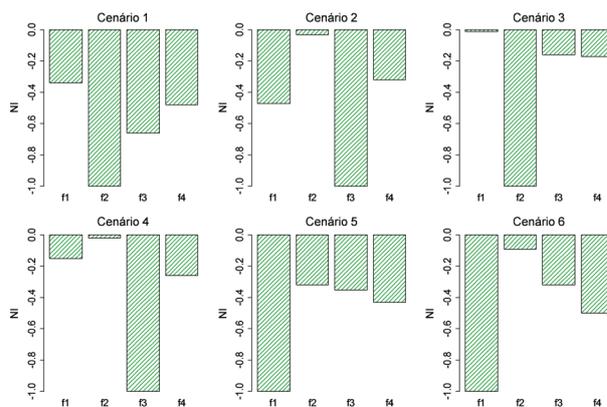


Figura 10 Incrementos numéricos das primeiras quatro frequências de vibração da passagem superior Z24

4.2.2 Avaliação do ajuste entre informação experimental e numérica

Uma vez definida a base de dados de cenários de dano, a metodologia de classificação e localização de dano baseia-se na comparação destes incrementos (NI) com os obtidos dos dados adquiridos *in situ*, aqui denominados de incrementos simbólicos (SI) devido à natureza da sua obtenção. Para obter cada conjunto de SI , o procedimento descrito em 4.1 para obtenção do índice de dano, DI , é repetido não para o conjunto de todas as respostas medidas *in situ*, mas para cada uma das respostas em separado. Assim, em vez de um valor de DI único para a estrutura, cada janela gera um conjunto de incrementos SI , com número igual aos das grandezas adquiridas *in situ*. No caso de estudo da passagem superior Z24, este procedimento consiste na obtenção de um incremento SI para cada uma das quatro frequências de vibração.

Os incrementos SI obtidos da janela 27 (na qual foi imposto o dano) encontram-se apresentados na Figura 11a. A comparação destes incrementos com os numéricos apresentados na Figura 10 foi feita com recurso à formulação dada pelo índice MAC , que é tradicionalmente usado como forma de aferir a correlação entre modos de vibração estrutural [18],

$$Corr_{sc}(SI, NI) = \frac{\left(\sum_{j=1}^p SI_j NI_{j,sc} \right)^2}{\sum_{j=1}^p SI_j^2 \sum_{j=1}^p NI_{j,sc}^2}; \quad sc = 1, \dots, SC \quad (10)$$

por se verificar que leva a maior precisão quando comparada com a formulação "tradicional" de correlação [18]. Na Eq.(10), sc é o índice de cenário de dano e SC o número total de cenários simulados numericamente.

A avaliação do ajuste entre os incrementos simbólicos, obtidos da janela $TW = 27$, e os numéricos apresenta-se na Figura 11b, onde se pode observar que, de entre os cenários simulados numericamente, aquele que corresponde aos dados adquiridos *in situ* e analisados no presente trabalho (cenário 1) é o que apresenta maiores valores de correlação, que atingem os 90%. Este resultado permite concluir

sobre a eficácia da metodologia desenvolvida em detetar, localizar e classificar dano estrutural em tempo real e sem recorrer a bases de referência.

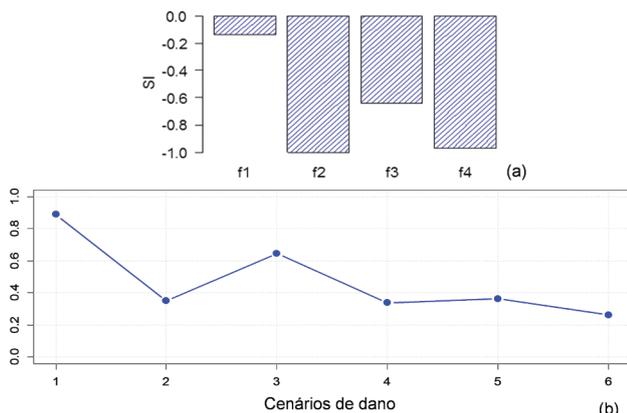


Figura 11 Valores de (a) incrementos simbólicos e (b) de correlação entre estes e os incrementos numéricos

5 Considerações finais

O presente trabalho propõe uma metodologia inovadora para deteção, localização e classificação de dano em estruturas de engenharia civil, que não assume quaisquer premissas sobre a condição estrutural. Esta consiste na combinação de algoritmos de reconhecimento de padrões com análises numéricas e o seu teste e validação foram feitos através da sua aplicação à passagem superior Z24, situada na Suíça e à qual foram impostos cenários de dano durante a sua vida útil.

Os algoritmos de inteligência artificial usados no desenvolvimento da metodologia proposta no presente trabalho consistem nas redes neuronais artificiais e nos algoritmos de *clusters*. As redes neuronais foram utilizadas para “aprender” e estimar a resposta estrutural sob imposição de ações ambientais e operacionais. Os algoritmos de *clusters* aplicados ao *output* das redes neuronais permitiram que a identificação de danos pudesse ser feita de forma totalmente automática e sem assumir quaisquer premissas sobre a condição estrutural.

A automatização da deteção de dano foi levada a cabo através da definição de janelas móveis, garantindo assim que a metodologia se processa de forma contínua e automática ao longo do tempo.

A localização e classificação de dano baseou-se na geração numérica de cenários de alterações estruturais e na comparação dos resultados com o *output* dos algoritmos de *clusters*. Esta comparação permitiu identificar com sucesso o cenário monitorizado *in situ*, de entre um conjunto de cenários gerados numericamente.

Referências

[1] C. R. Farrar; K. Worden – “An introduction to structural health monitoring”, *Philos. Trans. A. Math. Phys. Eng. Sci.*, vol. 365, no. 1851, pp. 303–315, Feb. 2007.

[2] S. W. Doebling; C. R. Farrar; M. B. Prime; D. W. Shevitz – *Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in Their Vibration Characteristics: A Literature Review*, Los Alamos, USA, 1996.

[3] F. L. Wang; T. H. T. Chan; D. P. Thambiratnam; A. C. C. Tan; C. J. L. Cowled – “Correlation-Based Damage Detection for Complicated Truss Bridges Using Multi-Layer Genetic Algorithm”, *Adv. Struct. Eng.*, vol. 15, no. 5, pp. 693–706, May 2012.

[4] S. D. Glaser; A. Tolman – “Sense of Sensing: From Data to Informed Decisions for the Built Environment”, *J. Infrastruct. Syst.*, vol. 14, no. 1, pp. 4–14, 2008.

[5] M. Sahin; R. A. Sheno – “Quantification and localisation of damage in beam-like structures by using artificial neural networks with experimental validation”, *Eng. Struct.*, vol. 25, no. 14, pp. 1785–1802, 2003.

[6] K. Worden; J. M. Dulieu-Barton – “An Overview of Intelligent Fault Detection in Systems and Structures”, *Struct. Heal. Monit.*, vol. 3, no. 1, pp. 85–98, Mar. 2004.

[7] D. F. Giraldo – “Damage Detection Accommodating Varying Environmental Conditions”, *Struct. Heal. Monit.*, vol. 5, no. 2, pp. 155–172, Jun. 2006.

[8] B. Peeters; G. de Roeck – “One-year monitoring of the Z24 Bridge environmental effects versus damage events”, *Earthq. Eng. Struct. Dyn.*, vol. 30, no. 2, pp. 149–171, 2001.

[9] E. Reynders; G. De Roeck – “Continuous vibration monitoring and progressive damage testing on the Z24 bridge”, in *Encyclopedia of Structural Health Monitoring*, 1st ed., Chichester, UK: John Wiley & Sons, 2009, Cap. 126, pp. 2149–2158.

[10] C. M. Bishop – *Pattern Recognition and Machine Learning*. Berkeley, USA: Springer, 2006, p. 748.

[11] T. Hastie – *The Elements of Statistical Learning, Data Mining, Inference and Prediction*, 2nd ed. Stanford, USA: Springer, 2011, p. 763.

[12] A. Cury – *Téchniques D’Anormalité Appliquées a la Surveillance de Santé Structurale*, Université Paris-Est, 2010.

[13] J. Santos; A. D. Orcesi; C. Crémona; P. Silveira – “Baseline-free real-time assessment of structural changes”, *Struct. Infrastruct. Eng. Maintenance, Manag. Life-Cycle Des. Perform.*, 2014.

[14] E. Diday; Noirhomme-Fraiture – *Symbolic Data Analysis and the SODAS Software*. Chichester, UK: John Wiley and Sons, 2008, p. 445.

[15] J. Santos; C. Crémona; A. D. Orcesi; P. Silveira – “Multivariate Statistical Analysis for Early Damage Detection”, *Eng. Struct.*, vol. 56, pp. 273–285, 2013.

[16] G. Milligan; M. Cooper – “An Examination of Procedures for Determining the Number of Clusters in a Data Set”, *Psychometrika*, vol. 50, no. 2, pp. 159–179, 1985.

[17] J. Santos; C. Crémona; A. Orcesi; P. Silveira – “Baseline-Free Real-Time Novelty Detection Using Vibration-Based Symbolic Features”, in *EVACES’13*, 2013, pp. 1–8.

[18] J. P. Santos – *Smart Structural Health Monitoring Techniques for Novelty Identification in Civil Engineering Structures*, Instituto Superior Técnico - University of Lisbon, 2014.

[19] EN1990 – “Eurocode 0: Basis of Structural Design”, Brussels, Belgium, 1990.