

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

Daniel de Almeida Cardoso Soares

**Desenvolvimento de um sistema para monitoramento automático de integridade
estrutural**

Juiz de Fora

2022

Daniel de Almeida Cardoso Soares

Desenvolvimento de um sistema para monitoramento automático de integridade estrutural

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Civil. Área de concentração: Estruturas e Materiais

Orientador: Prof. Dr. Alexandre Abrahão Cury

Coorientador: Prof. Dr. Flávio de Souza Barbosa

Juiz de Fora

2022

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Soares, Daniel de Almeida Cardoso.

Desenvolvimento de um sistema para monitoramento automático de integridade estrutural / Daniel de Almeida Cardoso Soares. -- 2022.

61 f. : il.

Orientador: Alexandre Abrahão Cury

Coorientador: Flávio de Souza Barbosa

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Civil, 2022.

1. Monitoramento de integridade estrutural. 2. Objeto de dados simbólicos. 3. Aplicações experimentais. I. Cury, Alexandre Abrahão, orient. II. Barbosa, Flávio de Souza, coorient. III. Título.

Daniel de Almeida Cardoso Soares

Desenvolvimento de um sistema para monitoramento automático de integridade estrutural

Dissertação apresentada ao Programa de Pós graduação em Engenharia Civil da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Civil. Área de concentração: Estruturas e Materiais

Aprovada em 18 de abril de 2022.

BANCA EXAMINADORA

Prof. Dr. Alexandre Abrahão Cury - Orientador(a)

Universidade Federal de Juiz de Fora

Prof. Dr. Flávio de Souza Barbosa - Coorientador

Universidade Federal de Juiz de Fora

Prof. Dr. Carlos Cristiano Hasenclever Borges

Universidade Federal de Juiz de Fora

Prof. Dr. Ney Roitman

Universidade Federal do Rio de Janeiro

Prof. Dr. Diogo Rodrigo Ferreira Ribeiro

Instituto Superior de Engenharia do Porto

Juiz de Fora, 05/04/2022.



Documento assinado eletronicamente por **Alexandre Abrahao Cury, Professor(a)**, em 18/04/2022, às 16:57, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **Flavio de Souza Barbosa, Professor(a)**, em 18/04/2022, às 17:25, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Carlos Cristiano Hasenclever Borges, Professor(a)**, em 19/04/2022, às 08:39, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ney Roitman, Usuário Externo**, em 19/04/2022, às 14:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Diogo Rodrigo Ferreira Ribeiro, Usuário Externo**, em 19/04/2022, às 15:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **0734927** e o código CRC **BB973C8E**.

AGRADECIMENTOS

É uma honra poder apresentar essa dissertação, e uma grande felicidade estar concluindo essa grande etapa em minha carreira acadêmica. Conquistei muitas coisas valiosas na vida até este momento, como: conhecimento em geral, habilidades artísticas, musicais e esportivas, faculdade e agora o mestrado. Cada conquista foi extremamente facilitada pela ajuda e pelo apoio de muitas pessoas e instituições. Por isso, quero deixar claro o meu profundo agradecimento ao(à):

Meu querido orientador Alexandre Cury, que já vem me acompanhando durante cinco anos, desde a iniciação científica na faculdade, em 2017. Tenho muito a lhe agradecer por todo esse tempo de excelente orientação, pelos ensinamentos, correções de trabalhos acadêmicos e pelas reuniões, nas quais em pouco tempo me passa uma ideia brilhante o suficiente para me manter ocupado por meses. Admiro muito a sua forma eficiente de orientar, dar aulas e corrigir provas. Obrigado pelo bom humor, pela paciência e pela amizade, que torna tudo mais leve e fácil, mesmo quando se trata de assuntos complexos.

Meu coorientador Flávio Barbosa, por toda a confiança e apoio. Sou muito grato por todos os ensinamentos, passados com uma maestria exemplar, principalmente em relação aos temas de dinâmica e análise experimental, que são assuntos fundamentais para a realização deste trabalho. Obrigado por ser excelente, como pessoa e como profissional.

Minha maravilhosa mãe (Angélica), pelo perfeito exemplo de amor incondicional. Tudo o que eu aprendi e conquistei em minha vida teve sua ajuda e apoio fundamentais. Sou eternamente grato por ter você como mãe. Obrigado por todo o investimento em minha educação e desenvolvimento de minhas habilidades e virtudes.

Meus incríveis irmãos Davi e Rharã, que tornam a minha vida muito mais prazerosa e fácil de se viver. O Davi sendo o meu companheiro de sempre, principalmente em relação a esportes, jogos e música, que são aspectos fundamentais e indispensáveis da minha vida. E o Rharã, sendo o companheiro de profissão que sempre me orientou e ensinou com maestria. Muito mais do que isso, ambos me ensinam a ser uma pessoa melhor. Estamos sempre aprendendo e evoluindo juntos. Obrigado pelo infinito companheirismo, pela harmonia e pela amizade. Os meus irmãos são pessoas maravilhosas e estão acompanhados de pessoas maravilhosas. Assim, venho agradecer as minhas queridas cunhadas Tati e Iara, pela grande amizade, diversão, gargalhadas, esportes e comilanças. Vocês são queridas por mim e eu sou grato por suas presenças na minha vida.

Minha amada namorada Miriã, que me ilumina e me faz querer ser o melhor que eu posso ser. Sou extremamente grato por esse relacionamento, por seu companheirismo e apoio amoroso. A sua presença sempre me dá força e ânimo, suas palavras me motivam. Você é maravilhosa e eu sou extremamente feliz por ter você como companheira de vida.

Meus queridos amigos por todos os momentos juntos, sempre com muita diversão e felicidade.

UFJF, por toda minha formação profissional. Agradeço a todos os integrantes dessa excelente instituição, em especial aos professores que me ensinaram tanto e de uma forma exemplar.

FAPEMIG e ao CNPq, por todo o auxílio financeiro durante cinco anos. Isso definitivamente foi uma grandiosa ajuda e motivação.

Consciência Universal, pela existência desse universo perfeito baseado em inteligência amorosa.

RESUMO

Pesquisas recentes têm usado métodos baseados na análise de dados brutos de vibração como base para o Monitoramento de Integridade Estrutural (SHM – *Structural Health Monitoring*, em inglês). Em algumas delas, o conceito de Objeto de Dados Simbólicos (SDO – *Symbolic Data Object*, em inglês) vem sendo empregado e difundido. Uma característica marcante e vantajosa de se utilizar SDOs é que eles possuem uma grande capacidade de compactar dados brutos, isto é, sinais dinâmicos coletados diretamente da estrutura, enquanto mantém a essência das informações originais. Além disso, métodos baseados na utilização de SDOs geralmente possuem um custo computacional muito menor se comparados àqueles baseados no uso de parâmetros modais, haja vista que evitam o processo de identificação modal. Assim, o presente trabalho apresenta uma metodologia para a realização de SHM, implementada em um software denominado ReTiA-SHM (*Real-Time Automated Structural Health Monitoring*). Com o intuito de verificar a funcionalidade e a acurácia na detecção de alterações estruturais, foram utilizados os dados de quatro monitoramentos dinâmicos de estruturas que sofreram algum tipo de alteração ou ação excepcional. As quatro aplicações experimentais referem-se a: *i*) um pórtico metálico no Canadá; *ii*) uma torre de alvenaria na Itália; *iii*) uma ponte rodoviária na França e *iv*) um viaduto ferroviário na França. Os resultados obtidos mostraram que as alterações estruturais ou ações excepcionais foram identificadas com sucesso, com exceção de alguns danos progressivos menores no pórtico metálico. Em alguns casos, observou-se ser necessário um período de adaptação – quando alguns falsos alarmes positivos ocorrem – para que o *software* configure automaticamente os parâmetros de forma a soar alarme apenas em situações que alguma alteração de maior intensidade for encontrada no sinal.

Palavras-chave: *Monitoramento de Integridade Estrutural; Objeto de Dados Simbólicos; Aplicações experimentais.*

ABSTRACT

Recent research has used methods based on raw vibration data analysis as a basis for Structural Health Monitoring (SHM). In some of them, the concept of Symbolic Data Object (SDO) has been used and spread. A remarkable and advantageous feature of using SDOs is that they have a great capacity to compress raw data, that is, dynamic signals collected directly from the structure, while maintaining the essence of the original information. Furthermore, methods based on the use of SDOs generally have a much lower computational cost compared to those based on the use of modal parameters, since they avoid the modal identification process. Thus, the present work presents a methodology for performing SHM, implemented in a software called ReTiA-SHM (Real-Time Automated Structural Health Monitoring). To verify the functionality and accuracy in detecting structural changes, data from four dynamic monitoring of structures that suffered some kind of alteration or exceptional force were used. The four experimental applications refer to: *i*) a steel frame in Canada; *ii*) a masonry tower in Italy; *iii*) a road bridge in France and *iv*) a railway viaduct in France. The results obtained showed that the structural changes or exceptional forces were successfully identified, except for some minor progressive damage to the steel frame. In some cases, it was observed that an adaptation period is necessary – when some false positive alarms occur – so that the software automatically configures the parameters to sound an alarm only in situations when some change of greater intensity is found in the signal.

Keywords: *Structural Health Monitoring; Symbolic Data Object; Experimental applications.*

SUMÁRIO

1	INTRODUÇÃO	9
1.1	OBJETIVO	12
1.1.1	Objetivos específicos	13
1.2	JUSTIFICATIVA	13
1.3	ORGANIZAÇÃO DO TEXTO	14
2	REVISÃO BIBLIOGRÁFICA	15
3	METODOLOGIA	19
3.1	CONSTRUÇÃO DO OBJETO DE DADOS SIMBÓLICOS (SDO)	19
3.2	A MÉTRICA	21
3.3	ESCOLHA DOS PROTÓTIPOS	23
3.4	PARÂMETROS DE DETECÇÃO	24
3.5	MONITORAMENTO EM PARALELO	27
3.6	FUNCIONAMENTO DA METODOLOGIA ADAPTATIVA	27
3.7	INTERFACE GRÁFICA DO <i>SOFTWARE</i>	29
4	APLICAÇÕES PRÁTICAS	32
4.1	APLICAÇÃO 1: PÓRTICO METÁLICO	32
4.2	APLICAÇÃO 2: TORRE <i>GABBIA</i>	41
4.3	APLICAÇÃO 3: PONTE PI-57	45
4.4	APLICAÇÃO 4: VIADUTO FERROVIÁRIO	50
5	CONCLUSÕES	56
5.1	TRABALHOS FUTUROS	57
	REFERÊNCIAS	58

1 INTRODUÇÃO

Estruturas como prédios altos, torres, pontes, viadutos e edifícios históricos podem possuir grande importância social, econômica e política. Por isso, precisam sempre manter um bom nível de integridade, manutenção e segurança. O Monitoramento de Integridade Estrutural (SHM – *Structural Health Monitoring*, em inglês) surgiu para auxiliar na tarefa de manter a estrutura segura e tem sido uma grande fonte de pesquisa nos últimos anos. O SHM consiste em um conjunto de sensores, *hardware* e *software* que tem como objetivo principal notificar ao responsável pela estrutura, o mais rápido possível, a ocorrência de alguma alteração ou dano estrutural. Com estes alarmes prévios, as ações necessárias podem ser tomadas para corrigir o problema rapidamente, antes que ele evolua e possa causar diversos prejuízos, inclusive com risco de perda de vidas.

Alguns exemplos de pontes e viadutos que sofreram colapso são apresentados na Tabela 1, assim como suas possíveis causas. Esses incidentes poderiam ser minimizados ou evitados com o emprego de um SHM eficiente.

Tabela 1 – Exemplos de falhas em pontes e suas causas

Ponte	Localização	Ano	Causa
Ponte do rio Mianus	EUA	1983	Corrosão do metal e fadiga
Viaduto da rua Cypress	EUA	1989	Terremoto
Ponte Seongsu	Coréia do Norte	1994	Falha estrutural: defeito na solda
Ponte Tarcoles	Costa Rica	2009	Sobrecarga devido a caminhões pesados
Myllysilta	Finlândia	2010	Inclinação devido à falha nos pilares
Ponte Gongguan	China	2011	Sobrecarga
Ponte Skjeggstad	Noruega	2015	Deslocamento de pilar
Viaduto Vivekananda	Índia	2016	Ligação seção e pilar
Viaduto no Eixão Sul	Brasília (Brasil)	2018	Deterioração da estrutura/falta de manutenção

Fonte: Adaptado de Alves (2016).

Além dos incidentes mencionados na Tabela 1, um exemplo recente de desastre foi o colapso de uma ponte estaiada em Gênova, na Itália, que levou 43 pessoas ao óbito (Fig. 1) (GLANZ *et al.*, 2018).

Figura 1 – Colapso da ponte em Gênova, na Itália, em 2018.



Fonte: Adaptado de: Glanz *et al.* (2018).

A implementação de um SHM contínuo geralmente não possui baixo custo devido ao investimento inicial em equipamentos e sistemas, além da necessidade de inspeção humana, em alguns casos. Contudo, uma vez implementado, o monitoramento não possuirá altos custos de manutenção, e o próprio sistema de monitoramento poderá avisar, quase que imediatamente, se alguma alteração estrutural for detectada. Recentes avanços tecnológicos e metodologias inovadoras estão contribuindo para criar sistemas de SHM cada vez mais confiáveis e precisos. Atualmente, muitas estruturas estão sendo monitoradas continuamente através de variadas metodologias (CARDOSO; CURY; BARBOSA, 2019). Como exemplo, pode-se citar o viaduto de Millau na França (CACHOT *et al.*, 2015), a ponte Tsing Ma na China (NI *et al.*, 2011), o arranha-céu Burj Khalifa em Dubai (KIJEWSKI-CORREA *et al.*, 2013), a ponte Golden Gate nos Estados Unidos, a ponte Minami Bisan-Seto no Japão, a ponte Grande Belt na Dinamarca, entre outras que são mencionadas em (XU; XIA, 2012). A degradação natural e o envelhecimento das estruturas são uma das principais causas da instalação dos programas de monitoramento.

Um dano estrutural pode ocorrer de várias formas, mas normalmente o efeito do dano remete a alterações nas propriedades físicas e geométricas dos materiais. Outro efeito comum é a mudança nas condições de apoio dos elementos estruturais (ALVES, 2016).

O paradigma da identificação de danos estruturais consiste em várias etapas, como a detecção, quantificação, localização, prevenção e prognóstico (RYTTER, 1993). O presente trabalho possui foco na detecção do dano, que é um aspecto fundamental para garantir a segurança estrutural.

De forma ampla, pode-se dizer que existem dois tipos de metodologia para SHM baseado em dados de vibração: o *supervisionado* e o *não-supervisionado*. Um monitoramento *supervisionado* é aquele no qual existe a necessidade de um período de adaptação para poder começar a operar. Ou seja, é necessário se ter uma certa quantidade prévia de dados extraídos da estrutura alvo. Esse período de adaptação pode ser longo, para que procedimentos de aprendizagem estatística possam ser aplicados aos dados da estrutura submetida a diferentes condições ambientais e de tráfego, enquanto se assume que a estrutura permanece íntegra. Após a realização desse processo, o monitoramento prossegue comparando novos resultados aos resultados esperados. Assim, é possível detectar alguma alteração no comportamento da estrutura que pode ser consequência de um dano estrutural. Já o monitoramento do tipo *não-supervisionado* não requer um histórico de dados coletados previamente da estrutura e entra em operação quase instantaneamente após a implementação do sistema (CARDOSO *et al.*, 2019).

É possível monitorar uma estrutura estimando-se constantemente seus parâmetros modais, principalmente as frequências naturais de vibração. Foi percebido que danos estruturais podem causar variações nas frequências naturais das estruturas, e esse foi o motivo para se utilizar esse parâmetro modal em SHM (DOEBLING, 1996). Na maioria dos casos, os danos provocam alterações nas frequências naturais por causarem reduções da rigidez da estrutura (ALVANDI; CRÉMONA, 2016, ZHOU; NI; KO, 2011).

No entanto, esse tipo de monitoramento possui um custo computacional geralmente maior, pois necessita de um procedimento de identificação modal. Além disso, esse tipo de análise pode não ser sensível o suficiente para detectar danos estruturais em sua fase inicial. A razão para isso é que muitos danos ocorrem localmente e podem não influenciar significativamente os primeiros modos de vibração da estrutura (CARDOSO; CURY; BARBOSA, 2017). Muitos monitoramentos baseados em identificação modal possuem a premissa de que o sistema é linear. Isso também pode ser caracterizado como uma limitação, visto que muitos danos (como trincas, por exemplo) provocam fortes efeitos não lineares. Estruturas flexíveis e alguns materiais também induzem fortes não linearidades no sistema.

Outro fato que dificulta a identificação de danos estruturais através do monitoramento dos parâmetros modais é a variação das características ambientais, como temperatura, vento,

umidade e tráfego. O artigo de Soares e Cury (2018) apresenta um estudo com aplicação experimental que avalia os efeitos da variação de temperatura e de dano sobre as frequências naturais de uma viga metálica. Nesse trabalho, foi mostrado que, apesar de ser possível estabelecer relações entre a variação de temperatura e as frequências naturais da viga, a variação da primeira pode provocar alterações maiores nos parâmetros modais do que os próprios danos, dificultando, assim, as suas corretas identificações.

É extensa a quantidade de trabalhos que abordam a identificação de dano com base em parâmetros modais. Muitas técnicas são utilizadas para tratar esses dados, como: indicadores estatísticos, *clustering* (ou agrupamento), Análise de Componentes Principais, Redes Neurais Artificiais, Máquinas de Vetor Suporte, entre outras. Pode-se citar os trabalhos de Sahin e Sheno (2003), Gomes (2004), Lee *et al.* (2005), Fang *et al.* (2005), Jeyasehar e Sumangala (2006), Mehrjoo (2008), Rucka e Wilde (2010), Borowiec e Ziemianski (2011), Yu *et al.* (2013) e Nguyen *et al.* (2015).

Durante as últimas décadas, os pesquisadores procuram desenvolver indicadores cada vez mais consistentes e confiáveis para solucionar o paradigma da identificação de danos. Mais recentemente, muitas pesquisas estão direcionadas para a construção de novos indicadores de danos com base no uso de dados brutos, ou seja, sinais dinâmicos coletados da estrutura (TORRES *et al.*, 2018).

Uma possibilidade promissora é a utilização de Objetos de Dados Simbólicos (SDO – *Symbolic Data Object*, em inglês), cuja intenção é representar uma grande quantidade de dados brutos por meio de poucos valores, com o mínimo de perda da essência das informações do sinal original. Esse tipo de abordagem vem sendo tema de muitas pesquisas nos últimos anos (ALVES *et al.*, 2016, SANTOS *et al.*, 2015, SANTOS *et al.*, 2017, CARDOSO *et al.*, 2019) devido à sua grande capacidade de compactação de informação e manipulação com baixo custo computacional. Existem diversas metodologias que utilizam SDOs como base para detectar novidades estruturais com a vantagem de não necessitar de pós-processamento.

1.1 OBJETIVO

O objetivo principal do presente trabalho é desenvolver e testar uma metodologia para monitoramento automático de integridade estrutural utilizando SDOs. Essa metodologia foi implementada em um novo *software*, e foi desenvolvida a partir do aperfeiçoamento da metodologia de SHM baseada em SDOs apresentada por Cardoso, Cury e Barbosa (2019).

1.1.1 Objetivos específicos

- Avaliar a sensibilidade da metodologia quanto aos efeitos operacionais e ambientais embutidos nas respostas dinâmicas da estrutura;
- Remover – ou mitigar – a ocorrência de falsos alarmes, principalmente os falsos negativos;
- Eliminar a necessidade de escolha de parâmetros de entrada do *software* desenvolvido, facilitando o trabalho do usuário-alvo (gestor/engenheiro) responsável pelo monitoramento da estrutura.

1.2 JUSTIFICATIVA

A primeira justificativa para realização deste trabalho é o fato de que poucas pesquisas estão focadas na realização de SHM com base diretamente nas respostas dinâmicas de estruturas sujeitas à vibração ambiente. Existem diversas ferramentas para manipulação dos sinais dinâmicos, porém é difícil utilizá-las apropriadamente para um SHM, devido à presença de ruídos e à complexidade desse tipo de sinal.

Outra justificativa para a realização deste trabalho é que já foram desenvolvidos muitos métodos baseados em aprendizado supervisionado (como redes neurais e máquinas de vetor suporte, por exemplo), capazes de detectar danos estruturais. Esses métodos são eficientes, mas requerem muito mais conhecimento prévio do comportamento da estrutura em seu estado íntegro e precisam de um período maior para começar a operar (necessitam de mais dados para servirem de base para o aprendizado de máquina).

O trabalho desenvolvido por Cardoso, Cury e Barbosa (2019) apresenta uma metodologia eficiente para detecção de danos estruturais baseada em SDOs. Contudo, existe uma dificuldade associada, que é a escolha do comprimento ideal desses SDOs para cada monitoramento específico. Por isso, este trabalho oferece um aperfeiçoamento dessa metodologia de referência, baseado na ideia de se realizar um SHM em paralelo, considerando vários comprimentos de SDOs ao mesmo tempo. Além disso, esses comprimentos vão se modificando durante o monitoramento para se adaptarem a cada caso em específico, com o objetivo de diminuir a probabilidade de ocorrência de falsos alarmes positivos. Essa metodologia foi implementada em um *software* original chamado ReTiA-SHM.

1.3 ORGANIZAÇÃO DO TEXTO

Essa dissertação é composta de 5 capítulos, incluindo o presente, no qual foi realizada uma breve introdução sobre o tema abordado e sua importância. Apresentou-se, também, os objetivos pretendidos nesta pesquisa e a justificativa para sua realização.

No segundo capítulo é apresentada uma revisão bibliográfica, onde são descritos brevemente alguns trabalhos relacionados ao tema SHM baseado na utilização de dados brutos.

No terceiro capítulo é apresentada a metodologia proposta de forma detalhada, incluindo o funcionamento e a interface gráfica do *software* desenvolvido.

No quarto capítulo, a metodologia proposta (implementada no *software*) é testada e avaliada a partir de quatro aplicações experimentais de estruturas reais: *i*) um pórtico metálico no Canadá; *ii*) uma torre de alvenaria na Itália; *iii*) uma ponte rodoviária na França e *iv*) um viaduto ferroviário na França.

No quinto e último capítulo são apresentadas as considerações finais do trabalho, além de algumas sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Dado que o presente trabalho apresenta uma alternativa para a realização de SHM com base em dados brutos, a seguir serão mencionados alguns trabalhos da literatura que também utilizam esse tipo de entrada. Contudo, cada trabalho utiliza uma combinação diferente de técnicas para tratar esses dados e atingir o objetivo principal de identificar danos estruturais.

Zang, Friswell e Imregun (2004) exploraram uma nova abordagem para detectar danos estruturais com base na Análise de Componentes Independentes (ICA) e em Redes Neurais Artificiais (ANN). A ICA foi utilizada para capturar a essência dos dados de vibração medidos, e as ANNs foram criadas utilizando matrizes de mistura como entrada. Para demonstrar a eficiência do método, foi realizado um estudo com dados numéricos referentes a uma estrutura treliçada e uma análise experimental de uma estrutura metálica de uma estante. Ambas as aplicações obtiveram resultados que foram bem-sucedidos em detectar os estados estruturais com boa precisão e repetibilidade.

Silva *et al.* (2007) aplicaram um modelo de duas etapas denominado autorregressivo e autorregressivo com entradas exógenas (AR-ARX) para diagnosticar dano ou deterioração estrutural. O algoritmo utilizado baseia-se no monitoramento do erro residual de índices sensíveis ao dano. O trabalho também utilizou a Análise de Componentes Principais (PCA) para compactar os dados de entrada e o *clustering fuzzy c-means* para quantificar os índices sensíveis ao dano de forma não-supervisionada. O algoritmo foi testado em um problema com diferentes padrões de danos, e as respostas obtidas apresentaram altos níveis de correlação com os diferentes estados estruturais.

Li *et al.* (2008) desenvolveram uma metodologia para o diagnóstico de falhas em elementos rolantes baseado na transformada *wavelet*. A eficiência de tal metodologia foi atestada com sinais oriundos de rolamentos com danos em diferentes localizações e com diferentes intensidades. Os resultados demonstraram que o uso de WTK (*wavelet transform-based kurtosis*, do inglês) no processamento de sinais de vibração possui excelente capacidade para diagnosticar falhas em elementos rolantes.

Park *et al.* (2008) propuseram um método prático para conduzir SHM sem fio. O método baseia-se na impedância eletromecânica, e faz uso das técnicas Análise de Componentes Principais (PCA) e *clustering (k-means)*. A PCA foi utilizada para compactar os dados dinâmicos e eliminar ruídos. O *clustering k-means* foi utilizado para separar os estados estruturais utilizando duas componentes principais como entrada. Foi realizado um estudo

experimental que inspeciona parafusos soltos em uma estrutura de alumínio. A aplicação experimental mostrou que o método proposto obteve resultados satisfatórios.

Cury e Crémona (2012) apresentam uma nova abordagem para avaliar estados estruturais baseada no conceito de Análise de Dados Simbólicos (SDA). Essa análise foi aplicada tanto em sinais dinâmicos brutos quanto em parâmetros modais (frequências naturais e formas modais). Os dados de entrada foram transformados em dados simbólicos e foram aplicados três algoritmos de aprendizagem: Árvores de Decisão Bayesianas, Redes Neurais e Máquinas de Vetor Suporte. Foram realizadas simulações numéricas para avaliar as probabilidades de detecção referentes aos níveis de dano. Nesse procedimento também foram incluídos vários níveis de ruído no sinal, para testar a sensibilidade das técnicas. Também foram utilizados dados experimentais de um viaduto ferroviário, na França. Os resultados das aplicações mostraram que, tanto considerando dados dinâmicos quanto parâmetros modais, os algoritmos de aprendizado combinados com o conceito de dados simbólicos são capazes de classificar e discriminar modificações estruturais com alta probabilidade de detecção.

O livro de Farrar e Worden (2012) apresenta informações abrangentes sobre SHM, com foco no uso de aprendizado de máquina/reconhecimento de padrões. Os processos inerentes ao SHM são explicados com detalhes e conta com muitas aplicações numéricas e experimentais. É mostrado, através de pesquisas de vários autores, que o paradigma de aprendizado de máquinas fornece uma estrutura ampla para o desenvolvimento de soluções para SHM.

Alves (2016) utilizou duas estratégias para detectar, localizar e quantificar de danos estruturais. Uma é baseada em dados brutos, e pode ser subdividida em métodos de classificação não-supervisionados (*clustering* hierárquico, *k-means* e *c-means*) e supervisionadas (redes neurais e máquinas de vetor suporte). A outra estratégia é baseada em parâmetros modais e modelos computacionais, com a utilização de métodos de otimização (algoritmos genéticos) para atualizar esses modelos. As metodologias propostas foram aplicadas a diversos estudos de caso (numéricos e experimentais) para avaliar suas eficiências. Todas as abordagens apresentaram respostas que aferem, com certo grau de confiança, o estado das estruturas.

Zhou *et al.* (2016) propuseram uma nova abordagem para detectar danos estruturais baseada em transmissibilidade, que foi trabalhada juntamente com técnicas de *clustering* hierárquico e análises de similaridade. A transmissibilidade deriva-se diretamente dos sinais dinâmicos. O monitoramento iniciou-se utilizando o *clustering* hierárquico para agrupar os diferentes níveis de dano. Essa técnica foi aplicada sobre a transmissibilidade de forma não-

supervisionada. Foram exploradas outras técnicas para fins de comparação, entre elas, a medida de similaridade de cosseno e uma medida de distância. Todas as abordagens descritas foram testadas para verificar suas acurácias com respeito a detecção de danos estruturais. Para isso, foram utilizados dados numéricos de uma estrutura de 10 pavimentos e dados experimentais de uma viga livre. Os resultados das aplicações mostraram bom desempenho na detecção dos danos estruturais, o que indica que as abordagens possuem potencial para serem aplicadas na vida real da engenharia.

Torres *et al.* (2018) utilizaram Estatísticas de Ordem Superior (HOS – *Higher-Order Statistic*, do inglês) juntamente com duas técnicas de *clustering* (*k-means* e *c-means*) para detectar danos estruturais. Para verificar a eficiência da metodologia, duas aplicações foram consideradas: um estudo numérico de um modelo de viga biapoiada e um SHM de um viaduto ferroviário, na França. As duas aplicações levaram a resultados que comprovam que o uso de HOS aliada às técnicas de *clustering* é capaz de classificar os diferentes cenários de danos (ou alterações estruturais) adequadamente.

Finotti, Cury e Barbosa (2019) realizaram uma investigação sobre alguns parâmetros estatísticos utilizados para caracterizar sinais de aceleração e detectar danos estruturais. Dois algoritmos de aprendizado de máquina foram comparados: Redes Neurais Artificiais e Máquinas de Vetor Suporte. Os algoritmos foram testados com dados de simulações numéricas e de duas estruturas reais (uma viga de aço em um laboratório e um viaduto ferroviário). Os resultados obtidos mostraram que ambos os métodos obtiveram bons resultados na identificação das alterações estruturais. As taxas de classificação correta de estados estruturais atingiram níveis superiores a 80%.

Entezami, Sarmadi e Mariani (2020) propuseram um método de aprendizado baseado em análise de sinais temporais, *deep learnig* e a métrica de distância *Mahalanobis*. O objetivo principal foi lidar com a questão da análise de *Big Data* e detectar estados estruturais danificados de forma não-supervisionada. Para verificar a eficácia da abordagem proposta, foi utilizado um grande conjunto de dados experimentais extraídos de uma ponte estaiada. Apesar da questão do processamento de *Big Data*, a abordagem se mostrou altamente bem-sucedida na detecção precoce dos danos estruturais.

Nunes *et al.* (2020) apresentaram uma nova abordagem para SHM em tempo real utilizando indicadores estatísticos (para caracterizar o sinal no domínio do tempo) e técnicas de inteligência computacional. Foi construído um classificador híbrido utilizando métodos de classificação supervisionados (Redes Neurais Artificiais) e não-supervisionados (agrupamento

k-means). Foram utilizados estudos numéricos e experimentais para atestar a eficiência da metodologia. As aplicações revelaram que a metodologia possui desempenho promissor.

Gao *et al.* (2021) combinaram uma modelagem de séries temporais com o aprendizado de máquina para extrair os parâmetros que identificam o dano estrutural. Foi proposta uma estrutura que contempla um aprendizado de máquina autorregressivo de média móvel (ARIMA-ML, *Auto-Regressive Integrated Moving-Average Machine Learning*, do inglês) para determinação de parâmetros, extração e classificação de recursos. Foram estipuladas três tarefas para serem avaliadas: detecção de danos globais, detecção de danos locais e o reconhecimento de padrões de danos locais. Para realizar essa avaliação, foram utilizados dados de aceleração de uma estrutura de aço sobre uma mesa de vibração. Os resultados mostraram uma precisão de 97%, 98% e 80% para cada uma das três tarefas, respectivamente. Concluiu-se que o *framework* ARIMA-ML proposto possui alto potencial para realizar SHM com dados brutos de entrada.

Finotti *et al.* (2022) propuseram uma abordagem para detecção de alterações estruturais com base em um algoritmo chamado *Sparse Autoencoder* (SAE). O SAE foi utilizado para caracterizar as respostas dinâmicas das estruturas, e o gráfico de controle *Shewhart T* foi empregado para detectar anomalias a partir dos recursos extraídos do SAE. Para testar a metodologia, foram utilizados dados de SHM de uma ponte denominada Z24 e do campanário de *San Vittore*, na Itália. As alterações estruturais foram detectadas corretamente pela metodologia, mesmo sob variações de temperatura.

Os parágrafos anteriores mostram que existem inúmeras maneiras de abordar o SHM com base em dados brutos. Isso prova que esse campo de pesquisa é extenso e que novas alternativas sempre podem ser exploradas, com o objetivo de desenvolver metodologias cada vez mais consistentes e confiáveis para solucionar o paradigma da identificação de danos.

3 METODOLOGIA

A metodologia de SHM utilizada neste trabalho é baseada no SDO e no sistema de detecção de alterações estruturais apresentado no trabalho de Cardoso, Cury e Barbosa (2019), no qual foi desenvolvido um novo SDO, que engloba informações do sinal nos domínios do tempo e da frequência.

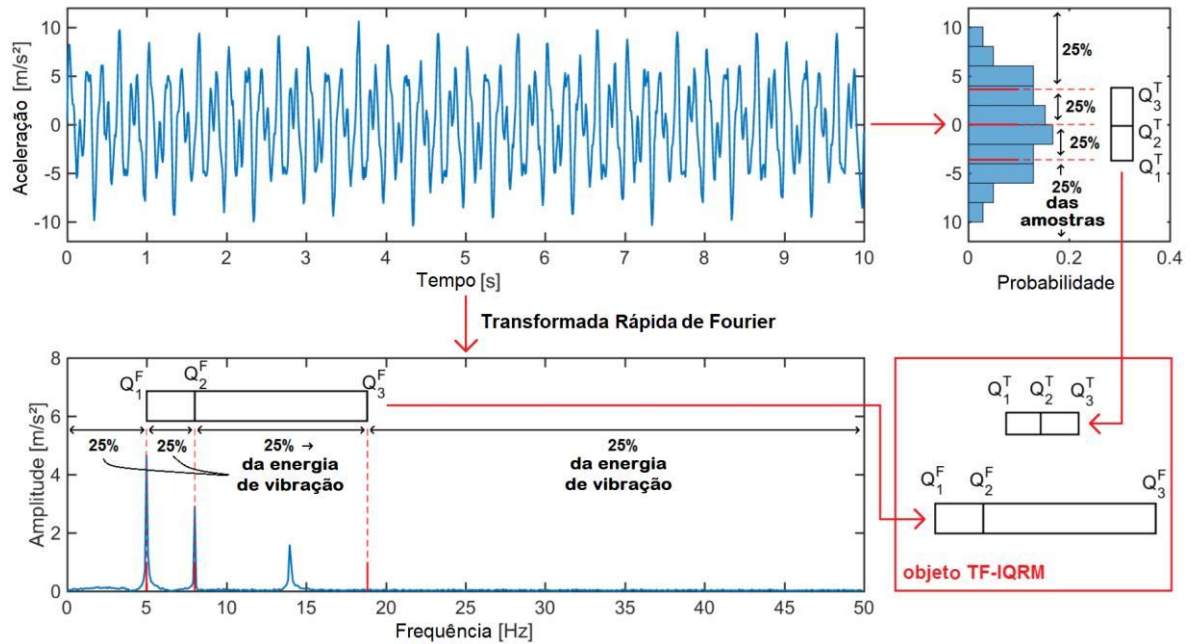
3.1 A CONSTRUÇÃO DO OBJETO DE DADOS SIMBÓLICOS (SDO)

Inicialmente, as informações dinâmicas são coletadas diretamente da estrutura por meio de sensores. O mais usual é realizar a instalação de acelerômetros em pontos estratégicos da estrutura, geralmente aqueles que possuem as maiores amplitudes de vibração. A estrutura pode estar sujeita apenas à vibração ambiente, como vento e tráfego, ou também a carregamentos forçados (por *shakers*, por exemplo).

Após a coleta dos dados brutos, é possível transformar esse sinal em SDOs, que são calculados com base em um comprimento pré-definido L , em segundos, do sinal original. Cada sensor representa um canal e de cada canal são coletados seis valores por SDO, três correspondendo aos três quartis da densidade de pontos no domínio do tempo e três correspondendo aos três quartis do espectro do sinal no domínio da frequência. Para esta última etapa, é inicialmente necessário aplicar a Transformada Rápida de Fourier (FFT) sobre o sinal original. A Figura 2 ilustra o procedimento de extração de um SDO de comprimento $L = 10s$, de um único canal.

O SDO é denominado TF-IQRM, onde IQR se refere ao intervalo interquartil, M se refere à mediana (segundo quartil) e TF indica que foram considerados aspectos do sinal nos domínios do tempo e da frequência.

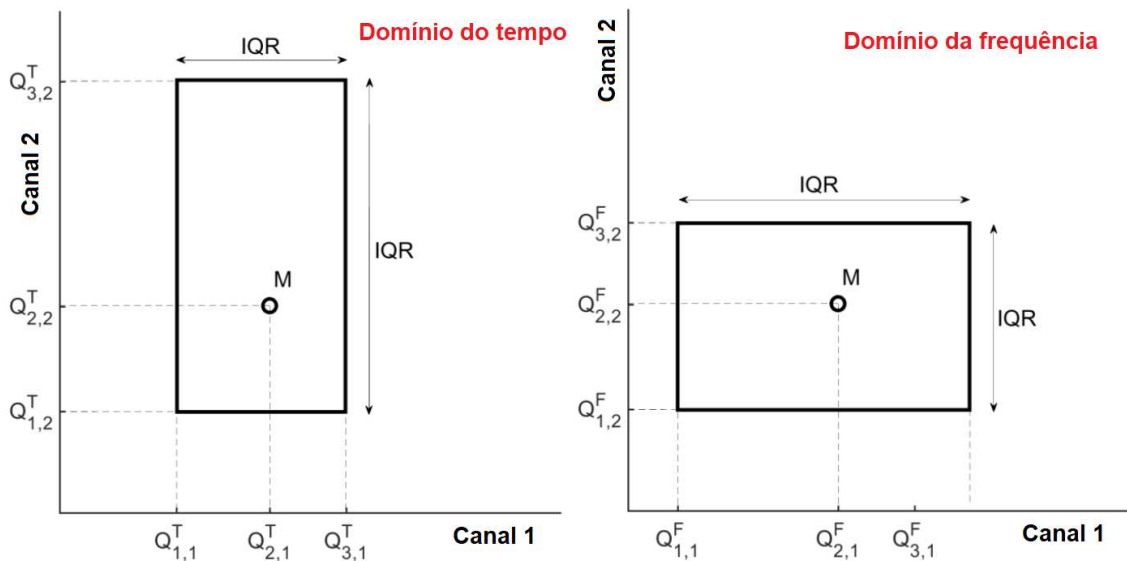
Figura 2 – Procedimento para obtenção de um SDO



Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).

A Figura 3 representa geometricamente um objeto TF-IQRM que possui dois canais de aquisição. Nesse caso, o objeto pode ser representado por dois retângulos, um no domínio do tempo e um no domínio da frequência, cada um com um ponto dentro. As dimensões dos retângulos são definidas pelos primeiros e terceiros quartis, e os pontos internos possuem as coordenadas das medianas (segundos quartis).

Figura 3 – Representação geométrica de um objeto TF-IQRM de dois canais



Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).

O número de canais de aquisição não possui um limite máximo e, normalmente, são utilizados mais de dois canais em um SHM. De forma genérica, para uma quantidade p de canais, um SDO índice i pode ser escrito por meio de seis vetores. As equações (1) e (2) apresentam os vetores do domínio do tempo (sobrescrito T) e do domínio da frequência (sobrescrito F), respectivamente.

$$\mathbf{L}_i^T = \begin{bmatrix} Q_{1,1}^T \\ Q_{1,2}^T \\ Q_{1,3}^T \\ \vdots \\ Q_{1,p}^T \end{bmatrix}, \mathbf{M}_i^T = \begin{bmatrix} Q_{2,1}^T \\ Q_{2,2}^T \\ Q_{2,3}^T \\ \vdots \\ Q_{2,p}^T \end{bmatrix}, \mathbf{U}_i^T = \begin{bmatrix} Q_{3,1}^T \\ Q_{3,2}^T \\ Q_{3,3}^T \\ \vdots \\ Q_{3,p}^T \end{bmatrix} \quad (1)$$

$$\mathbf{L}_i^F = \begin{bmatrix} Q_{1,1}^F \\ Q_{1,2}^F \\ Q_{1,3}^F \\ \vdots \\ Q_{1,p}^F \end{bmatrix}, \mathbf{M}_i^F = \begin{bmatrix} Q_{2,1}^F \\ Q_{2,2}^F \\ Q_{2,3}^F \\ \vdots \\ Q_{2,p}^F \end{bmatrix}, \mathbf{U}_i^F = \begin{bmatrix} Q_{3,1}^F \\ Q_{3,2}^F \\ Q_{3,3}^F \\ \vdots \\ Q_{3,p}^F \end{bmatrix} \quad (2)$$

sendo $Q_{k,r}$ o quartil k , do canal $r = 1, 2, 3, \dots, p$; os vetores \mathbf{L} , \mathbf{M} e \mathbf{U} contêm o primeiro, segundo e terceiro quartis, respectivamente. Os quartis mostrados na Eq. (1) possuem unidades de acordo com a configuração do sensor utilizado e, aqueles mostrados pela Eq. (2), são os índices dos coeficientes FFT.

3.2 A MÉTRICA

Como a proposta é detectar alterações estruturais, é necessário adotar alguma medida de dissimilaridade entre os SDOs. No presente trabalho, será utilizada a métrica simbólica criada por Cardoso *et al.* (2019), que calcula a distância d entre dois SDOs i e j de acordo com a Eq. (3):

$$d_{i,j} = \frac{\|\Delta_{i,j}^T\|}{\max(\overline{\text{RMS}}_i, \overline{\text{RMS}}_j)} + \frac{\|\Delta_{i,j}^F\|}{N/2} \quad (3)$$

onde $\overline{\text{RMS}}_i$ é a média dos valores de Raíz Quadrada Média dos p canais do SDO i ; N é o número de pontos no espectro de frequência (número de pontos FFT); $\|\bullet\|$ é a norma Euclidiana do vetor \bullet ; $\Delta_{i,j}^T$ e $\Delta_{i,j}^F$ são vetores de distância, definidos pelas Eqs. (4) e (5):


$$\Delta_{i,j}^T = \begin{bmatrix} \|L_j^T - L_i^T\| \\ \|M_j^T - M_i^T\| \\ \|U_j^T - U_i^T\| \end{bmatrix} \quad (4)$$

$$\Delta_{i,j}^F = \begin{bmatrix} \|L_j^F - L_i^F\| \\ \|M_j^F - M_i^F\| \\ \|U_j^F - U_i^F\| \end{bmatrix} \quad (5)$$

Note que a métrica mostrada na Eq. (3) sempre resulta em um valor adimensional composto por duas parcelas expressando dissimilaridades: uma no domínio do tempo e outra no domínio da frequência. Foi verificado que essas duas parcelas contribuem com o valor de distância calculado. Contudo, considerando as aplicações experimentais deste trabalho, a parcela referente ao domínio do tempo apresentou maior impacto (de 50 a 80%, aproximadamente).

A Figura 4a mostra dois objetos TF-IQRM bidimensionais (2 canais) e a relação entre eles. Cada um desses SDOs é definido pelos três vetores da Eq. (1) ou (2). A Figura 4b representa geometricamente o vetor de distância tridimensional da Eq. (4) ou (5), que é composto pelas normas das distâncias entre os quartis dos dois SDOs.

Figura 4 – Representação gráfica da métrica: (a) Relação entre dois SDOs; (b) Vetor de distância



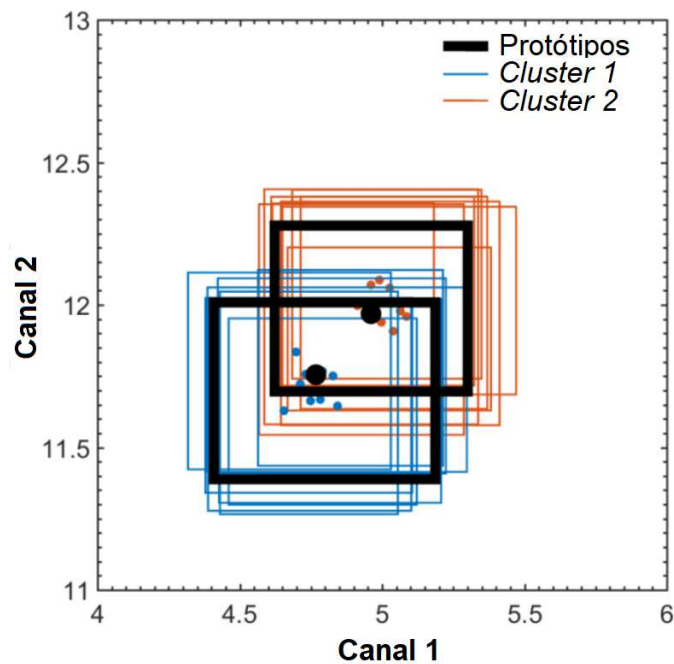
Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).

Para objetos com mais canais, a relação é a mesma, mas envolvem hiper retângulos que não podem ser representados graficamente.

3.3 ESCOLHA DOS PROTÓTIPOS

A presente metodologia é baseada no conceito de uma janela que se move no tempo (TW - *Time-Window*, em inglês). Esta janela é composta por S SDOs, cada um com tamanho L , em segundos. A técnica de agrupamento k -medoids é aplicada a cada nova janela, visando agrupar objetos por similaridade, gerando k clusters, onde $k \in [2, S-1]$. Cada cluster é representado por um SDO protótipo (KAUFMAN; ROUSSEEUW, 2009), que é escolhido como sendo o objeto que possui a menor soma das distâncias entre os demais SDOs pertencentes ao mesmo cluster. A Figura 5 ilustra dois clusters de SDOs de dois canais, e seus protótipos.

Figura 5 – Exemplo de Clusters de SDOs e protótipos



Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).

A escolha otimizada do número k de clusters de um conjunto de SDOs é realizada através de um sistema de votação, no qual são utilizadas quatro técnicas de validação diferentes. Essas técnicas também foram utilizadas no trabalho de Cardoso *et al.* (2019), são elas: Calinski-Harabasz (KALINSKI; HARABASZ, 1974), Davies-Bouldin (DAVIES; BOULDIN, 1979), Gap Statistic (TIBSHIRANI; WALTHER; HASTIE, 2001) e Silhouette (ROUSSEEUW, 1987). Cada uma dessas técnicas vai sugerir um único número de partições k

de *clusters*. O número de partições k mais votado é adotado. Em caso de empate, adota-se o menor número entre os empatados.

3.4 PARÂMETROS DE DETECÇÃO

O primeiro parâmetro de detecção a ser apresentado é o chamado Índice de Novidade (NI – *Novelty Index*, em inglês). Após a escolha dos protótipos, o parâmetro NI é calculado a partir da Eq. (6):

$$NI_{TW} = \max(d_{i,j}) | i, j = p_1, p_2, \dots, p_k \quad (6)$$

onde NI_{TW} é dado como a maior distância entre todos os pares possíveis de SDOs protótipos, dentro de uma janela de índice TW ; a distância $d_{i,j}$ é calculada pela Eq. (3); e p_1, p_2, \dots, p_k são os índices dos protótipos.

Para estimar se alguma alteração estrutural foi detectada, é necessário comparar o valor de NI com algum limite de confiança (CB – *Confidence Boundary*, em inglês). Aqui, é utilizado o CB proposto por Cardoso *et al.* (2019), cujo cálculo é composto por duas parcelas (Eq. (7)), uma representando o valor esperado, e outra que engloba a variabilidade dos valores de NI.

$$CB_{TW} = \overbrace{\text{med}_i(NI_i)}^{\text{Valor Esperado}} + t_{[S-1; 99,9\%]} \times \frac{\overbrace{1,1926 \text{ med}_i \left\{ \text{med}_j |NI_i - NI_j| \right\}}^{\text{Variabilidade}}}{\sqrt{S}}; \quad i, j = TW - S + 1, \dots, TW \quad (7)$$

onde CB_{TW} é o limite de confiança estabelecido em uma janela de índice TW ; $\text{med}(\bullet)$ é a mediana de \bullet ; $t_{[S-1; 99,9\%]}$ é o percentil 99,9 de uma distribuição *t-Student* com $S-1$ graus de liberdade (é usada uma distribuição do tipo *t-Student* porque a população da amostra é pequena); o fator 1,1926 presente na variabilidade é definido por Rousseeuw e Croux (1993) para tornar este estimador consistente com populações gaussianas.

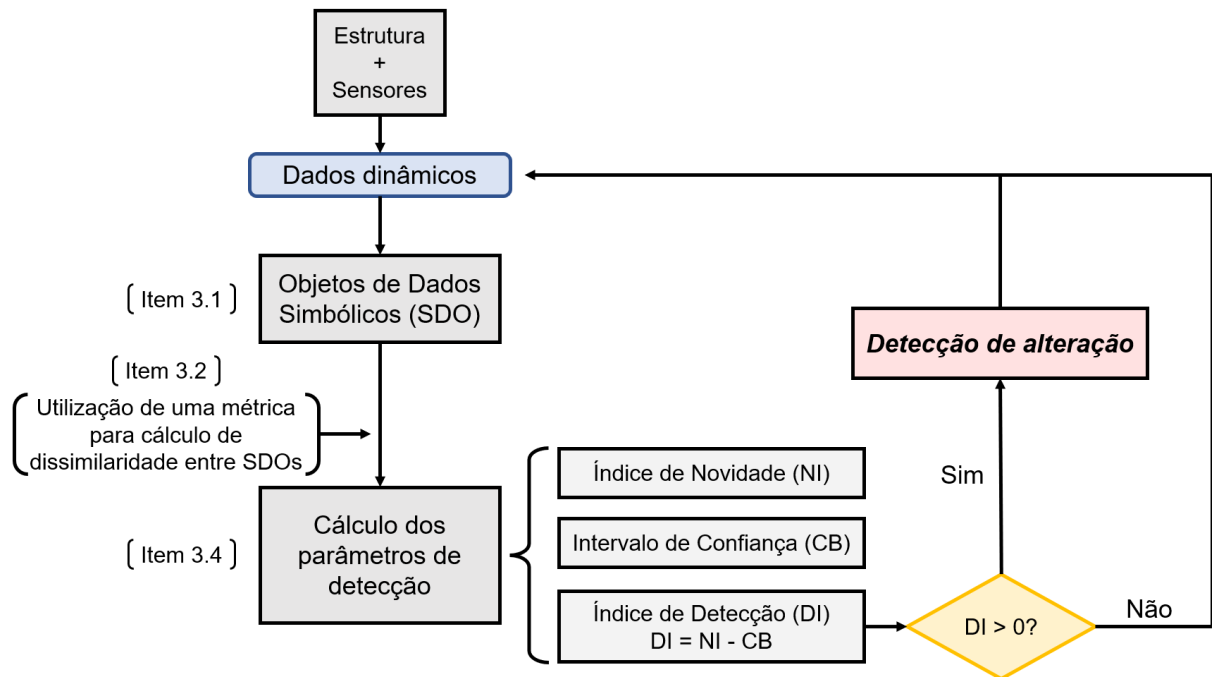
Assim, o chamado Índice de Detecção (DI – *Detection Index*, em inglês) pode ser definido simplesmente como mostra a Eq. (8):

$$DI_{TW} = NI_{TW} - CB_{TW} \quad (8)$$

Desta forma, quando DI_{TW} apresenta um valor positivo, significa que alguma alteração foi detectada no sinal (o Índice de Novidade foi maior que o Limite de Confiança).

O Fluxograma 1 apresenta a metodologia descrita até este ponto. Percebe-se que o monitoramento é um processo contínuo, que verifica e avisa, rapidamente, se alguma alteração for detectada no sinal.

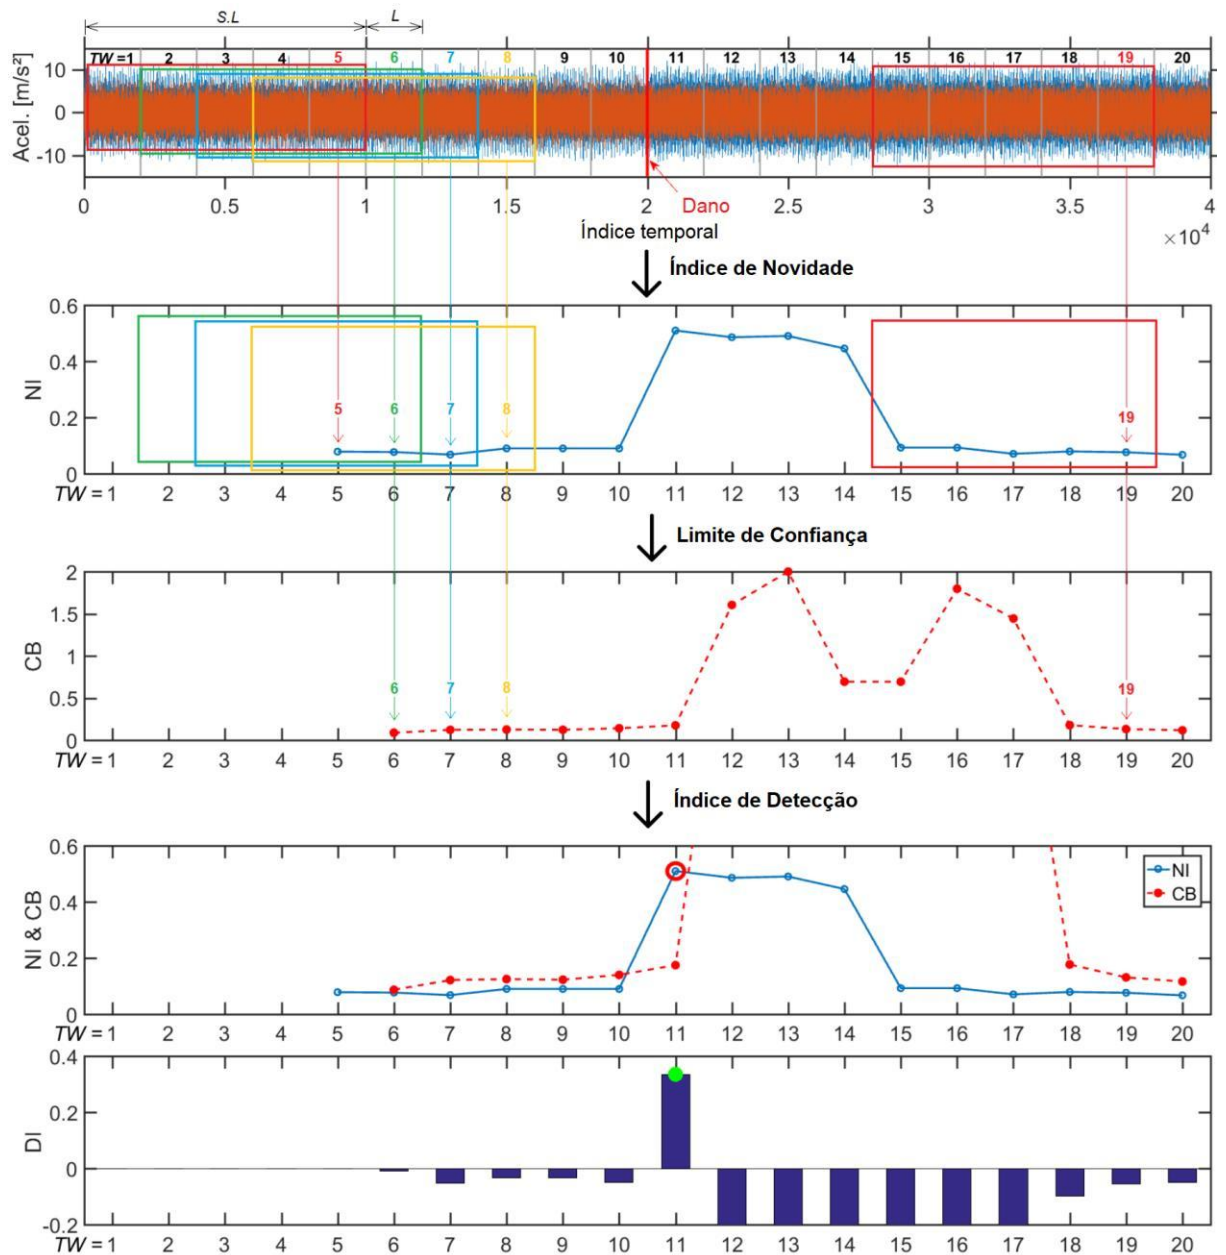
Fluxograma 1 – Metodologia para detecção de alterações baseada em SDOs



Fonte: Elaborada pelo autor (2022).

A Figura 6 ilustra um exemplo numérico da aplicação da metodologia. O sinal mostrado foi alterado a partir da metade, simulando um dano estrutural. O número de SDOs por TW é fixado como $S = 5$, que é uma quantidade razoável, visto que o aumento do valor de S não reflete em uma melhoria da probabilidade de detecção das alterações, além de aumentar o custo computacional. Dessa forma, assim que 5 SDOs são montados, completa-se a primeira TW, de índice 5. Toda vez que mais um comprimento L (em segundos) é adicionado ao sinal, uma nova TW surge. Para cada TW é computado o índice NI (Eq. (6)) e, a partir de dois NIs, calcula-se um valor de CB (Eq. (7)). Por último, calcula-se a diferença entre os índices NI e CB para se obter o Índice de Detecção DI (Eq. (8)).

Figura 6 – Resumo do processo de detecção de novidade



Fonte: Adaptado de: Cardoso *et al.* (2019).

Nota-se que, neste exemplo, a alteração foi detectada corretamente, dado que o valor NI excedeu o valor CB, resultando em um valor DI positivo imediatamente após o dano. Após a TW ter passado pela alteração no sinal (TW = 15 em diante), os valores de NI voltaram aos níveis normais e, a partir de TW = 19 em diante, os valores de CB também retornaram a níveis normais. Isso indica que o sistema se adapta a novos estados estruturais.

3.5 MONITORAMENTO EM PARALELO

Uma das maiores dificuldades na aplicação direta da metodologia descrita até o momento é a escolha ideal do comprimento do SDO. Cardoso, Cury e Barbosa (2019) realizaram uma análise de sensibilidade, na qual foram escolhidos alguns comprimentos de SDOs e foi verificada a adequação do método para detectar alterações estruturais. A conclusão foi: quanto menor o comprimento do objeto (menor valor de L , em segundos), maior a chance de se detectar as alterações estruturais, mas também aumenta a probabilidade de aparecimento de falsos alarmes positivos. Por outro lado, quanto maior for o comprimento do objeto, maior a probabilidade de ocorrência de falsos alarmes negativos, o que vai contra a segurança estrutural. Além disso, a escolha do comprimento do SDO é dificultada por outras variáveis, como aquelas devidas às diferentes frequências de amostragem que cada monitoramento adota, os tipos de estruturas, os pontos de instalação dos sensores, a magnitude dos danos a serem detectados, etc. Portanto, não é possível selecionar um único valor de L que se ajuste bem a todas as estruturas e situações.

Para contornar essa limitação, este trabalho apresenta uma nova proposta que monitora o comportamento estrutural a partir de 11 TWs trabalhando em paralelo, de forma automática. Essa estratégia foi implementada em um *software* denominado ReTiA-SHM (*Real-Time Automated Structural Health Monitoring*, do inglês), desenvolvido pelos autores do presente trabalho.

3.6 FUNCIONAMENTO DA METODOLOGIA ADAPTATIVA

Primeiramente, define-se o tamanho inicial dos SDOs através do vetor V , mostrado na Eq. (9):

$$V = \frac{1000}{sf} \{1,0 \ 1,5 \ 2,0 \ 2,5 \ 3,0 \ 3,5 \ 4,0 \ 4,5 \ 5,0 \ 5,5 \ 6,0\} \quad (9)$$

onde sf é a frequência de amostragem do sinal. A Eq. (9) foi concebida a partir de vários testes realizados em diferentes estruturas e verificou-se ser um bom ponto de partida para os comprimentos dos SDOs.

Os únicos dados de entrada para que a metodologia adaptativa inicie o monitoramento são: *i*) o valor da frequência de amostragem do sinal (sf) e *ii*) o caminho do diretório onde os arquivos de dados serão armazenados. Percebe-se, portanto, que nenhuma informação técnica

adicional é solicitada ao usuário, como a escolha da quantidade e dos comprimentos dos SDOs, por exemplo.

Após a entrada dos dados, são calculados os comprimentos iniciais dos 11 SDOs, de acordo com a Eq. (9). Em seguida, o *software* inicia o monitoramento contínuo. Primeiramente, verifica-se quantos arquivos contendo ensaios dinâmicos existem no diretório. Essa verificação ocorre a cada segundo. Não é necessário nenhum pré-processamento, mas cada arquivo precisa conter apenas uma matriz, na qual cada coluna corresponde a um canal de entrada e, cada linha, a um valor de leitura dinâmica. Então esses arquivos vão sendo processados um a um, com todos os tamanhos de SDOs, calculando-se os valores de DI (Eq. (8)). Assim que novos arquivos são adicionados no diretório, o sistema reconhece e continua o monitoramento, ou seja, o SHM acontece quase em tempo real.

Diz-se que uma detecção de alteração estrutural ocorreu se mais de 50% (maioria) das TWs paralelas apresentarem ao menos um valor DI positivo durante o mesmo ensaio. Com isso, a detecção se torna mais robusta e menos sujeita a alterações pontuais devidas a efeitos ambientais/operacionais.

O percentual de detecção é verificado constantemente. Enquanto este encontra-se abaixo de 50%, o monitoramento prossegue normalmente. Por outro lado, quando uma alteração é encontrada (mais de 50% de detecção), o *software* emite uma mensagem perguntando se a estrutura sofreu algum tipo de alteração ou se foi submetida a alguma ação excepcional externa (terremoto, colisão de veículo, explosão etc.). Nesse momento, é necessária uma intervenção humana para responder essa pergunta. Se a estrutura começou a ser monitorada há pouco tempo, é muito provável que esse alarme seja falso, pelo fato de os comprimentos dos SDOs serem inicialmente pequenos. Por isso, a pessoa/setor responsável pelo monitoramento pode responder que não (a estrutura não sofreu alteração e nem foi submetida a uma ação excepcional). Assim, multiplica-se o comprimento de todos os objetos (vetor V) por 1,2 e continua o monitoramento. Este procedimento é repetido até que os comprimentos dos SDOs atinja um valor compatível com a estrutura-alvo e se adapte às formas comuns de excitação dinâmica presentes. Após esse período de autoadaptação (geralmente curto, durando no máximo alguns dias), o sistema para de soar falsos alarmes positivos e só detecta se alguma alteração de maior intensidade for encontrada no sinal.

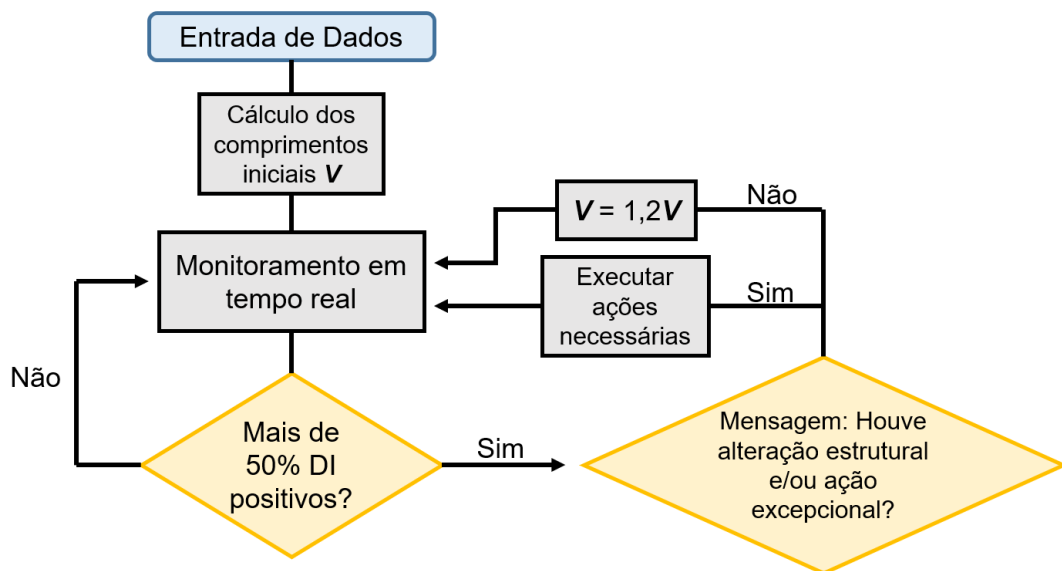
Foi escolhido como padrão o valor 1,2 como fator que aumenta os comprimentos dos SDOs, pois foi verificado que fatores menores (1,1, por exemplo) aumentariam a quantidade de falsos alarmes positivos durante o período de autoadaptação do *software*. Por outro lado,

fatores maiores que 1,2 aumentariam o risco de ocorrerem falsos alarmes negativos, devido a incrementos excessivos dos comprimentos dos SDOs.

Quando ocorre um alarme após o período de autoadaptação, é necessário que a estrutura seja inspecionada para verificar se ela sofreu algum tipo de alteração, danos ou ações excepcionais. Caso esse alarme seja verdadeiro, o monitoramento prossegue sem aumentar o tamanho dos SDOs e as ações necessárias devem ser tomadas para corrigir o problema como, por exemplo, a interdição da estrutura até o seu reparo.

O Fluxograma 2 resume o funcionamento da metodologia adaptativa criada.

Fluxograma 2 – Funcionamento da metodologia adaptativa criada no *software* ReTiA-SHM



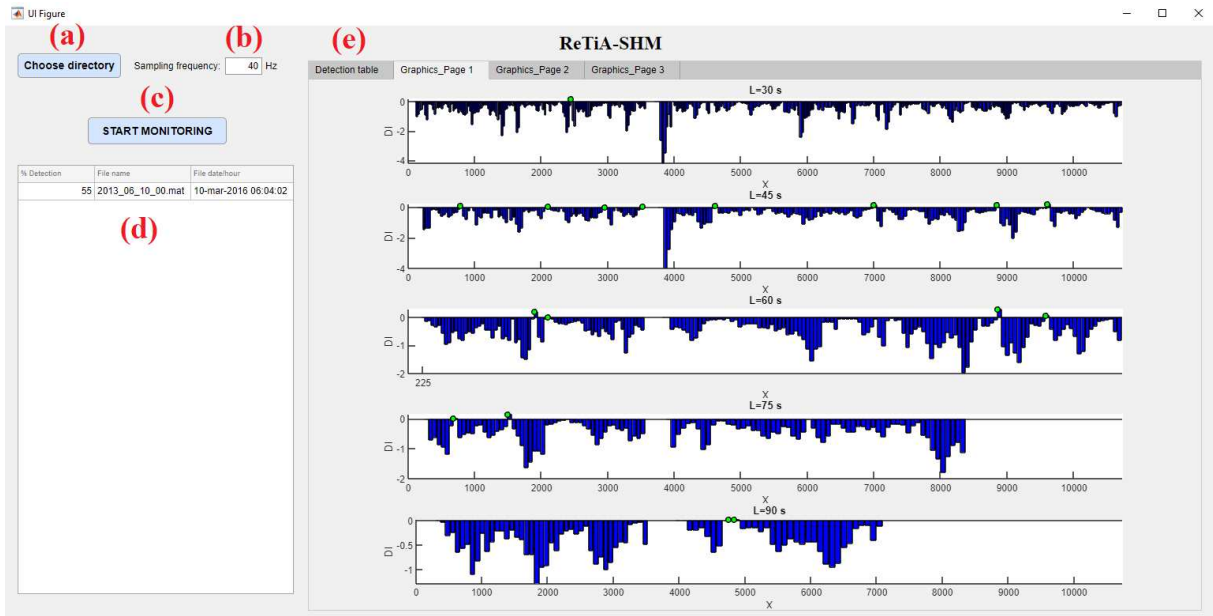
Fonte: Elaborada pelo autor (2022).

3.7 INTERFACE GRÁFICA DO SOFTWARE

O *software* ReTiA-SHM foi totalmente implementado em MATLAB®, e sua interface gráfica foi criada com auxílio da ferramenta *app designer*, do MATLAB®.

A Figura 7 mostra a interface gráfica do software implementado, onde é possível observar: o botão *Choose directory* (Fig. 7a), que abre uma janela para o usuário escolher a pasta na qual serão armazenados os dados dinâmicos da estrutura; um campo *Sampling frequency* (Fig. 7b), onde o usuário deve digitar qual é a frequência de aquisição dos sensores utilizados no momento; o botão *START MONITORING* (Fig. 7c), que inicia o monitoramento de integridade estrutural imediatamente; uma tabela (Fig. 7d) que mostra as informações dos alarmes (percentual de detecção, nome do arquivo, data e hora que o arquivo foi gravado); e uma área maior que contém um painel com 4 abas (Fig. 7e).

Figura 7 – Interface gráfica do *software* ReTiA-SHM



Fonte: Elaborada pelo autor (2022).

Três abas (Fig. 7e) servem para mostrar os 11 gráficos com os índices de detecção (DI) sendo calculados em tempo real, enquanto o sistema processa os dados de entrada. A primeira aba mostra uma tabela (Fig. 8), contendo: o nome dos arquivos carregados; quais monitoramentos (de 1 a 11) apresentaram ao menos um valor de DI positivo durante cada ensaio (marcados com a letra D); e o percentual de detecção de cada ensaio. Quando o percentual de detecção de um ensaio for superior a 50%, considera-se um alarme, e esse ensaio fica salvo na tabela de alarmes (Fig. 7d).

Figura 8 – Interface gráfica: tabela de detecções

The screenshot displays the ReTiA-SHM software interface. On the left, there is a control panel with a 'Choose directory' button, a 'Sampling frequency' input field set to 40 Hz, and a 'START MONITORING' button. Below this is a small table with columns for '% Detection', 'File name', and 'File date:hour', containing one entry: 55 | 2013_06_10_00.mat | 10-mar-2016 06:04:02.

The main area is titled 'ReTiA-SHM' and contains a 'Detection table' with tabs for 'Graphics_Page 1', 'Graphics_Page 2', and 'Graphics_Page 3'. The table has 11 columns (0-10) and 3 rows of data:

% Detection	File name	1	2	3	4	5	6	7	8	9	10	11
55	2013_06_10_00.mat	D	D	D	D		D	D				
18	2013_06_10_01.mat		D			D						
18	2013_06_10_02.mat		D									

Fonte: Elaborada pelo autor (2022).

4 APLICAÇÕES PRÁTICAS

A metodologia proposta foi aplicada a quatro estruturas diferentes: um pórtico metálico no Canadá; uma torre de alvenaria na Itália; uma ponte rodoviária na França e um viaduto ferroviário na França. Cada uma dessas estruturas foi submetida a diferentes alterações estruturais, ações excepcionais ou a danos artificiais. Com isso, o objetivo desta seção é aplicar a metodologia concebida no âmbito do *software* ReTiA-SHM, desenvolvido pelos autores, para monitorar os dados dinâmicos extraídos dessas estruturas e testar se a ferramenta proposta é adequada para detectar mudanças no comportamento das estruturas.

4.1 APLICAÇÃO 1: PÓRTICO METÁLICO

A estrutura em análise é um pórtico metálico (Fig. 27), localizado no laboratório *Earthquake Engineering Research Laboratory* da universidade UBC (*University of British Columbia*), no Canadá. O pórtico foi criado para gerar dados dinâmicos a partir de vibrações ambiente e forçada, considerando diversos estados estruturais.

Figura 27 – Pórtico metálico amarelo




Fonte: Cardoso; Cury; Barbosa (2019).

A estrutura do pórtico é composta principalmente por perfis de aço laminados a quente (W300, tensão de escoamento nominal de 300 MPa), contendo 9 pilares e 64 vigas, sendo 16 vigas para cada um dos 4 pavimentos. Os perfis de aço utilizados foram: B100x9 para os pilares e S75x11 para as vigas. Os pilares foram parafusados a uma base metálica, que foi

presa à uma plataforma de concreto. O pórtico foi construído para representar um modelo de edifício em escala 1:3. A estrutura possui base quadrada, com 2,5 m de lado, e 3,6 m de altura (Fig. 28) (CARDOSO; CURY; BARBOSA, 2019).

Figura 28 – Vista frontal do pórtico com cotas



Fonte: Adaptado de: Dyke *et al.* (2015).

Além dos perfis de aço, o pórtico também foi reforçado por um sistema de contraventamento, que consistiu em conectar os perfis diagonalmente através de duas barras de aço roscáveis, com diâmetro de 12,6 mm. A Figura 29 mostra o detalhe das barras de contraventamento.

Figura 29 – Detalhe do sistema de contraventamento



Fonte: Dyke *et al.* (2003).

Para simular as cargas proveniente dos pavimentos, foram anexadas massas ao pórtico, sendo 4 massas de 1000 kg no 1º, 2º e 3º pavimentos, e 4 massas de 750 kg no 4º pavimento. A Figura 30 mostra o detalhe de uma placa de 1000 kg fixada nas vigas.


Figura 30 – Detalhe da massa fixada nas vigas



Fonte: Dyke *et al.* (2003).

A estrutura foi submetida a uma série de monitoramentos dinâmicos. Como formas de excitação foram utilizados: vibração ambiente (tráfego, vento etc.), ensaios com cargas de impacto e com *shakers*. Foram instalados 15 acelerômetros (sensores FBA e EPI, com frequência de aquisição de 0 a 50 Hz, sensibilidade de 5 V/g) no pórtico, sendo 3 por pavimento, incluindo o térreo. Esses sensores foram instalados em diferentes direções, de tal forma que consigam também detectar modos torcionais. A frequência de aquisição dos acelerômetros foi fixada em 200 Hz, e foi utilizado um filtro passa-baixa de 50 Hz no sinal. Todos os ensaios estão publicamente disponíveis em Dyke *et al.* (2015). A Figura 31 mostra a planta de um pavimento, com a posição de 3 acelerômetros e de 4 placas de massa.

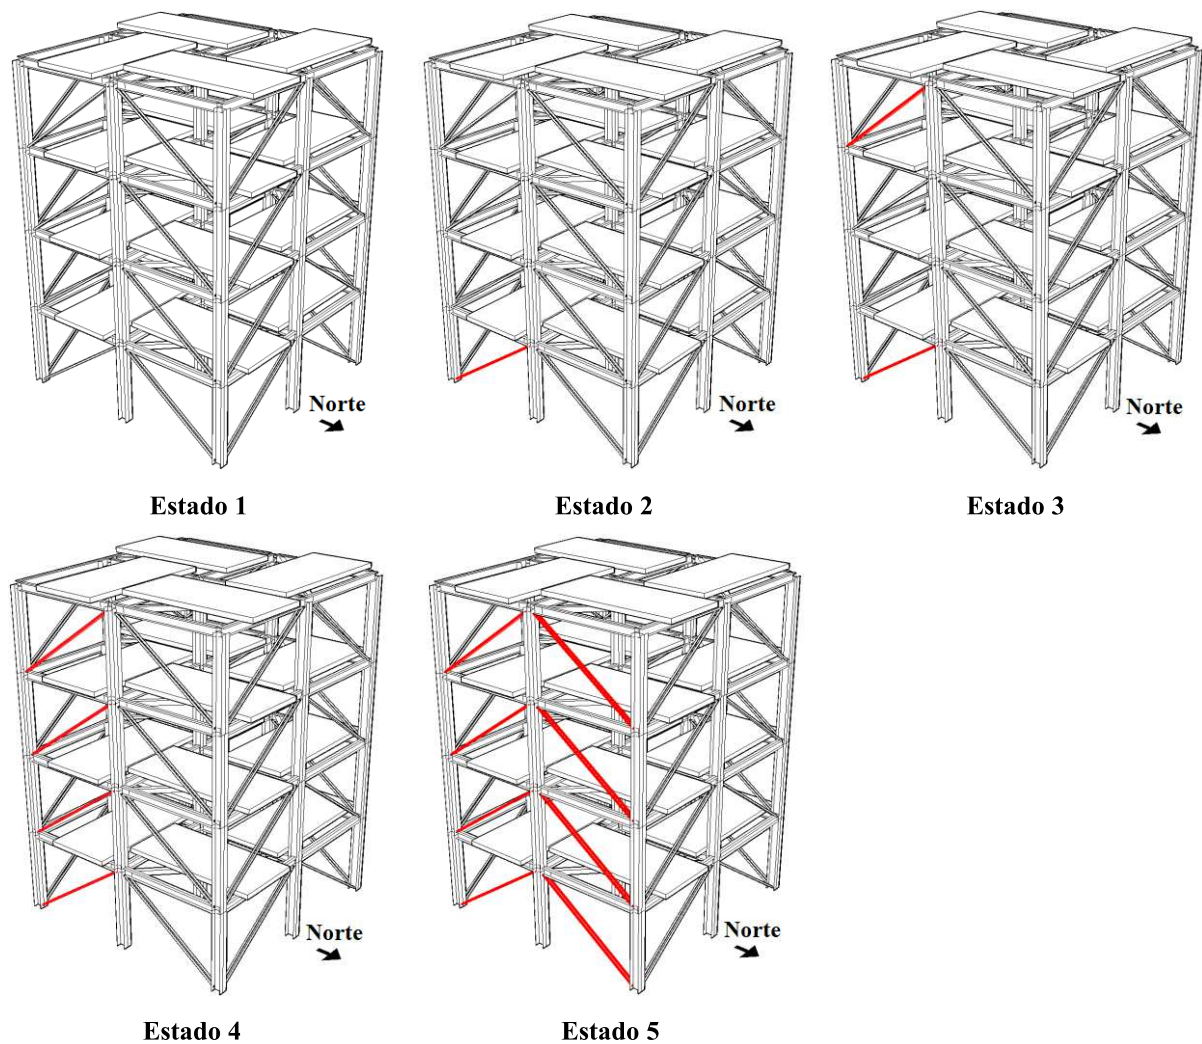
Figura 31 – Planta de um pavimento, instrumentação e massas



Fonte: Adaptado de: Dyke *et al.* (2015).

A estrutura foi submetida a diversos estados estruturais diferentes, que podem ser divididos em dois grupos: com contraventamento e sem contraventamento. Dentro do grupo com contraventamento, foram utilizados os 5 estados estruturais mostrados na Fig. 32. O estado 1 corresponde à estrutura íntegra. Para os estados subsequentes, foram-se removendo as barras de contraventamento da face leste, em etapas, até que todas foram removidas (estado 5). As barras removidas estão marcadas em vermelho. A ordem dos estados estruturais foi modificada para simular um dano crescente. Maiores detalhes sobre o monitoramento, instrumentação e ensaios podem ser encontrados em Dyke *et al.* (2015) e Dyke *et al.* (2003).


Figura 32 – 5 estados estruturais, variações no sistema de contraventamento



Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).

Neste trabalho, foram utilizados apenas os ensaios de vibração ambiente, dado que o objetivo do software é realizar um SHM contínuo, sem depender de formas de excitação forçada. Para cada um dos 5 estados estruturais, foi realizado um ensaio de 5 minutos. A Figura 33 mostra os sinais obtidos pelos 15 acelerômetros.

Figura 33 – Ensaios dos estados estruturais 1 a 5




Fonte: Elaborada pelo autor (2022).


Nota-se que os ensaios relativos aos estados estruturais 1 e 2 apresentaram amplitudes de vibração maiores que os demais. Isso ocorreu porque as formas de excitação ambiente estavam mais intensas durante esses ensaios.

A intenção dessa etapa do trabalho é detectar as alterações de estados estruturais a partir da metodologia de SHM apresentada. Para isso, cada ensaio foi dividido em 10 partes de 30 segundos para serem utilizados como dados de entrada. É importante ressaltar que, em todas as aplicações experimentais deste trabalho, nenhum procedimento de identificação modal ou normalização de dados é realizado previamente. A extração e classificação dos parâmetros são realizadas dentro de cada TW, diretamente dos sinais fornecidos pelos sensores.

A Figura 34 apresenta o resultado final do monitoramento realizado pelo software ReTia-SHM, onde apenas os valores de DI positivos são mostrados. Os valores de DI que foram contados para os alarmes foram marcados com círculos vermelhos e, os demais, foram marcados com círculos verdes. É importante lembrar que um alarme só ocorre quando mais de 50% dos 11 monitoramentos em paralelo apresentam valor de DI positivo durante o mesmo ensaio. Os alarmes também foram marcados por barras tracejadas vermelhas verticais. Os ensaios referentes aos estados estruturais 1 a 5 foram carregados em sequência, para simular um dano gradual crescente.

Figura 34 – Monitoramento do pórtico metálico (estados 1 a 5)



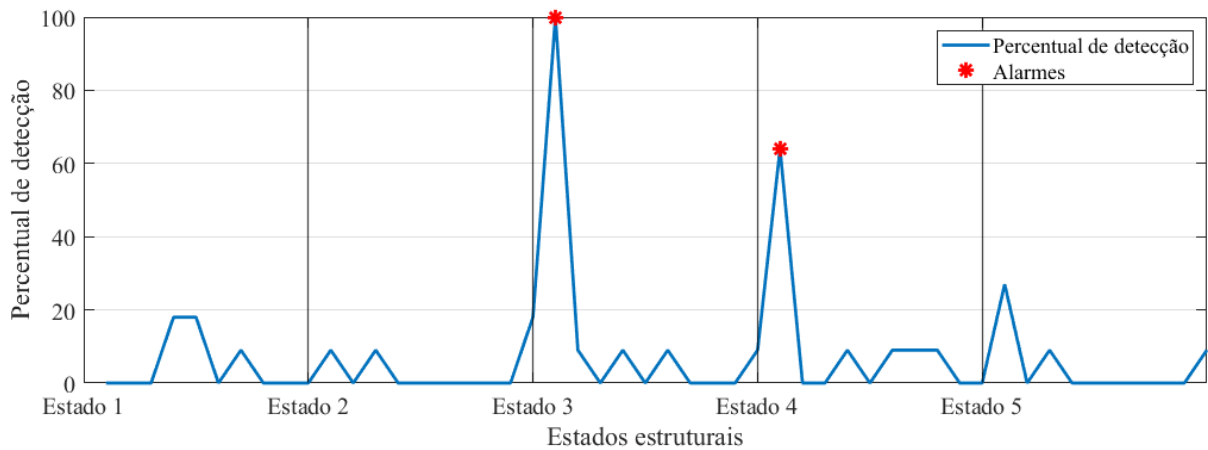


Fonte: Elaborada pelo autor (2022).

Nota-se que foram detectadas duas alterações de estado estrutural (de 2 para 3 e de 3 para 4), cujos percentuais de detecção foram de 100% e 64%. Por não ter ocorrido nenhum falso alarme positivo, o comprimento L dos objetos (calculado pela Eq. (9)) não sofreu

aumento durante o monitoramento. Não foram detectadas duas alterações estruturais (de 1 para 2 e de 4 para 5). A Figura 35 mostra os percentuais de detecção encontrados para cada um dos 50 ensaios.

Figura 35 – Resumo de detecções: pórtico metálico (estados 1 a 5)



Fonte: Elaborada pelo autor (2022).

O mesmo pórtico também foi submetido a ensaios dinâmicos na configuração sem contraventamento (Fig. 36).


Figura 36 – Pórtico sem contraventamento



Fonte: Dyke *et al.* (2003).

Nessa configuração, o modelo foi submetido a três estados estruturais (Fig. 37). O primeiro consiste no pórtico íntegro. Para os demais estados, algumas vigas da face leste (marcadas em vermelho) tiveram seus parafusos de fixação afrouxados (Fig. 38).

Figura 37 – 3 estados estruturais, afrouxamento de parafusos



Fonte: Adaptado de: Cardoso; Cury; Barbosa (2019).


Figura 38 – Detalhe do afrouxamento de parafusos



Fonte: Cardoso; Cury; Barbosa (2019).

Foram registrados 15 minutos de dados em cada estado estrutural. A Figura 39 mostra esses ensaios de vibração ambiente.

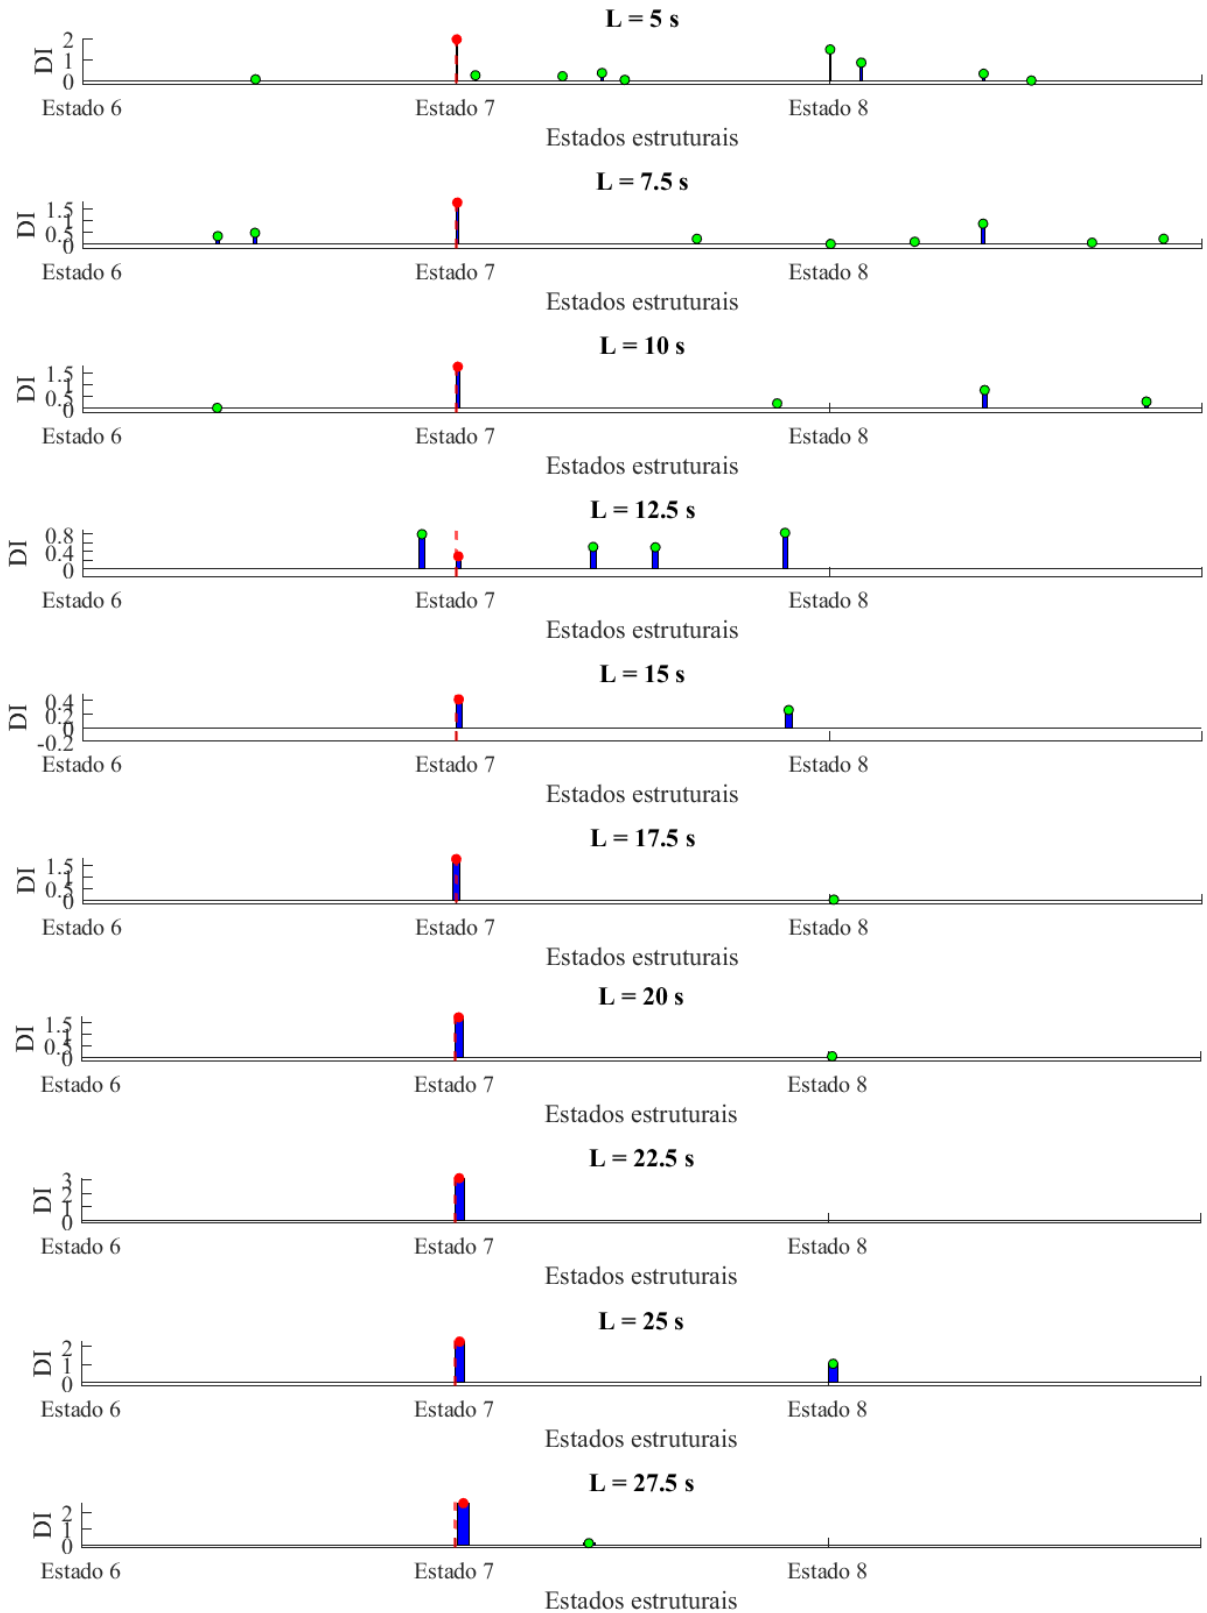
Figura 39 – Ensaios dos estados estruturais 6 a 8




Fonte: Elaborada pelo autor (2022).

Esses sinais também foram divididos em sinais menores de 30 s pelo autor. A Figura 40 mostra o resultado do monitoramento conduzido pelo programa ReTiA-SHM.

Figura 40 – Monitoramento do pórtico metálico (estados 6 a 8)






Fonte: Elaborada pelo autor (2022).

Percebe-se que a primeira alteração estrutural foi detectada por 100% dos monitoramentos em paralelo. Entretanto, a segunda alteração (o afrouxamento de parafusos de mais duas vigas) apresentou um percentual de detecção de 45% (Fig. 41), ou seja, não foi considerado um alarme.

Figura 41 – Resumo de detecções: pórtico metálico (estados 6 a 8)



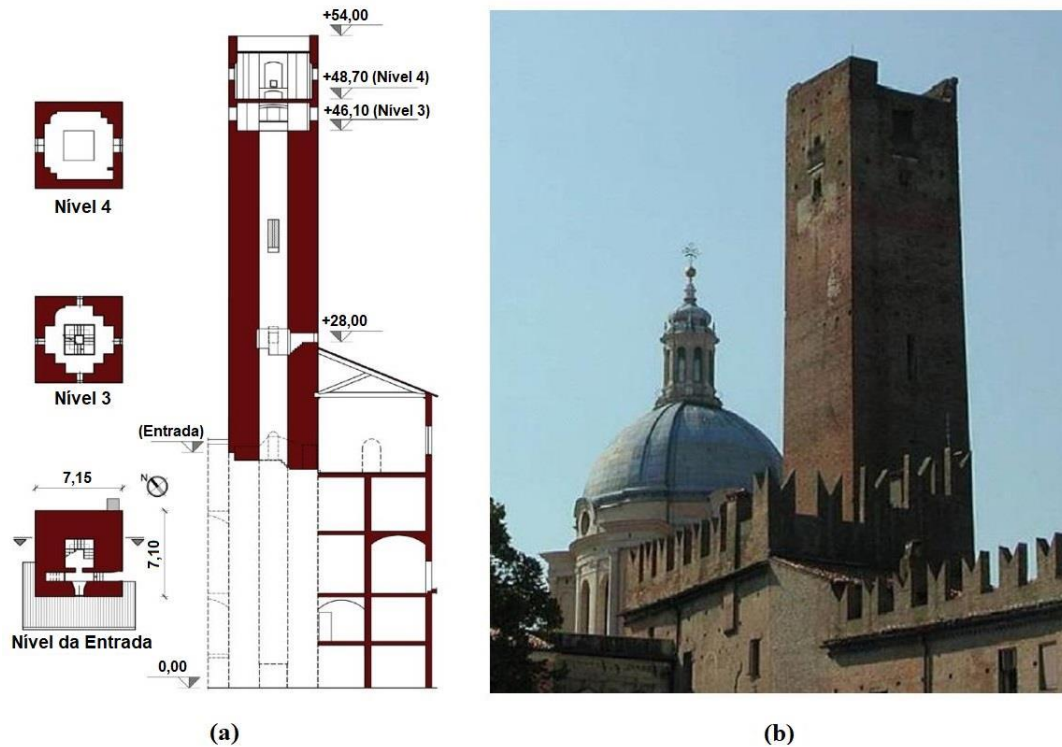
Fonte: Elaborada pelo autor (2022).

Das 6 alterações estruturais graduais apresentadas nesse item, três foram identificadas com precisão, e três não foram identificadas. Portanto, houve três falsos alarmes negativos. Não ocorreu nenhum falso alarme positivo. Esses resultados implicam que o sistema pode não apresentar alta eficiência quando se trata de detectar danos graduais progressivos. Contudo, a eficiência aumenta drasticamente quando ocorrem alterações/danos mais repentinos, e isso pode ser observado ao longo das aplicações seguintes.

4.2 APLICAÇÃO 2: TORRE *GABBIA*

Um SHM contínuo foi implementado para uma torre histórica de alvenaria, denominada torre *Gabbia*, localizada em Mântua, Itália. A torre é a mais alta da região, medindo 54 metros de altura, constituída de blocos maciços de alvenaria, tendo a sua construção concluída no ano de 1227 (SAISI; GUIDOBALDI; GENTILE, 2016). A Figura 9a mostra as dimensões (em metros) da torre em um corte longitudinal e três seções transversais, e a Fig. 9b mostra uma fotografia recente da estrutura.

Figura 9 – Torre *Gabbia*: (a) Corte longitudinal e seções transversais; (b) Fotografia recente




Fonte: Adaptado de: Saisi; Gentile; Guidobaldi (2015).

A torre *Gabbia* foi monitorada a partir de um sistema de monitoramento contínuo utilizando-se três acelerômetros piezoelétricos instalados em sua seção superior. A cada hora foi gravado um novo sinal e, sobre ele, foi aplicado um filtro passa-baixa de 20 Hz. A frequência de aquisição foi reduzida de 200 Hz para 40 Hz (SAISI; GENTILE; GUIDOBALDI, 2015). Cada arquivo consiste em uma matriz de dimensões 143200 x 3, que corresponde à aquisição de 3580s pelos três canais.

Um terremoto ocorreu durante o período de monitoramento da torre, no dia 21 de junho de 2013, entre 12:00 e 13:00. A Figura 10 apresenta o sinal registrado pelos três acelerômetros, no horário em que ocorreu o terremoto.


Figura 10 – Sinal no horário do terremoto



Fonte: Elaborada pelo autor (2022).

Percebe-se um trecho onde ocorreu um aumento súbito na amplitude de aceleração, que foi consequência do terremoto. A Figura 11 mostra uma aproximação desse fenômeno que ocorreu no sinal, que durou pelo menos 200 s.

Figura 11 – Detalhe da alteração no sinal provocada pelo terremoto




Fonte: Elaborada pelo autor (2022).

A metodologia de SHM proposta foi utilizada para tentar detectar este abalo sísmico. Para isso, foram utilizados os sinais dos dias 10 a 30 de junho de 2013. A Figura 12 apresenta o resultado final do monitoramento realizado pelo software ReTia-SHM. A disposição dos alarmes mostra como ocorre o processo de adaptação do sistema às ações dinâmicas comuns presentes na região onde a estrutura se encontra.

Figura 12 – Monitoramento da torre *Gabbia* realizado com o software ReTiA-SHM



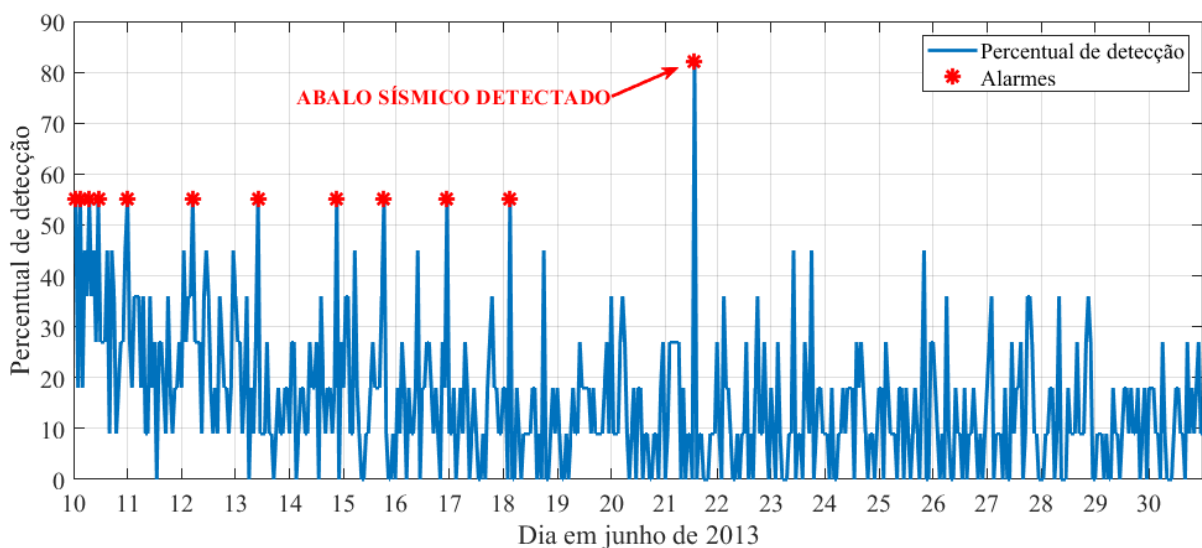


Fonte: Elaborada pelo autor (2022).

Os SDOs iniciaram com comprimentos V (calculados de acordo com a Eq. (9)) e se estabilizaram com comprimentos $(1,2)^{11}V$, pois ocorreram 11 detecções até a estabilização, antes do evento sísmico (11 falsos alarmes positivos). Após esses incrementos, os SDOs alcançaram comprimentos ideais (mostrados na Fig. 12) para detectar com precisão o abalo sísmico e **não disparar nenhum falso alarme durante os dias seguintes**.

A Figura 13 mostra o resumo dos percentuais de detecção encontrados para cada um dos 502 ensaios. Nota-se que todos os alarmes possuíam 55% de detecção (6 de 11), com exceção do alarme que detectou o abalo sísmico, que foi identificado por 82% dos monitoramentos (9 de 11).

Figura 13 – Resumo de detecções referente ao monitoramento da torre *Gabbia*



Fonte: Elaborada pelo autor (2022).

4.3 APLICAÇÃO 3: PONTE PI-57

A ponte denominada PI-57 (Fig. 14) foi construída em 1965 e está localizada próxima à cidade de Senlis, na França. Essa construção contempla o trecho da autoestrada A1 sobre o rio Oise, fazendo conexão entre as cidades de Paris e Lille. A tipologia da estrutura é de concreto moldado no local, com vigas caixão que possuem armadura passiva e armadura pós-tensionada em seu interior. A ponte possui aparência esbelta e elegante, com duas plataformas


e três vãos: o central com 80,50 m de comprimento, e dois laterais com 18,00 m cada, que servem como contrapesos (CURY; CRÉMONA; DUMOULIN, 2012). A Figura 15 mostra uma vista em elevação da ponte, na qual é possível observar melhor os vãos.

Figura 14 – Ponte PI-57 sobre o rio Oise



Fonte: Cardoso *et al.* (2019).

Figura 15 – Vista em elevação da ponte PI-57



Fonte: Adaptado de: Cury; Crémona; Dumoulin (2012).

Durante a elaboração e execução da estrutura, o conhecimento sobre as tensões causadas por variações térmicas era limitado. Além disso, alguns efeitos como retração e fluência não foram suficientemente considerados no projeto. Esses foram os principais motivos que levaram a uma protensão insuficiente. Consequentemente, a estrutura passou por vários problemas durante e após sua construção, resultando em rachaduras localizadas e aumento da deflexão no vão central.

Alguns estudos numéricos foram realizados e concluiu-se que a integridade estrutural poderia ser afetada a longo prazo se medidas corretivas não fossem tomadas imediatamente. Com base nestas avaliações técnicas e considerando a importância da estrutura, a *Société des Autoroutes du Nord et de l'Est de la France* (SANEF), empresa concessionária de autoestradas, decidiu reforçar as duas plataformas. O reforço consistiu na aplicação de uma


protensão longitudinal adicional que corrigiria a falta de protensão suficiente aplicada durante a construção da ponte. Este trabalho foi programado para o verão de 2009.

A partir de cálculos realizados pelo gabinete de projetos da ACOGEC sob a supervisão da empresa de autoestradas SANEF, foi escolhido um perfil reto para os cabos de protensão externos. As ancoragens foram realizadas na parte posterior das vigas transversais localizadas sobre os pilares da ponte. Foram instalados oito cabos 19T15S, que induziram uma força de compressão de cerca de 32000 kN, gerando uma tensão de compressão de pelo menos 6,60 MPa e reduzindo a tensão de tração de 5,10 MPa para 1,50 MPa no meio do vão central. O deslocamento vertical nesse ponto reduziu-se de -2,44 cm para -0,69 cm sob efeitos de carga permanente e acidental (CURY; CRÉMONA; DUMOULIN, 2012).

Para verificar, por um lado, a variabilidade do comportamento estrutural devido aos efeitos térmicos e, por outro, avaliar a eficiência do procedimento de reforço, foi realizado um monitoramento estrutural que consistiu na instalação de acelerômetros e termopares antes e depois do reforço. A primeira campanha de medições ocorreu entre 21 de novembro de 2008 e 3 de abril de 2009. A segunda campanha, após reforço, teve início em 21 de novembro de 2009 e terminou em 3 de abril de 2010. Os ensaios dinâmicos foram realizados sob excitação ambiente (tráfego e vento).

A instrumentação da ponte consistiu em 16 acelerômetros piezoelétricos (Bruel&Kjær 4507B-005 com sensibilidade 1 V/g, faixa de frequência de 0,4 a 6000 Hz, nível operacional máximo $\pm 5g$, faixa de temperatura de -54 a 100°C) e sete sensores de temperatura (Pt100 classe B). Os acelerômetros mediram 16 acelerações verticais e três acelerações longitudinais, de forma a permitir identificar modos de vibração verticais, torcionais e longitudinais. As medições de temperatura foram feitas em sete locais diferentes ao longo de uma seção transversal da plataforma da ponte. A Figura 16 mostra o posicionamento dos sensores ao longo da ponte.

Figura 16 – Instrumentação da ponte PI-57




Fonte: Adaptado de: Cury; Crémona; Dumoulin (2012).

Foram utilizados dois sistemas de aquisição de dados distintos. Para o registro da aceleração, foi utilizado um controlador de dados programável *Gantner* E-PAC DL conectado a uma unidade flash USB de 8 GB. Os dados foram transferidos por um modem TCP/IP. Os módulos de medição *e-bloxx Gantner* A2-1 conectaram os sensores piezoelétricos ao controlador E-PAC DL. Para o registro da temperatura foi utilizado um *data logger Gantner* IDL100 e os dados foram transferidos por um modem GSM.

Para facilitar o processamento e evitar qualquer perda de informação em caso de perda de conexão, os dados foram registrados apenas a cada 3 horas durante um período de 24 horas e armazenados em um disco rígido.

As acelerações foram filtradas na faixa de frequência de 0 a 30 Hz e o período de amostragem foi definido igual a 0,004s (frequência de aquisição de 250 Hz). No presente trabalho, foram utilizados 4 minutos por ensaio, o que corresponde a 60000 pontos de aquisição. Apenas os dados de aceleração foram utilizados neste trabalho. Portanto, cada ensaio consiste em uma matriz de dimensões 60000x19. A Figura 17 mostra um sinal típico de 4 minutos registrado pelos 19 canais de aceleração. Analisando-se o sinal, percebe-se que acontecem vários aumentos de amplitude de aceleração devido à excitação ambiente (tráfego e vento).

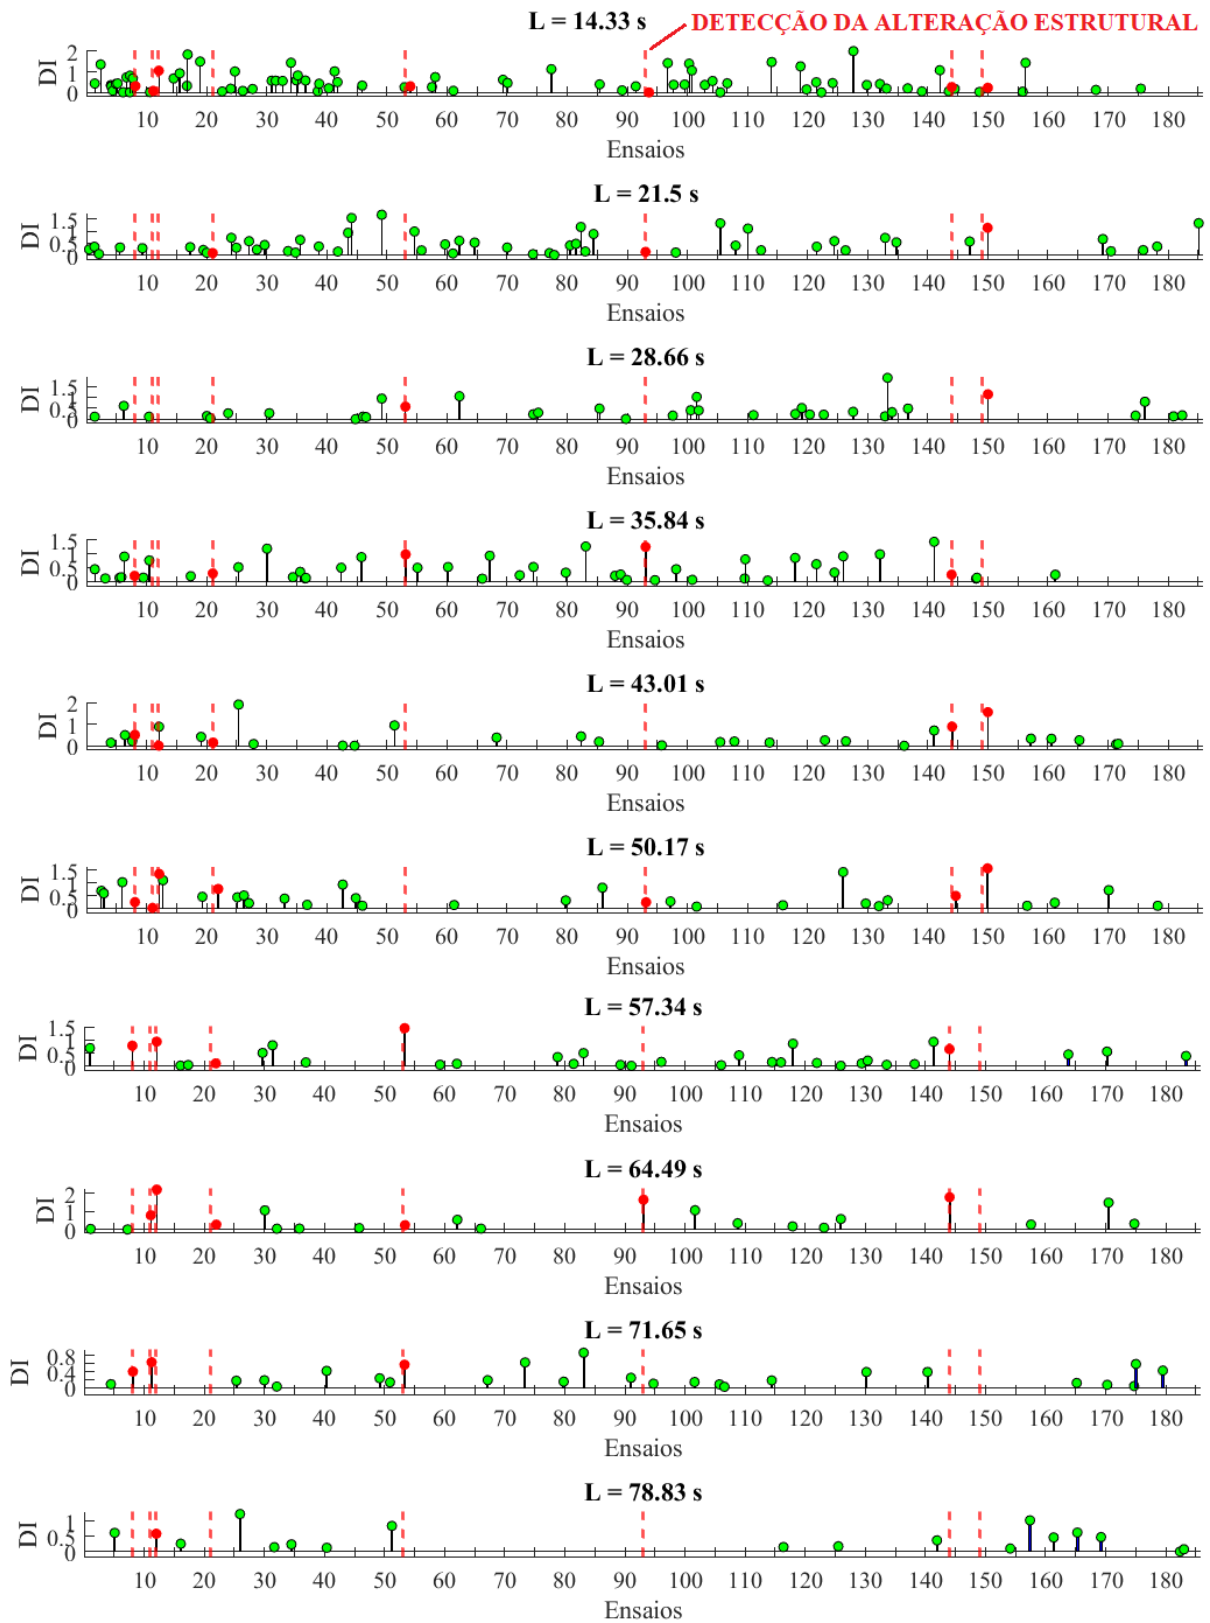
Figura 17 – Ensaio dinâmico típico da ponte PI-57




Fonte: Elaborada pelo autor (2022).

Durante a primeira campanha de ensaios, foram registrados 972 ensaios. A segunda campanha teve um total de 1164 ensaios. Neste trabalho, foram analisados 186 ensaios, sendo 93 antes e 93 depois do reforço. A Figura 18 mostra o resultado do monitoramento realizado pelo *software* ReTiA-SHM.

Figura 18 – Monitoramento da ponte PI-57 realizado com o software ReTiA-SHM

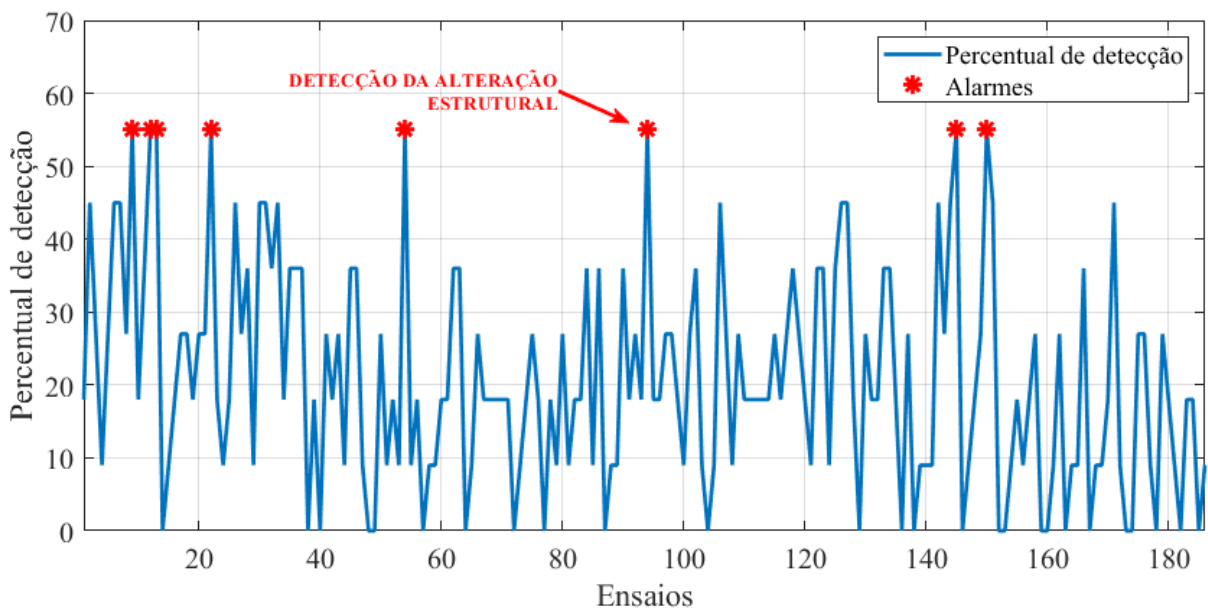




Fonte: Elaborada pelo autor (2022).

Nota-se que houve oito alarmes no total (marcados com barras vermelhas tracejadas). Dentre eles, ocorreram sete falsos alarmes positivos, sendo cinco antes e dois após o reforço. A alteração estrutural foi detectada com precisão (ensaio número 94). A Figura 19 apresenta os percentuais de detecção do monitoramento em estudo. Percebe-se que todos os alarmes ocorreram com apenas 55% de detecção. Isso pode ter ocorrido por consequência das formas de excitação ambiente, do nível de ruído embutido na resposta dinâmica, ou então o reforço não provocou uma mudança tão aguda no sinal.

Figura 19 – Resumo de detecções referente ao monitoramento ponte PI-57



Fonte: Elaborada pelo autor (2022).

4.4 APLICAÇÃO 4: VIADUTO FERROVIÁRIO

O viaduto em análise (Fig. 20) foi construído na década de 80 e sustenta duas vias ferroviárias para TGV (*Trains à Grande Vitesse* – Trens de alta velocidade, do francês), conectando as cidades de Paris e Lyon, na França. Ele está localizado sobre a estrada 939, no ponto quilométrico 075+317. Esta estrada conecta as cidades de Sens e Soucy, no condado de Yonne. O viaduto foi construído com base em uma estrutura mista (aço e concreto) que sustenta um único vão de 17,5 m (ALVES; CURY; CRÉMONA, 2016)

Figura 20 – TGV passando sobre o viaduto



Fonte: Cardoso *et al.* (2019).

As medições anteriormente realizadas pela SNCF (*Société Nationale des Chemins de Fer Français*) revelaram vibrações e deformações excessivas da estrutura por conta de efeitos de ressonância devidos às passagens de trens de alta velocidade (TGV). Por isso, o Departamento de Infraestrutura da SNCF decidiu modificar as condições de apoio da estrutura. O reforço constituiu-se da instalação de estruturas metálicas nos encontros do tabuleiro da ponte com a com a parede de concreto armado (nos apoios), para se aumentar a rigidez à flexão das vigas (Fig. 21) (CURY; CRÉMONA; DIDAY, 2019).

Figura 21 – Detalhe do reforço estrutural



Fonte: Cury; Crémona; Diday (2019).

Para caracterizar e quantificar os efeitos do reforço estrutural, foi realizado um monitoramento dinâmico antes e depois do mesmo, entre os dias 23 e 26 de junho de 2003. Era esperado que o aumento da rigidez estrutural provocasse um acréscimo das frequências

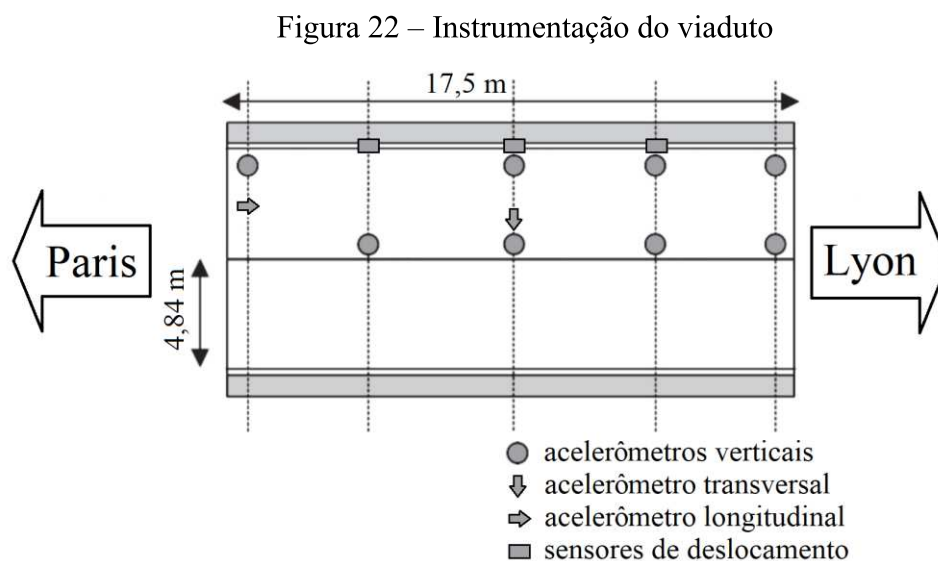
naturais de vibração. Isso era importante para evitar a ressonância entre a primeira frequência natural (cerca de 5,8 Hz) com a fonte de excitação dinâmica, que nesse caso consistia nas passagens de trens (entre 4 e 5 Hz). A Tabela 2 mostra os valores médios e os respectivos desvios-padrão das 4 primeiras frequências naturais da estrutura. Nota-se um aumento das frequências após o reforço estrutural.

Tabela 2 – Frequências naturais de vibração, antes e depois do reforço estrutural

Número da frequência natural	Frequência (Hz)	
	Antes do reforço	Depois do reforço
1	5.848 ± 0.242	6.461 ± 0.267
2	8.507 ± 0.322	8.592 ± 0.415
3	13.017 ± 0.305	13.078 ± 0.296
4	16.850 ± 0.502	17.142 ± 0.507

Fonte: Adaptado de: Alves; Cury; Crémona (2016).


Para que os ensaios dinâmicos fossem eficazes, era importante, entre outros fatores, a definição adequada da quantidade e da localização dos sensores. Ducret, Caron e Boufridi (2003) descrevem detalhadamente a instrumentação e o monitoramento dinâmico realizado na estrutura em estudo. Entre os sensores utilizados estavam inclusos: 8 acelerômetros piezoelétricos na direção vertical e 2 na direção horizontal; 3 sensores de deslocamento fixados no parapeito, medindo o deslocamento vertical relativo entre este e o tabuleiro; 2 sensores de temperatura e 2 sistemas de aquisição *Q.Bridge* sobre os trilhos, que mediam as cargas por eixo na entrada e na saída do viaduto. A Figura 22 mostra a disposição de alguns dos sensores utilizados.



Fonte: Adaptada de: Alves; Cury; Crémona (2016).

A frequência de amostragem dos acelerômetros foi fixada em 4096 Hz. Cada vez que o trem passava pelo viaduto, 2 segundos de vibrações eram registrados. A Figura 23 mostra um sinal típico gerado pelos acelerômetros.


Figura 23 – Ensaio típico de 2 segundos



Fonte: Elaborada pelo autor (2022).

Neste trabalho, são utilizados apenas os dados registrados pelos 8 acelerômetros verticais. Foram utilizados 24 ensaios, 12 antes e 12 após a intervenção estrutural. Logo, os dados de entrada para análise pelo *software* ReTiA-SHM constituem-se em 24 matrizes com 8192 linhas (2 s de 4096 Hz) e 8 colunas (8 canais). A Figura 24 mostra os 24 sinais descritos.

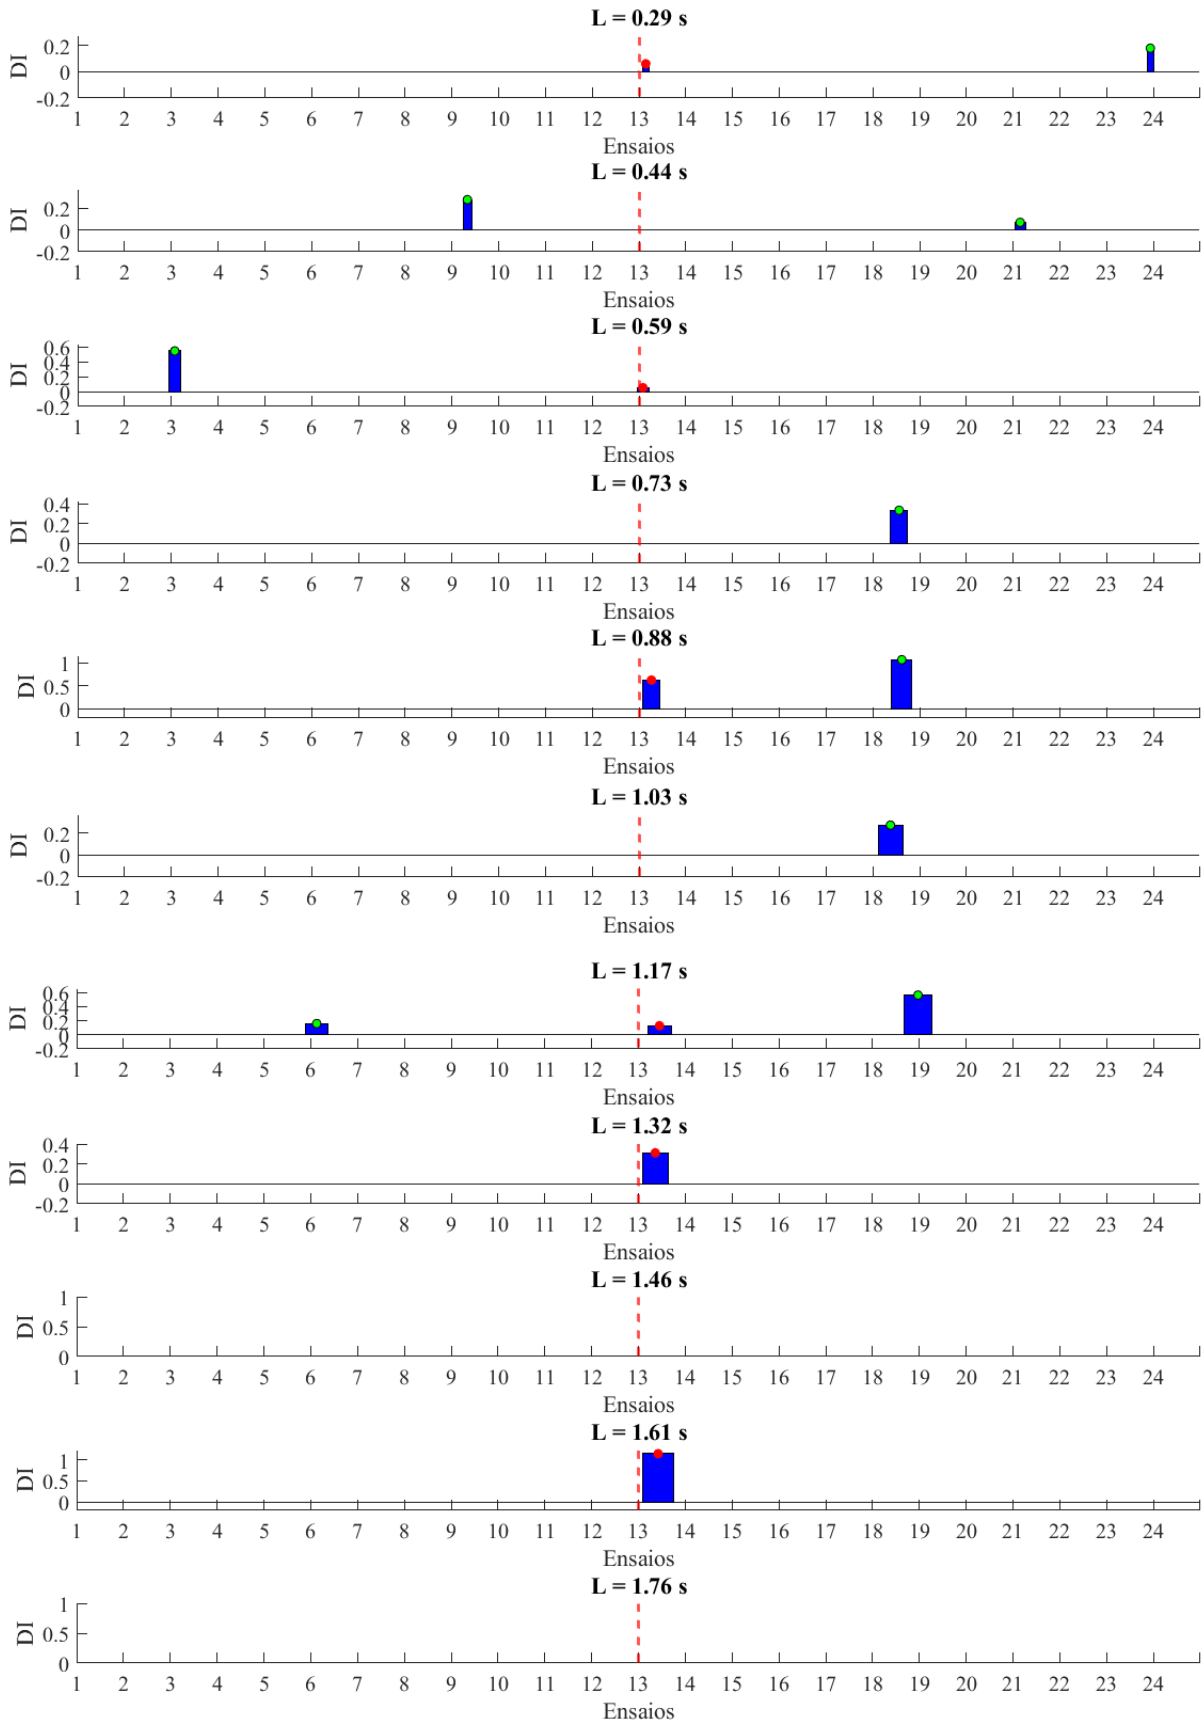
Figura 24 – 24 sinais de aceleração extraídos do viaduto ferroviário



Fonte: Elaborada pelo autor (2022).

Observando o resultado do monitoramento automático do software proposto, mostrado na Fig. 25, nota-se que ocorreu apenas um alarme. Esse único alarme ocorreu no 13º ensaio, que é o primeiro ensaio contendo os dados que expressam o novo comportamento estrutural. Ou seja, a alteração estrutural foi identificada com sucesso.


Figura 25 – Monitoramento do viaduto ferroviário realizado com o *software* ReTiA-SHM



Fonte: Elaborada pelo autor (2022).

Além disso, nenhum outro ensaio teve mais de 50% de taxa de detecção, o que comprova a robustez da ferramenta. O resultado também é mostrado no gráfico de percentuais de detecção (Fig. 26).

Figura 26 – Resumo de detecções referente ao monitoramento do viaduto ferroviário



Fonte: Elaborada pelo autor (2022).

5 CONCLUSÕES

Neste trabalho foi concebida uma metodologia baseada em SDOs desenvolvida no âmbito de um *software* chamado ReTiA-SHM que se mostrou capaz de conduzir monitoramentos de integridade estrutural de forma contínua e automatizada. O programa apresentou uma solução para o problema referente à dificuldade de escolha de comprimentos adequados para os SDOs, visto que são utilizados 11 comprimentos diferentes ao mesmo tempo, e que esses vão aumentando durante um período de autoadaptação. Foram eliminados todos os parâmetros de entrada que não são essenciais para o funcionamento do *software*, tornando-o simples de ser operado, evitando que o usuário-alvo precise inserir mais informações técnicas.

O monitoramento em paralelo torna a metodologia mais robusta, adicionando um carácter probabilístico (mais de 50% das janelas precisam apresentar um valor de DI positivo dentro de um mesmo ensaio). Contudo, existe a condição de haver intervenção humana cada vez que uma novidade é detectada, principalmente quando a detecção ocorre após o período de autoadaptação do *software*.

As aplicações práticas descritas na seção 4 apresentaram vários tipos de alterações estruturais e uma ação excepcional (terremoto) para serem identificadas pelo *software* ReTiA-SHM. Os resultados dos monitoramentos mostraram que foram corretamente detectados: o terremoto que atingiu a torre *Gabbia*, na Itália; os reforços estruturais aplicados na ponte PI-57 e no viaduto ferroviário, ambos na França. Em relação aos danos estruturais graduais impostos sobre o pórtico metálico, no Canadá, três foram detectados e três não foram detectados como alarmes. Esses resultados implicam que o sistema é eficiente para detectar alterações/danos mais repentinas, mas essa eficiência pode diminuir se as alterações forem graduais e progressivas.

A aplicação prática da torre de *Gabbia* mostrou a natureza adaptativa da metodologia de SHM proposta. Após 11 falsos alarmes positivos, o software foi calibrado para detectar apenas alterações de maior intensidade no sinal. Isso foi confirmado pela detecção precisa de um abalo sísmico que atingiu a estrutura em 21 de junho de 2013. Após esta detecção, nenhum alarme falso foi notificado durante os dias seguintes. No caso da ponte PI-57, ainda ocorreram dois falsos alarmes positivos após a detecção da intervenção estrutural.

Foi mostrado que a metodologia proposta pode ser aplicada a estruturas em condições de vibração ambiente. Os efeitos operacionais e ambientais embutidos nas respostas

dinâmicas não impediram que as alterações estruturais/ações excepcionais fossem identificadas pelo *software*.

5.1 TRABALHOS FUTUROS

Sugere-se alguns temas para trabalhos futuros:

- a) Aplicar a metodologia de SHM descrita neste trabalho em ensaios experimentais de outras estruturas, para avaliar sua funcionalidade e acurácia;
- b) Executar o SHM contínuo em uma estrutura com condições ambientais controladas. Adicionar alterações ou danos estruturais artificiais. Verificar quantos alarmes falsos ocorreram durante o período de autoadaptação do *software* e quantas alterações foram detectadas corretamente. Aferir o tempo de atraso entre cada alteração e sua respectiva detecção pelo SHM;
- c) Desenvolver uma estratégia para aprimorar a metodologia de SHM descrita nesse trabalho, tornando-a ainda mais robusta, de tal forma que consiga detectar danos de progressão lenta, ou seja, danos com incrementos pequenos entre os ciclos de medição. Testar esse novo sistema em novas aplicações práticas.
- d) Aplicar diferentes pesos para as duas parcelas que compõem a métrica (Eq. (3)) e verificar o impacto que isso gera no resultado do monitoramento.

REFERÊNCIAS

- ALVANDI, A.; CRÉMONA, C. Assessment of vibration-based damage identification techniques. **Journal of Sound and Vibration**, 292, p. 179–202, 2006.
- ALVES, V.; CURY, A.; CRÉMONA, C. On the use of symbolic vibration data for robust structural health monitoring. **Proceedings of the Institution of Civil Engineers - Structures and Buildings**, v. 169, p. 715-723, 2016.
- ALVES, V.; CURY, A.; ROITMAN, N.; MAGLUTA, C.; CRÉMONA, C. Structural modification assessment using supervised learning methods applied to vibration data. **Engineering Structures**, v.99, p. 439–448, 2015.
- ALVES, V. N. **Técnicas de anormalidade aplicadas à detecção de danos estruturais**. 2016. Tese (Doutorado em Ciências da Engenharia Civil) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2016.
- CACHOT, E.; VAYSSADE, T.; VIRLOGEUX, M.; LANCON, H.; HAJAR, Z.; SERVANT, C. The Millau Viaduct: Ten Years of Structural Monitoring. **Structural Engineering International**, v. 25, n. 4, p. 375-380, 2015.
- CALINSKI, T.; HARABASZ, J. A dendrite method for cluster analysis, **Communications in Statistics**, v. 3, No. 1, p.1–27, 1974.
- CARDOSO, R.; CURY, A.; BARBOSA, F. A robust methodology for modal parameters estimation applied to SHM. **Mechanical Systems and Signal Processing**, 95, p.24–41, 2017.
- CARDOSO, R.; CURY, A.; BARBOSA, F. Automated real-time damage detection strategy using raw dynamic measurements. **Engineering Structures**, v. 196, 2019.
- CARDOSO, R.; CURY, A.; BARBOSA, F.; GENTILE, C. Unsupervised real-time SHM technique based on novelty indexes. **Structural Control Health Monitoring**, v. 26, Issue 7, e2364, 2019.
- CURY, A. A.; CRÉMONA, C. Pattern recognition of structural behaviors based on learning algorithms and symbolic data concepts. **Structural Control and Health Monitoring**, v. 19, n. 2, p. 161-186, 2012.
- CURY, A. A.; CRÉMONA, C.; DIDAY, E. Application of symbolic data analysis for structural modification assessment. **Engineering Structures**. v. 32, p. 762–775, December, 2009.
- CURY, A.; CRÉMONA, C.; DUMOULIN, J.: Long-term monitoring of a PSC box girder bridge: Operational modal analysis, data normalization and structural modification assessment. **Mechanical Systems and Signal Processing**, v. 33, p. 13–37, 2012.
- DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-1, No. 2, p. 224–227, 1979.
- DOEBLING, S. W. *et al.* **Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in Their Vibration Characteristics: A Literature Review**. Los Alamos, USA, 1996.

DUCRET D.; CARON H.; BOUFRIDI N. Programme de Recherche Evaluation Dynamique des Ponts – Instrumentation et Mesures Dynamiques sur le Pont-Rail SNCF du PK 075+317 de la Ligne a Grande Vitesse Paris Sud-Est – Campagne de Mesures no 1, **Rapport SITES R 03 PS 15400**, 2003.

DYKE, S.; AGRAWAL, A. K.; CAICEDO, J. M.; CHRISTENSON, R.; GAVIN, H.; JOHNSON, E.; NAGARAJAIAH, S.; NARASIMHAN, S.; SPENCER, B. **NEES: Database for Structural Control and Monitoring Benchmark Problems**, 2015. Disponível em: < <https://datacenterhub.org/resources/257>>. Acesso em: 02 mar. 2022.

DYKE, S.; BERNAL, D.; BECK, J.; VENTURA, C. Experimental Phase II of the Structural Health Monitoring Benchmark Problem. **In: Proceedings of the 16th ASCE Engineering Mechanics Conference**, 2003.

ENTEZAMI, A.; SARMADI, H.; MARIANI, S. An Unsupervised Learning Approach for Early Damage Detection by Time Series Analysis and Deep Neural Network to Deal with Output-Only (Big) Data. **Engineering Proceedings**, v. 2, n. 17, 2020.

FANG, X.; LUO, H.; TANG, J. Structural Damage Detection Using Neural Network with Learning Rate Improvement. **Computers and Structures**, v. 83, p. 2150-2161, 2005.

FARRAR, C. R.; WORDEN, K. **Structural Health Monitoring: A Machine Learning Perspective**. [S.l.]: John Wiley e Sons, Ltd, 2012.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. de S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, n. 2, e165, 2019.

FINOTTI, R. P.; GENTILE, C.; BARBOSA, F. de S.; CURY, A. A., Structural novelty detection based on sparse autoencoders and control charts. **Structural Engineering and Mechanics**, v. 81, n. 5, p. 647-664, 2022.

GAO, Y.; MOSALAM, K. M.; CHEN, Y.; WANG, W.; CHEN, Y. Auto-Regressive Integrated Moving Average Machine Learning for Damage Identification of Steel Frames. **Applied Sciences**, v.11, 2021.

GLANZ, J.; PIANIGIANI G.; WHITE J; PATANJALI K. Genoa bridge collapse: the road to tragedy. **New York Times**, September 6, 2018. Disponível em: < <https://www.nytimes.com/interactive/2018/09/06/world/europe/genoa-italy-bridge.html>>. Acesso em: 02 mar. 2022.

GOMES, H. M. Redes Neurais Artificiais para Detecção de Danos. **Mecânica Computacional**, v. 23. Bariloche, Argentina, 2004.

JEYASEHAR C. A.; SUMANGALA, K. Damage Assessment of Prestressed Concrete Beams Using Artificial Neural Network (ANN) Approach. **Computers and Structures**, v.84, p. 1709-1718, 2006.

KAUFMAN, L.; ROUSSEEUW, P. J. Finding Groups in Data: An Introduction to Cluster Analysis. Hoboken, **New Jersey: John Wiley & Sons**, Inc, 2009.

KIJEWSKI-CORREA, T.; KWON, D. K.; KAREEM, A.; BENTZ, A.; GUO, Y.; BOBBY, S.; ABDELRAZAQ, A. SmartSync: An Integrated Real-Time Structural Health Monitoring

- and Structural Identification System for Tall Buildings. **Journal of Structural Engineering**, v. 139, p. 1675-1687, 2013.
- LEE, J. W.; YI, J. H.; YUN, C. B.; JUNG, H. Y. Neural networks-based damage detection for bridges considering errors in baseline finite element models. **Journal of Sound and Vibration**, v.280, p. 555-578, 2005.
- LI, F.; MENG, G.; YE, L.; CHEN, P. Wavelet transform-based higher-order statistic for fault diagnosis in rolling element bearings. **Journal of Vibration and Control**, v. 14, n. 11, p. 1691-1709, 2008.
- MEHRJOO, M.; KHAJI, N.; MOHARRAMI, H.; BAHREININEJAD, A. Damage Detection of Truss Bridge Joints Using Artificial Neural Networks. **Expert Systems with Applications**, v. 35, p. 1122-1131, 2008.
- NGUYEN, V. V.; DACKERMANN, U., LI, J.; MAKKI ALAMDARI, M.; MUSTAPHA, S.; RUNCIE, P.; YE, L. Damage Identification of a Concrete Arch Beam Based on Frequency Response Functions and Artificial Neural Networks. **Electronic Journal of Structural Engineering**, 2015.
- NI, Y.; XIA, H.; WONG, K.; KO, J. In-Service Condition Assessment of Bridge Deck Using Long-Term Monitoring Data of Strain Response. **Journal of Bridge Engineering**, v. 17, n. 6, p. 876-885, 2011.
- NUNES, L. A.; FINOTTI, R. P.; BARBOSA; F. de S.; CURY, A. A. A hybrid learning strategy for structural damage detection. **Structural Health Monitoring**, v. 20, n. 4, p. 2143–2160, 2020.
- PARK, S.; LEE, J. J.; YUN, C.B.; INMAN, D. J. Electro-Mechanical Impedance-Based Wireless Structural Health Monitoring Using PCA-Data Compression and k-means Clustering Algorithms. **Journal of Intelligent Material Systems and Structures**, v. 19, n. 4, p. 509–520, 2008.
- ROUSSEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis, **Journal of Computational and Applied Mathematics**, v. 20, No. 1, p. 53–65, 1987.
- ROUSSEUW, P.; CROUX, C. “Alternatives to the Median Absolute Deviaton”, **Journal of the American Statistical Association**, 88(424), p. 1273–1283, 1993.
- RUCKA, W.; WILDE, K. Neuro-Wavelet Damage Detection Technique In Beam, Plate And Shell Structures With Experimental Validation. **Journal of Theoretical and Applied Mechanics**, v. 48, n. 3, p. 579-604, 2010.
- RYTTER, A. **Vibrational based inspection of civil engineering structures**. 1993. Ph.D. Thesis – Denmark: Department of Building Technology and Structural, Aalborg University, Aalborg, 1993.
- SAHIN, M.; SHENOI, R. A. Quantification and localisation of damage in beam-like structures. **Engineering Structures**, v.25, p. 1785-1802, 2003.

- SAISI, A.; GENTILE, C.; GUIDOBALDI, M. Post-earthquake continuous dynamic monitoring of the Gabbia Tower in Mantua, Italy. **Construction and Building Materials**, 81, p. 101–112, 2015.
- SAISI, A.; GUIDOBALDI, M.; GENTILE, C. On Site Investigation and Health Monitoring of a Historic Tower in Mantua, Italy. **Applied Sciences**, 6, 173, 2016.
- SANTOS, J.; CRÉMONA, C.; ORCESI, A.; SILVEIRA P. Early Damage Detection Based on Pattern Recognition and Data Fusion, **Journal of Structural Engineering**, v. 143, Issue 2, 2017.
- SANTOS, J.; ORCESI, A.; CRÉMONA, C.; SILVEIRA, P. Baseline-free real-time assessment of structural changes. **Structure and Infrastructure Engineering: Maintenance, Management, Life-Cycle Design and Performance**, 11(2), p. 145-61, 2015.
- SILVA, S.; DIAS JÚNIOR, M; LOPES JUNIOR; V. Damage Detection in a Benchmark Structure Using AR-ARX Models and Statistical Pattern Recognition. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 29, n. 2, p. 174-184, 2007.
- SOARES, D. de A. C.; CURY, A. A. Avaliação dos Efeitos da Variação de Temperatura e Dano Sobre Frequências Naturais de uma Viga Metálica. *In*: SIMPÓSIO DE MECÂNICA COMPUTACIONAL, 13.; SIMPÓSIO DE MECÂNICA COMPUTACIONAL, 13., 2018, Vitória. **Anais eletrônicos...** Vitória: UFES, 2018. Disponível em: <<https://doity.com.br/anais/xiiisimmec2018/trabalho/68451>>. Acesso em: 10 jan. 2022.
- TIBSHIRANI, R.; WALTHER, G.; HASTIE, T. Estimating the number of clusters in a data set via the gap statistic, **Journal of the Royal Statistical Society: Series B**, v. 63, Part 2, p. 411–423, 2001.
- TORRES, A. S.; ALVES, V. N.; CURY, A. A.; BARBOSA, F. S. Advanced Statistical Techniques Applied to Raw Data for Structural Damage Detection. **Experimental Vibration Analysis for Civil Structures**, v.5, p. 94-103, 2018.
- XU, YOU-LIN; XIA, YONG. **Structural Health Monitoring of Long-Span Suspension Bridges**. Taylor e Francis Group, 2012.
- YU, L.; ZHUL, J.; YU, L. Structural Damage Detection in a Truss Bridge Model Using Fuzzy Clustering and Measured FRF Data Reduced by Principal Component Projection. **Advances in Structural Engineering**, v. 16, n. 1, p. 207-217, 2013.
- ZANG, C.; FRISWELL, M. I.; IMREGUN, M. Structural Damage Detection using Independent Component Analysis. **Structural Health Monitoring**, v. 3, n. 1, p. 69-83, 2004.
- ZHOU, Y.; MAIA, N. M.; SAMPAIO, R. P. C.; WAHAB, M. A. Structural damage detection using transmissibility together with hierarchical clustering analysis and similarity measure. **Structural Health Monitoring**, v.16, p. 711-731, 2016.
- ZHOU, H. F.; NI, Y. Q.; KO, J. M. Structural damage alarming using auto-associative neural network technique: Exploration of environment-tolerant capacity and setup of alarming threshold. **Mechanical Systems and Signal Processing**, v. 25, p. 1508–1526, 2011.