

Universidade Federal do Rio Grande do Sul
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Civil

**Detecção, Localização e Quantificação de Dano em Estruturas via
Algoritmos Metaheurísticos e Redes Neurais Artificiais**

Daniele Kautz Monteiro

Porto Alegre
2023

DANIELE KAUCTZ MONTEIRO

**DETECÇÃO, LOCALIZAÇÃO E QUANTIFICAÇÃO DE
DANO EM ESTRUTURAS VIA ALGORITMOS
METAHEURÍSTICOS E REDES NEURAS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação
em Engenharia Civil da Universidade Federal do Rio
Grande do Sul, como parte dos requisitos para obtenção
do título de Mestre em Engenharia.

Porto Alegre
2023

CIP - Catalogação na Publicação

Monteiro, Daniele Kautz
Detecção, Localização e Quantificação de Dano em
Estruturas via Algoritmos Metaheurísticos e Redes
Neurais Artificiais / Daniele Kautz Monteiro. --
2023.
108 f.
Orientadora: Letícia Fleck Fadel Miguel.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Escola de Engenharia, Programa de
Pós-Graduação em Engenharia Civil, Porto Alegre,
BR-RS, 2023.

1. Identificação Estocástica de Sistemas. 2.
Análise Modal Operacional. 3. Monitoramento da
Integridade Estrutural. 4. Detecção de Dano. I.
Miguel, Letícia Fleck Fadel, orient. II. Título.

DANIELE KAUCTZ MONTEIRO

**DETECÇÃO, LOCALIZAÇÃO E QUANTIFICAÇÃO DE
DANO EM ESTRUTURAS VIA ALGORITMOS
METAHEURÍSTICOS E REDES NEURAS ARTIFICIAIS**

Esta dissertação de mestrado foi julgada adequada para a obtenção do título de MESTRE EM ENGENHARIA, Estruturas, e aprovada em sua forma final pelo professor orientador e pelo Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Rio Grande do Sul.

Porto Alegre, 8 de março de 2023

Profa. Letícia Fleck Fadel Miguel (PPGEC e PROMEC/UFRGS)
Dra. pela Universidade Federal do Rio Grande do Sul
Orientadora

Prof. Lucas Festugato
Coordenador do PPGEC/UFRGS

BANCA EXAMINADORA

Profa. Marta Graciela Amani (UNCUYO)
Dra. pela Universidad Nacional de Tucumán, Argentina

Prof. Tiago Becker (UFRGS)
Dr. pela Universidade Federal do Rio Grande do Sul, Brasil

Prof. Mauro de Vasconcellos Real (FURG)
Dr. pela Universidade Federal do Rio Grande do Sul, Brasil

AGRADECIMENTOS

Gostaria de agradecer a Deus pelas bênçãos na jornada, além de deixar os meus agradecimentos a todas as pessoas que foram importantes de alguma forma nesse trabalho.

À minha professora e orientadora Letícia, principalmente pela paciência com minhas dúvidas.

À minha família, por todo o suporte incondicional durante os últimos anos.

Aos meus amigos Lucas e Marcos, por fazerem me sentir em um trio de ouro.

Aos meus amigos Igor, Sarah e Yasmim, por me darem suporte apesar de toda distância.

Aos meus colegas Gustavo, Daniel e Felipe, por me socorrerem em várias etapas do trabalho.

Aos meus colegas do CEMACOM, Augusto, Cássio, Luciene e Mateus, por me ajudarem a resolver obstáculos do dia a dia.

Ao meu colega de orientação Patrick, por todas as reuniões e desabafos.

Aos engenheiros Giovanni e Rodrigo, por me auxiliarem na parte experimental.

Ao professor Tiago, por tirar inúmeras dúvidas sobre equipamentos e sensores.

À Universidade Católica de Leuven e aos seus professores, pelos dados e informações concedidas referente à Ponte Z24.

À CAPES, pela bolsa concedida.

E a todos aqueles que torceram por mim.

Se deixou levar por sua convicção de que os seres humanos não nascem para sempre no dia em que as suas mães os dão à luz, e sim que a vida os obriga outra vez e muitas vezes a parirem-se a si mesmos.

Gabriel Garcia Marquez

RESUMO

MONTEIRO, D. K. **Detecção, Localização e Quantificação de Dano em Estruturas via Algoritmos Metaheurísticos e Redes Neurais Artificiais**. 2023. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio grande do Sul, Porto Alegre.

Métodos de detecção de dano baseados nas propriedades dinâmicas de estruturas estão ganhando mais espaço na engenharia civil, principalmente devido à difusão do Monitoramento de Integridade Estrutural (*Structural Health Monitoring* – SHM). O acompanhamento contínuo pela utilização de sensores, como acelerômetros, em grandes obras civis vem se tornando comum, permitindo o diagnóstico ágil de estruturas. A partir dos dados obtidos nas medições, ocorre a identificação de sistemas para a determinação dos parâmetros modais (frequências naturais, modos de vibração e razões de amortecimento). Essas propriedades podem ser comparadas com as calculadas (ou medidas) no estado íntegro da estrutura por diversos critérios. Dessa forma, esse trabalho busca aplicar e comparar metodologias de identificação, localização e quantificação de dano em estruturas utilizando os parâmetros modais identificados a partir das respostas às excitações ambientais. Para determinação das propriedades dinâmicas, foi adotado o Método de Identificação Estocástica de Subespaços baseado nas séries temporais (*Data-driven Stochastic Subspace Identification* – SSI-DATA). Dois métodos de detecção de dano foram analisados: o método de detecção de dano baseado na atualização de matrizes com auxílio do Algoritmo de Otimização da Baleia (*Whale Optimization Algorithm* – WOA) e o método baseado em Redes Neurais Artificiais (*Artificial Neural Networks* – ANN). Inicialmente, analisaram-se três estruturas através de simulações de ensaios experimentais, sendo elas: uma viga em balanço, uma treliça de 10 barras e uma passarela de pedestres de treliça Warren (39 metros de comprimento). Em seguida, os métodos foram avaliados em um sistema experimental e na Ponte Z24 (Suíça). As simulações numéricas mostram que ambas as metodologias são promissoras para identificação, localização e quantificação de cenários de dano simples e múltiplos, mesmo com a presença de ruídos e imprecisões nos sinais de aceleração. O desempenho do método com base na atualização de matrizes utilizando o WOA foi mais preciso que outras técnicas usadas anteriormente na literatura. Além disso, o estudo da Ponte Z24 confirmou que ambos os métodos de detecção de dano são capazes de localizar dano em estruturas civis utilizando apenas as frequências naturais como dado de entrada.

Palavras-chave: *identificação estocástica de sistemas; análise modal operacional; monitoramento da integridade estrutural; detecção de dano.*

ABSTRACT

MONTEIRO, D. K. **Detection, Localization, and Quantification of Damage in Structures via Metaheuristic Algorithms and Artificial Neural Networks.** 2023. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre.

Damage detection methods based on the structures' dynamic properties are gaining more space in civil engineering, mainly due to the diffusion of Structural Health Monitoring (SHM). Continuous surveillance using sensors, such as accelerometers, in large civil works has become common, allowing an agile diagnosis of structures. From the data obtained in the sensing measurements, the system identification occurs to determine the modal parameters (natural frequencies, mode shapes, and damping ratios). These properties can be compared with those calculated (or measured) in the healthy state of the structure by several criteria. Thus, this work seeks to apply and compare methodologies for identifying, locating, and quantifying damage in structures using the modal parameters identified from the responses to environmental excitations. To determine the dynamic properties, the Data-driven Stochastic Subspace Identification (SSI-DATA) method was adopted. Two damage detection methods were assessed: the method based on matrix updating with the aid of the Whale Optimization Algorithm (WOA), and the method based on Artificial Neural Networks (ANN). Initially, three structures have been numerically analyzed, namely: a cantilevered beam, a 10-bar truss, and a Warren truss footbridge (39 meters in length). Afterward, the methods were evaluated in an experimental system and on the Z24 Bridge (Switzerland). The numerical simulations shown that both methodologies are promising for identifying, locating, and quantifying single and multiple damage scenarios, even with the presence of noise and inaccuracies in the acceleration signals. The performance of the matrix updating method using the WOA was more accurate than previous techniques available in the literature. In addition, the Z24 Bridge study confirmed that both damage detection methods are capable of localizing damage to civil structures using only natural frequencies as input.

Keywords: *stochastic system identification; operational modal analysis; structural health monitoring; damage detection.*

LISTA DE FIGURAS

Figura 1.1 – Exemplos de sensores de SHM	20
Figura 2.1 – Relação excitação-resposta de um sistema estrutural	24
Figura 2.2 – Linha do tempo dos Métodos de Identificação de Sistemas	27
Figura 4.1 – Exemplo de Diagrama de Estabilização.....	53
Figura 5.1 – Metodologia do Monitoramento de Integridade Estrutural.....	54
Figura 5.2 – Comportamento das baleias jubarte em redes de bolhas.....	56
Figura 5.3 – Pseudocódigo do Algoritmo de Otimização da Baleia	58
Figura 5.4 – Modelo de um neurônio artificial.....	59
Figura 5.5 – Exemplos de funções de ativação	60
Figura 5.6 – Exemplo de arquitetura de uma rede neural.....	60
Figura 6.1 – Metodologia da simulação numérica de ensaios experimentais	64
Figura 6.2 – Viga modelada com 25 elementos	64
Figura 6.3 – WOA (viga com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3	66
Figura 6.4 – WOA (viga com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3	67
Figura 6.5 – Arquitetura da rede neural proposta para a viga	68
Figura 6.6 – ANN (viga com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3	68
Figura 6.7 – ANN (viga com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3	69
Figura 6.8 – Treliça de 10 barras	70
Figura 6.9 – WOA: treliça	71
Figura 6.10 – Arquitetura da rede neural proposta para a treliça	72
Figura 6.11 – ANN: treliça.....	72
Figura 6.12 – Passarela de pedestres de treliça Warren	73
Figura 6.13 – Diagrama de estabilização da passarela no cenário íntegro (3% de ruído).....	74
Figura 6.14 – WOA (passarela com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4, (e) cenário 5.....	76
Figura 6.15 – WOA (passarela com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4, (e) cenário 5.....	77
Figura 6.16 – Valores preditos pela ANN para a passarela de pedestres	78
Figura 7.1 – Metodologia dos ensaios experimentais	79
Figura 7.2 – Régua de aço	80
Figura 7.3 – Régua experimental e sistema de aquisição	80
Figura 7.4 – Acelerograma no nó 29 (condição íntegra).....	81

Figura 7.5 – Diagrama de estabilização da régua no cenário íntegro.....	81
Figura 7.6 – Formas modais numéricas e experimentais: (a) modo 1, (b) modo 2, (c) modo 3, (d) modo 4, (e) modo 5.....	83
Figura 7.7 – MAC das formas modais experimentais e numéricas no cenário íntegro.....	83
Figura 7.8 – WOA (régua): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4.....	85
Figura 7.9 – Arquitetura da rede neural proposta para a régua.....	86
Figura 7.10 – ANN (régua): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4.....	86
Figura 8.1 – Metodologia da aplicação dos métodos em estrutura real.....	88
Figura 8.2 – Visão geral da Ponte Z24.....	89
Figura 8.3 – Seção transversal da Ponte Z24.....	89
Figura 8.4 – Rachaduras na viga da Ponte Z24 após recalque de fundação.....	90
Figura 8.5 – Exemplo de sinal de aceleração (PDT-06).....	91
Figura 8.6 – Posição dos acelerômetros e sensores de referência.....	92
Figura 8.7 – Modelo FE da Ponte Z24.....	93
Figura 8.8 – Valores iniciais e atualizados da rigidez à flexão e rigidez à torção.....	94
Figura 8.9 – Regiões da Ponte Z24 para análise de dano.....	95
Figura 8.10 – WOA: Ponte Z24.....	95
Figura 8.11 – Arquitetura da rede neural proposta para a Ponte Z24.....	96
Figura 8.12 – ANN: Ponte Z24.....	96

LISTA DE TABELAS

Tabela 5.1 – Parâmetros utilizados no treinamento das ANN.....	62
Tabela 6.1 – Frequências naturais do modelo FE da viga	65
Tabela 6.2 – Frequências naturais identificadas na viga	65
Tabela 6.3 – Situação de dano estimada para a viga	70
Tabela 6.4 – Frequências naturais da treliça.....	71
Tabela 6.5 – Situação de dano estimada para a treliça	72
Tabela 6.6 – Área das seções transversais das barras.....	73
Tabela 6.7 – Frequências naturais do modelo FE da passarela	74
Tabela 6.8 – Frequências naturais identificadas na passarela considerando 3% de ruído.....	75
Tabela 6.9 – Frequências naturais identificadas na passarela considerando 5% de ruído.....	75
Tabela 6.10 – Situação de dano estimada para a passarela	78
Tabela 7.1 – Propriedades dos acelerômetros utilizados	80
Tabela 7.2 – Frequências naturais da régua no cenário íntegro.....	82
Tabela 7.3 – Frequências naturais da régua identificadas nos cenários danificados	84
Tabela 8.1 – Cenários de dano da Ponte Z24	90
Tabela 8.2 – Frequências naturais da ponte identificadas no cenário íntegro	91
Tabela 8.3 – Frequências naturais da ponte identificadas no cenário danificado.....	91
Tabela 8.4 – Frequências naturais experimentais e do modelo numérico	94
Tabela 8.5 – Situação de dano estimada para a Ponte Z24.....	97

LISTA DE SÍMBOLOS

LETRAS ROMANAS MAÍUSCULAS

\mathbf{A} – matriz de estado no tempo discreto

\vec{A}, \vec{C} – vetor de coeficiente WOA

\mathbf{A}_c – matriz de estado no tempo contínuo

\mathbf{B} – matriz de entradas no tempo discreto

\mathbf{B}_2 – matriz de distribuição dos atuadores

\mathbf{B}_c – matriz de entradas no tempo contínuo

\mathbf{B}_m – matriz modal de entradas

\mathbf{C} – matriz de saídas no tempo discreto

\mathbf{C}_2 – matriz de amortecimento

\mathbf{C}_a – matriz de localização das saídas de aceleração

\mathbf{C}_c – matriz de saídas no tempo contínuo

\mathbf{C}_d – matriz de localização das saídas de deslocamento

\mathbf{C}_m – matriz modal de saídas

\mathbf{C}_v – matriz de localização das saídas de velocidade

\mathbf{D} – matriz de transmissão direta no tempo discreto

\mathbf{D}_c – matriz de transmissão direta no tempo contínuo

\mathbf{G} – matriz de covariâncias do estado no instante $k+1$

\mathbf{H}^{ref} – matriz Hankel

\mathbf{I}_r – matriz identidade

\mathbf{K} – matriz de rigidez

K – componente da matriz de rigidez

\mathbf{K}_{k-1} – matriz de ganho do filtro Kalman

\mathbf{L} – matriz de seleção das referências

\mathbf{M} – matriz de massa

N_e – número de elementos da estrutura

N_m – número de modos analisados

Nn – número de deslocamentos nodais

\mathbf{O}_i – matriz de observabilidade estendida

\mathbf{P}_i^{ref} – matriz de projeção do espaço

\mathbf{P}_k – matriz de covariância de estado

$\mathbf{Q}, \mathbf{R}, \mathbf{S}$ – matrizes de covariância do ruído

\mathbf{R}_i – matriz de covariância das respostas

S_i – conjunto de entradas de um neurônio

S_j – saída de um neurônio

$\hat{\mathbf{X}}_i$ – matriz da sequência de estado do filtro Kalman

\vec{X}^* – vetor de posição da melhor solução obtida

\vec{X} – vetor de posição

\vec{X}_{rand} – vetor de posição aleatória

\mathbf{V} – matriz de formas modais observáveis

$\mathbf{W}_1, \mathbf{W}_2$ – matrizes de peso das variantes do SSI-DATA

$\mathbf{Y}_{0i-1}^{ref}, \mathbf{Y}_p^{ref}$ – matriz de saídas passadas

$\mathbf{Y}_{i|2i-1}, \mathbf{Y}_f$ – matriz de saídas futuras

LETRAS ROMANAS MINÚSCULAS

\vec{a} – vetor de coeficientes WOA

f – função de ativação da rede neural

$f^{(n)}$ – frequência natural n

$\vec{f}(t)$ – vetor de forças

i – número de atrasos no tempo

j – unidade imaginária

k – instante de tempo

\mathbf{k}_j – matriz de rigidez elementar

l – número de saídas

n – número de graus de liberdade do sistema

n_2 – número de ordem no espaço de estado, número de estados

n_{\max} – número de ordem máxima do modelo

p – instante no tempo

q – instante no tempo

\vec{r} – vetor aleatório em $[0,1]$

r – número de saídas de referência

s – número de amostras no tempo

t – tempo

$\vec{u}(t)$ – vetor de deslocamento

$\vec{\dot{u}}(t)$ – vetor de velocidade

$\vec{\ddot{u}}(t)$ – vetor de aceleração

$\vec{x}(t)$ – vetor de estado

\vec{x}_k – vetor de estado no instante k

$\hat{\vec{x}}_k$ – vetor de estado estimado no instante k

$\vec{x}_m(t)$ – vetor de estado expresso em termos das coordenadas modais

$\vec{v}(t)$ – vetor de excitação

\vec{v}_k – vetor de excitação no instante k

\vec{w}_k – vetor de perturbações e imprecisões do modelo dinâmico no instante k

\vec{y}_k – vetor de medição nas saídas no instante k

$\vec{y}(t)$ – vetor de saídas

\vec{z}_k – vetor de ruído de medição devido a imprecisão do sistema de aquisição

LETRAS GREGAS

α – constante escalar

α_j – coeficiente de redução de rigidez

β – constante escalar

Δt – taxa de amostragem

δ_{pq} – delta de Kronecker

$\delta\psi_{kj}$ – variação fracionária da forma modal

$\delta\omega_j$ – variação fracionária da frequência natural

Θ – matriz de autovetores do sistema original de equações de segunda ordem

θ_j – termo de polarização

Λ – matriz dos autovalores do modelo de elementos finitos

Λ_c – matriz dos autovalores em tempo contínuo

λ_i – autovalores no tempo contínuo

μ_i – autovalores no tempo discreto

ξ_i – razões de amortecimento crítico

Π – função objetivo

Σ – matriz de covariância dos estados

ϕ – variáveis a serem atualizadas no processo de otimização

Ψ – matriz de autovetores (matriz modal)

$\overrightarrow{\psi}_i$ – vetor da forma modal i

ω_i – frequências naturais

ω_{ij} – pesos sinápticos

OPERADORES

$\mathbf{E}[\cdot]$ – valor esperado

$(\cdot)^\dagger$ – Moore-Penrose pseudo-inversa

SUMÁRIO

1 INTRODUÇÃO	19
1.1 JUSTIFICATIVA.....	20
1.2 OBJETIVOS	21
1.3 ORGANIZAÇÃO DO TRABALHO	21
2 REVISÃO BIBLIOGRÁFICA.....	24
2.1 IDENTIFICAÇÃO DE SISTEMAS	24
2.2 DETECÇÃO DE DANOS EM ESTRUTURAS	27
2.2.1 Métodos Baseados nos Parâmetros Modais ou nas suas Derivadas	29
2.2.1.1 Métodos baseados nas frequências naturais	29
2.2.1.2 Métodos baseados nas formas modais.....	30
2.2.1.3 Métodos baseados nas curvaturas das formas modais.....	30
2.2.1.4 Métodos baseados na energia de deformação modal.....	31
2.2.1.5 Métodos baseados nos coeficientes de amortecimento	32
2.2.2 Métodos Baseados na Matriz de Flexibilidade	32
2.2.3 Métodos Baseados na Teoria de Probabilidade Bayesiana.....	33
2.2.4 Métodos Baseados na Transformada de Wavelet.....	34
2.2.5 Métodos Baseados na Atualização de Matrizes.....	34
2.2.6 Métodos Baseados em Redes Neurais	35
2.2.7 Exemplos de Trabalhos com Combinações de Métodos	37
3 MODELOS DINÂMICOS DE ESTRUTURAS.....	39
3.1 SISTEMAS LINEARES	39
3.2 ESPAÇO DE ESTADO.....	40
3.2.1 Modelo em Espaço de Estado no Tempo Contínuo.....	40
3.2.2 Modelo em Espaço de Estado no Tempo Discreto.....	43
3.2.3 Modelo Estocástico em Espaço de Estado.....	44
4 MÉTODO DE IDENTIFICAÇÃO ESTOCÁSTICA DE SUBESPAÇO	47
4.1 DADOS EXPERIMENTAIS	47
4.2 FILTRO KALMAN	49
4.3 TEORIA DO SSI-DATA	49

4.4	ALGORITMO E IMPLEMENTAÇÃO	51
4.5	DIAGRAMA DE ESTABILIZAÇÃO	52
5	MONITORAMENTO DA INTEGRIDADE ESTRUTURAL.....	54
5.1	DETECÇÃO DE DANO COM BASE NA ATUALIZAÇÃO DE MATRIZES	55
5.1.1	Algoritmo de Otimização de Baleia	56
5.2	DETECÇÃO DE DANO COM BASE EM REDES NEURAIIS	59
6	SIMULAÇÃO NUMÉRICA DE ENSAIOS EXPERIMENTAIS	63
6.1	VIGA ENGASTADA-LIVRE	64
6.1.1	Detecção de Dano com Base na Atualização de Matrizes.....	66
6.1.2	Detecção de Dano com Base em Redes Neurais	67
6.1.3	Comparação dos Resultados das Metodologias Aplicadas.....	69
6.2	TRELIÇA DE 10 BARRAS	70
6.2.1	Detecção de Dano com Base na Atualização de Matrizes.....	71
6.2.2	Detecção de Dano com Base em Redes Neurais	71
6.2.3	Comparação dos Resultados das Metodologias Aplicadas.....	72
6.3	PASSARELA TRELIÇADA	73
6.3.1	Detecção de Dano com Base na Atualização de Matrizes.....	75
6.3.2	Detecção de Dano com Base em Redes Neurais	77
6.3.3	Comparação dos Resultados das Metodologias Aplicadas.....	78
7	ENSAIO EXPERIMENTAL.....	79
7.1	RÉGUA DE AÇO.....	80
7.1.1	Detecção de Dano com Base na Atualização de Matrizes.....	84
7.1.2	Detecção de Dano com Base em Redes Neurais	85
7.1.3	Comparação dos Resultados das Metodologias Aplicadas.....	87
8	APLICAÇÃO EM ESTRUTURA CIVIL.....	88
8.1	PONTE Z24.....	88
8.1.1	Identificação dos Parâmetros Modais.....	90
8.1.2	Desenvolvimento e Atualização do Modelo em Elementos Finitos.....	92
8.1.3	Detecção de Dano com Base na Atualização de Matrizes.....	95
8.1.4	Detecção de Dano com Base em Redes Neurais	95

8.1.5 Comparação dos Resultados das Metodologias Aplicadas.....	96
9 CONSIDERAÇÕES FINAIS	98
REFERÊNCIAS	100
ANEXO A.....	106

1 INTRODUÇÃO

Todas as construções estão sujeitas à deterioração ao longo do tempo, seja ela causada por condições naturais ou eventos extremos. A presença de dano nos sistemas pode acarretar o seu colapso, provocando assim graves acidentes. Por isso, é necessário o acompanhamento contínuo das estruturas visando a segurança dos usuários. Nesse contexto, a área de Monitoramento da Integridade Estrutural (*Structural Health Monitoring* – SHM) se tornou relevante por recomendar a observação e análise perene das estruturas.

Diversas construções, como pontes e edifícios altos, não possuem fácil acesso para execução de inspeções visuais ou ensaios *in loco* (como ensaios não destrutivos) em toda sua extensão. Dessa forma, mesmo que os procedimentos locais sejam amplamente utilizados, eles podem ser impraticáveis por terem altos custos. Além disso, o fator humano tem um grande papel nessa análise, possibilitando a má interpretação dos dados obtidos e podendo gerar um diagnóstico incorreto.

Por consequência, o monitoramento das propriedades globais das estruturas ganha maior destaque, tais como os parâmetros modais como frequências naturais, formas modais e razões de amortecimento. Essas características podem ser adquiridas continuamente através da análise de dados de um sistema de sensores das respostas estruturais (Figura 1.1). Quando esse sistema é previsto e implementado durante a construção, os dados são obtidos facilmente pelas medições e diversas análises podem ser feitas em um curto período. Assim, uma das maiores vantagens do SHM é o diagnóstico ágil.

Como os resultados das medições são os deslocamentos, velocidades e acelerações ao longo do tempo, esses dados podem ser utilizados para estimar os parâmetros modais da estrutura. Esta fase é conhecida como identificação de sistemas e pode ser realizada através de diversos métodos. Visto que as forças excitadoras normalmente são não-determinísticas, a identificação pode ser classificada como identificação estocástica de sistemas. Essa subclasse é comum em estruturas civis já que as ações ambientais são variáveis aleatórias e podem ser estimadas por funções de densidade de probabilidade.




Figura 1.1 – Exemplos de sensores de SHM (adaptado de GKM Consultants)

Através das características dinâmicas obtidas ao longo da vida útil da estrutura, ocorre a comparação com os valores auferidos na situação íntegra. Diferentes métodos de detecção de dano podem ser empregados de acordo com o tipo de construção e sua função. Dependendo da metodologia utilizada, a danificação pode ser até mesmo quantificada. Caso algum dano seja encontrado, os analistas e engenheiros responsáveis podem fazer o devido prognóstico.

1.1 JUSTIFICATIVA

Mesmo com os inúmeros métodos de detecção de dano, como os baseados nos parâmetros modais e suas derivadas, ou em ferramentas específicas (matriz de flexibilidade, teorema de Bayes, transformada de Wavelet, algoritmos de otimização, redes neurais, etc.), não existe uma metodologia amplamente aceita para qualquer tipo de estrutura, ou até mesmo para qualquer tipo de dano. Além disso, cada método tem uma limitação quanto à identificação, localização e quantificação da região danificada. Por isso, muitos estudos de combinações de técnicas foram realizados visando aprimorar os resultados obtidos em simulações numéricas e ensaios

experimentais (SRINIVAS *et al.*, 2010; SHIH *et al.*, 2011; GUO, LI, 2012; GARCIA-PEREZ *et al.*, 2013; TRAN-NGOC *et al.*, 2019).

Dessa forma, o teste, a comparação e a aprimoração de métodos de detecção de dano em diferentes tipos de estruturas civis é extremamente relevante para determinar uma metodologia eficaz e eficiente. Uma metodologia robusta será capaz de identificar, localizar e quantificar falhas em sistemas estruturais até mesmo em estágios iniciais, garantindo a segurança dos usuários.

1.2 OBJETIVOS

Neste contexto, este trabalho tem como objetivo geral aplicar e comparar metodologias de localização e quantificação de dano baseadas na atualização de matrizes e em redes neurais em estruturas utilizando as frequências naturais e os modos de vibração identificados a partir das respostas às excitações ambientais. Para isto, têm-se os seguintes objetivos específicos:

- determinar os parâmetros modais através da implementação de um método de identificação estocástica de sistemas;
- simular numericamente cenários com danos em estruturas para os testes de métodos de detecção de dano e comparação de resultados;
- validar as metodologias utilizadas por meio de ensaios experimentais em pequenas estruturas;
- aplicar as metodologias estudadas em estrutura real utilizada como *benchmark* na literatura.

1.3 ORGANIZAÇÃO DO TRABALHO

Esta dissertação é composta por 9 capítulos, dos quais esta introdução é o primeiro.

O Capítulo 2 apresenta a revisão bibliográfica sobre métodos de identificação de sistemas e detecção de dano em estruturas. No Subcapítulo Identificação de Sistemas, dá-se enfoque aos métodos que utilizam apenas os dados da resposta estrutural, pois esses são os mais usuais na engenharia civil. Já no Subcapítulo de detecção de dano em estruturas, citam-se as variadas metodologias empregadas, como as baseadas nos parâmetros modais, na matriz de

flexibilidade, na teoria da probabilidade Bayesiana, na transformada de Wavelet, na atualização de matrizes e em redes neurais.

O Capítulo 3 contém a teoria de alguns modelos matemáticos que são capazes de representar o comportamento dinâmico de estruturas. Os modelos em espaço de estado têm suas propriedades detalhadas, pois o modelo estocástico em espaço de estado é a base do método de identificação utilizado nesse trabalho.

O Capítulo 4 traz a teoria e o algoritmo de implementação do Método de Identificação Estocástica de Subespaço baseado nas séries temporais. Explica-se a organização e a manipulação dos dados de medições experimentais, o filtro Kalman e as formulações matemáticas. Além disso, descreve-se o diagrama de estabilização que surge como ferramenta de escolha dos modos estáveis de um sistema.

O Capítulo 5 apresenta inicialmente uma metodologia genérica de Monitoramento da Integridade Estrutural. Em seguida, explicam-se os procedimentos adotados nesse trabalho para aplicação de métodos de detecção de dano. O primeiro método baseia-se na atualização de matrizes utilizando o Algoritmo de Otimização de Baleia, já o segundo é baseado em redes neurais utilizando as redes *Feedforward*.

O Capítulo 6 contém a simulação numérica de ensaios experimentais de três estruturas, sendo elas: uma viga em balanço, uma treliça plana de 10 barras e uma passarela treliçada de pedestres. Para isso, fez-se: a modelagem dos três sistemas, a obtenção das respostas por meio do Método de Integração de Newmark, a identificação modal estocástica e a detecção de cenários de danos simples e múltiplos.

O Capítulo 7 traz a verificação de desempenho das metodologias de detecção de dano estudadas em ensaios experimentais de uma régua de aço. Explicam-se os ensaios de dano progressivo realizados no sistema e os equipamentos utilizados. As frequências naturais e formas modais foram identificadas pelo Método de Identificação Estocástica de Subespaço baseado nas séries temporais, sendo o cenário íntegro referência para o desenvolvimento de um modelo numérico. Foram localizados e quantificados cenários de danos simples e múltiplos.

O Capítulo 8 apresenta a aplicação dos métodos estudados neste trabalho em uma estrutura civil, a Ponte Z24 localizada na Suíça. Os parâmetros modais da estrutura são determinados pela identificação estocástica de sistemas a partir dos dados de ensaios sob excitação ambiental.

Explica-se o desenvolvimento e atualização de um modelo em elementos finitos desenvolvido no ANSYS, sendo este a base dos métodos baseados na atualização de matrizes e de redes neurais para localização e quantificação da danificação.

Por fim, o Capítulo 9 traz as conclusões finais, além de sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

A revisão bibliográfica desse trabalho é dividida em duas áreas, sendo elas a identificação de sistemas e a detecção de danos em estruturas. Esses temas foram estudados por serem base da metodologia de monitoramento de estruturas reais, como é explicado nos tópicos a seguir.

2.1 IDENTIFICAÇÃO DE SISTEMAS

A avaliação das propriedades dinâmicas de estruturas através de dados experimentais é conhecida como identificação, visto que é realizada a estimativa dos parâmetros de um modelo que se enquadra com os dados fornecidos. Dessa forma, a identificação de sistemas é a dedução de modelos com base em informações obtidas experimentalmente. A partir desse conceito, criou-se na área da dinâmica estrutural a identificação modal, que consiste na descrição de modelos estruturais por meio de propriedades dinâmicas do sistema, como: frequências naturais, razões de amortecimento e modos de vibração (RODRIGUES, 2004).

Segundo Van Overschee e De Moor (1996), a identificação pode ser dividida em três categorias: identificação determinística, identificação estocástica e identificação determinística-estocástica. Essas três formas se baseiam em diferentes abordagens de análise utilizando os dados de entrada (excitação) e de saída (resposta), sendo estes dados relacionados conforme a Figura 2.1. A identificação determinística é aquela que ocorre por meio de modelos com dados de entrada e saída, enquanto, na identificação estocástica, a análise é feita apenas com os dados de saída devido a impossibilidade de determinação da excitação. Já a identificação determinística-estocástica é realizada com as entradas e saídas, sendo executada a modelagem de perturbações nas excitações e de ruído nas respostas.




Figura 2.1 – Relação excitação-resposta de um sistema estrutural (Carini, 2021)

Muitas estruturas civis, como pontes e edifícios, têm grandes dimensões, o que torna inviável excitá-las por meio artificiais. Por isso, é comum para esse tipo de estrutura que se utilizem excitações ambientais (vento, tráfego de veículos ou pessoas etc.) em análises dinâmicas. Esse

tipo de excitação não pode ser representado através de uma função determinística ao longo do tempo, sendo de natureza estocástica e, portanto, deve ser caracterizada por parâmetros estatísticos. Deste modo, esse trabalho dá um maior enfoque em métodos de identificação estocástica de sistemas.

O método mais simples de identificação estocástica é o Método Básico no Domínio da Frequência (*Basic Frequency Domain Method* – BFD), também conhecido como Método de Detecção de Picos (*Peack Picking Method* – PP), que se baseia no domínio da frequência. Suas primeiras aplicações foram feitas na década de 1960, mas a apresentação da fundamentação do método foi feita por Bendat e Piersol (1993). Sua análise se fundamenta no fato de que a resposta em frequência do sistema apresenta valores de pico em torno das frequências naturais da estrutura. Além disso, os modos de vibração são determinados por meio de funções de transferência das frequências naturais. Assim, assume-se que a ressonância da resposta dinâmica é dominante apenas em um modo de vibração, os modos são bem espaçados e a taxa de amortecimento da estrutura é baixa (REN; ZONG, 2004).

Em 2000, Brincker *et al.* propuseram o Método da Decomposição no Domínio da Frequência (*Frequency Domain Decomposition* – FDD) como uma extensão do BFD. Utilizando a decomposição em valores singulares (*singular value decomposition* – SVD), o FDD decompõe a resposta espectral em um conjunto de sistemas de um grau de liberdade, sendo cada um responsável por um modo de vibração.

Peeters e Van der Auweraer (2005) desenvolveram o Método da Polireferência no Domínio da Frequência por Mínimos Quadrados (*polyreference Least-Squares Complex Frequency domain method* – p-LSCF), também chamado de PolyMAX. Essa técnica determina os parâmetros modais através da minimização do erro entre densidades espectrais medidas e estimadas. Ademais, o processo de interpretação de resultados é facilitado utilizando diagramas de estabilização, que contêm informações das frequências e amortecimento, para identificação de polos estáveis do sistema.

Segundo Fadel Miguel (2007), os métodos de identificação no domínio da frequência apresentam alguns problemas, como os efeitos nocivos provocados pelo fenômeno de vazamento e as restrições impostas para casos com frequências naturais muito próximas. Por isso, desenvolveram-se novas técnicas baseadas no domínio do tempo, que facilitaram a

identificação de um número maior de frequências naturais com base na determinação do número de graus de liberdade da estrutura analisada.

Utilizando o domínio do tempo, Cole (1968) desenvolveu o Método do Decremento Aleatório (*Random Decrement* – RD). Este método gera um sinal proporcional ao decremento, causado pelo amortecimento do sistema, a partir de uma média de segmentos das respostas temporais em vibração livre. Já Ibrahim e Mikulcik (1973), criaram o Método de Ibrahim no Domínio do Tempo (Ibrahim Time Domain – ITD), sendo usadas as respostas da estrutura para determinar a matriz do sistema no espaço de estado e, conseqüentemente, encontrar as frequências naturais e razões de amortecimento.

O Método de Identificação Estocástica de Subespaços (*Stochastic Subspace Identification* – SSI) aborda o problema de identificação de um modelo estocástico no espaço de estado, que inicialmente foi solucionado por Akaike (1974). O SSI utiliza apenas os dados de saída, podendo se basear nas matrizes de covariância (*Covariance-driven Stochastic Subspace Identification* – SSI-COV) ou em séries temporais (*Data-driven Stochastic Subspace Identification* – SSI-DATA), sendo que ambas as técnicas visam cancelar os ruídos não correlacionados (PEETERS, 2000).

Em 1982, Vold *et al.* criaram o Método da Polireferência no Domínio do Tempo (*Polyreference Time Domain* – PTD). Essa técnica foi a primeira a utilizar respostas de excitação em diversos pontos simultaneamente. Além disso, a informação de fase dos sinais é utilizada para distinguir modos de vibração próximos ou repetidos.

Através de uma nova abordagem utilizando SVD na extensão do algoritmo Ho-Kalman, Juang e Pappa (1985) propuseram o Algoritmo de Realização de Sistemas (*Eigensystem Realization Algorithm* – ERA). O método inclui indicadores de precisão para avaliação de ruído e não-linearidades, e, como o PTD, é capaz de identificar raízes repetidas.

Os métodos descritos anteriormente são apresentados em uma linha do tempo pela Figura 2.2, de acordo com o ano de formalização de cada técnica. Além desses, existem outros métodos de identificação de sistemas, como os citados por Amani (2004), Rodrigues (2004) e Reynders (2012). Como resumo da teoria de identificação de sistemas no âmbito da engenharia Civil, cita-se o trabalho de Carini (2021), que tem enfoque nos métodos que usam apenas os dados de saída da estrutura. O autor implementou os métodos BFD, IV, PP, SSI-COV e SSI-DATA em

linguagem Python, validando as rotinas de identificação em estruturas reais (a Passarela P01 em Passo Fundo, a Passarela Domingos Martins em Canoas e a Ponte Z24 na Suíça).




Figura 2.2 – Linha do tempo dos Métodos de Identificação de Sistemas

Destaca-se que nos últimos anos combinações, atualizações e ponderações dos métodos já citados foram desenvolvidas. Principalmente utilizando os métodos SSI, p-LSCF, e FDD (REYNDERS, 2012). Porém, ainda não foi consolidado um novo método de identificação estocástica de sistemas na literatura.

2.2 DETECÇÃO DE DANOS EM ESTRUTURAS

Farrar *et al.* (2001) definem dano como mudanças introduzidas em um sistema que afetam sua performance atual ou futura. Desse modo, o conceito de dano depende da comparação de dois estados diferentes, assumindo-se que o primeiro representa o cenário inicial e íntegro. Em geral, as mudanças na estrutura podem ser caracterizadas como alterações nos materiais e/ou propriedades geométricas, incluindo modificações nas condições de contorno e conectividades.

A deterioração da estrutura pode alterar a rigidez do sistema e modificar os parâmetros modais. A magnitude dessa mudança depende tanto da severidade como do local do dano, sendo que cada evento de danificação afetará de maneira diferente cada modo de vibração. Ressalta-se que o dano diminui a rigidez do sistema, enquanto a massa permanece praticamente a mesma (HEARN; TESTA, 1991). Entretanto, existem certas situações que fogem dessa regra, como as citadas por Farrar e Worden (2012):

- a mudança nas condições de contorno em pontes devido a erosão do solo, que podem não alterar diretamente a rigidez do sistema;
- a mudança de conectividade gerada pelo afrouxamento de conexões parafusadas, que não causa a alteração de rigidez;
- a variação da massa, independentemente de dano, de plataformas *offshore* devido a incrustações marinhas, armazenamento de fluídos e movimento ondulatório.

As técnicas de detecção de dano vêm sendo desenvolvidas e implementadas buscando permitir o uso seguro de estruturas ou estender seu tempo de operação além do conceito tradicional de período de vida útil. Esses métodos podem ser classificados como locais ou globais. Os métodos locais se baseiam em partes restritas da estrutura e podem usar recursos experimentais como raios X, campos magnéticos e emissões acústicas. Já os métodos globais, em sua maioria, utilizam métodos baseados em vibrações para analisar as respostas do sistema e as variações nas propriedades modais. Uma vantagem dos métodos globais é que as medições não precisam ser realizadas em regiões próximas ao local de dano, que pode ser de difícil acesso (AMANI *et al.*, 2007).

De acordo com Rytter (1993), os métodos de detecção de dano são classificados em quatro níveis:

- nível 1 (identificação): métodos que indicam qualitativamente a presença de dano na estrutura;
- nível 2 (localização): métodos que informam o possível local do dano;
- nível 3 (quantificação): métodos que permitem a avaliação da intensidade do dano;
- nível 4 (prognóstico): métodos que viabilizam a previsão da vida remanescente da estrutura.

Em geral, os métodos desenvolvidos até o momento se enquadram nos níveis de 1 a 3, enquanto o nível 4 é considerado parte da avaliação estrutural. Os primeiros métodos criados na literatura eram classificados como métodos de identificação de dano, enquanto os métodos mais recentes tendem a se concentrar no nível de localização. Assim, ainda é necessário o avanço das metodologias quanto a quantificação de danos em estruturas.

Segundo Farrar e Worden (2012), as técnicas de detecção de dano estão ligadas a disciplinas como: Monitoramento da Integridade Estrutural (*Structural Health Monitoring – SHM*), Monitoramento de Condição (*Condition Monitoring – CM*), avaliação não-destrutiva (*nondestructive evaluation – NDE*) e Prognóstico de Danos (*Damage Prognosis – DP*).

O Monitoramento da Integridade Estrutural ainda é uma disciplina menos consolidada na engenharia e tem aplicações limitadas. O termo SHM ligado a métodos baseados em vibrações envolve a observação da estrutura ao longo do tempo usando medições das respostas dinâmicas do sistema, sendo que as propriedades sensíveis ao dano são analisadas para determinar o estado

estrutural. Essas propriedades incluem as frequências naturais, função de resposta em frequência, formas modais, curvaturas das formas modais, energia de deformação modal, matriz de flexibilidade, etc. (REN *et al.*, 2011).

Destacam-se os trabalhos de Doebling *et al.* (1996), Fan e Qiao (2011) e An *et al.* (2019) que resumem o estado da arte na área dos métodos de detecção de dano baseados em vibrações. Como mostram os autores, esses métodos podem ser categorizados de diversas formas, sendo a mais comum a classificação pelo tipo de dado medido e/ou solução empregada, como mostrado a seguir.

2.2.1 Métodos Baseados nos Parâmetros Modais ou nas suas Derivadas

Os parâmetros modais são as propriedades dominantes na identificação de dano, sendo geralmente obtidos pelo processo experimental de identificação de sistemas. Os principais métodos baseados nas alterações desses parâmetros ou de suas derivadas são descritos abaixo.

2.2.1.1 Métodos baseados nas frequências naturais

Os métodos baseados nas frequências naturais utilizam a mudança das frequências como propriedade básica para identificação do dano. Como esse parâmetro pode ser mensurado facilmente por meio de medições em poucos pontos da estrutura e são menos afetados pelo ruído experimental, o uso das frequências naturais se torna mais atrativo (FAN; QIAO, 2011).

Entretanto, Farrar *et al.* (2001) destacam que a alteração das frequências não fornece informação espacial sobre modificações na estrutura. Além disso, para detecção de dano em grandes construções se torna necessário medições mais precisas ou altas intensidades de dano. Essas restrições podem ser superadas a partir da análise das mudanças de frequência dos modos de vibração com frequências mais elevadas, pois esses modos se associam com as respostas locais. Contudo, a identificação desses modos se torna mais limitada devido as excitações ambientais não atingirem altas frequências.

Uma revisão bibliográfica do uso da frequência natural como parâmetro de detecção de dano é apresentada por Salawu (1997). O autor ressalta a facilidade de usar essa propriedade, mas coloca algumas ressalvas sobre possíveis causas de alteração das características modais, tais como o efeito de condições ambientais (temperatura e umidade) e mudança nas condições de apoio, que podem gerar poucas consequências estruturais. Além disso, pode ser necessário em

alguns casos dados com precisão mínima de 0,01 Hz, pois alterações menores que 5% nas frequências naturais dificultam a detecção de dano.

2.2.1.2 Métodos baseados nas formas modais

A detecção de dano por métodos baseados nas formas modais é feita de forma similar aos métodos que consideram as alterações nas frequências naturais. Porém, segundo Pandey *et al.* (1991), enquanto as mudanças das frequências conseguem indicar a presença de rachaduras ou outros tipos de dano na estrutura, as mudanças nas formas modais também podem indicar a localização.

Hearn e Testa (1991) destacam que o dano em um elemento pode afetar apenas as formas modais em que ele participa. Por isso, na análise é fundamental a escolha de modos locais de vibração – aqueles que envolvem o movimento de um único elemento ou um pequeno grupo de elementos vizinhos. Porém, a identificação experimental dos modos globais de vibração – aqueles que fornecem um panorama geral da estrutura – é mais simples.

Em 1982, Allemang e Brown desenvolveram o Critério de Concordância Modal (*Modal Assurance Criterion* – MAC) que estima a correlação entre duas formas modais. Essa função tem seu valor variando entre 0 e 1, sendo que se o MAC tem valor próximo a zero, há a indicação de que as formas modais analisadas não são consistentes entre si. Segundo Allemang (2002), uma das possíveis aplicações desse critério é a detecção de dano. Porém, o autor ressalta que o MAC pode apresentar insensibilidade para pequenas variações no sistema, não garantindo a validação entre os vetores.

2.2.1.3 Métodos baseados nas curvaturas das formas modais

As curvaturas das formas modais são obtidas a partir da segunda derivada das formas modais. O uso desse parâmetro na detecção de dano se fundamenta na suposição de que as mudanças nas curvaturas são altamente concentradas nas regiões de dano, sendo mais acentuadas que as mudanças em deslocamento das formas modais (CARDEN; FANNING, 2004).

Pandey *et al.* (1991) foram os responsáveis por introduzir o conceito de curvatura das formas modais aplicando o método em uma viga engastada e uma viga biapoiada. O dano foi simulado a partir da redução do módulo de elasticidade em um modelo em elementos finitos. Os autores mostraram que para as duas vigas os coeficientes MAC e o Critério de Concordância de Coordenada Modal (*Coordinate Modal Assurance Criterion* – COMAC) não conseguiram

constatar a presença de dano. Já as alterações das curvaturas das formas modais foram bem-sucedidas em apontar a localização do elemento danificado.

Buscando detectar dano em uma ponte de concreto protendida (Ponte Z24, na Suíça), Abdel Wahab e De Roeck (1999) aplicaram um método com base nas mudanças das curvaturas das formas modais. A partir de um indicador de dano chamado Fator de Dano de Curvatura (*Curvature Damage Factor* – CDF), pode-se encontrar com clareza a localização da área danificada. Ressalta-se que para modos de vibração mais altos as curvaturas das formas modais são determinadas com menos precisão, e, por isso, deve-se analisar o conjunto de curvaturas de vários modos.

2.2.1.4 Métodos baseados na energia de deformação modal

A taxa de mudança da energia de deformação modal em cada elemento do sistema também pode ser utilizada como parâmetro na detecção de dano. Segundo Shi e Law (1998), com a ocorrência de dano no sistema estrutural, a energia de deformação modal irá mudar pouco nos elementos não danificados, enquanto apresentará uma grande diferença nos elementos danificados. Nesse trabalho, os autores mostraram que o método utilizando a energia de deformação modal é efetivo e robusto na localização de um único ou múltiplos cenários de dano. A técnica proposta foi validada em estruturas de treliça e estruturas de pórtico plano.

Para estruturas tipo placa, Cornwell *et al.* (1999) desenvolveram um método de detecção de dano baseado na energia de deformação modal, que foi testado numericamente por elementos finitos e experimentalmente por meio de uma placa de alumínio. Constatou-se que o método proposto é efetivo para localização de áreas com redução de rigidez tão baixas quanto 10%, apesar de ele apresentar dificuldades na identificação de cenários múltiplos de dano.

Em 2012, Fan e Qiao criaram o fator de localização de dano (*damage location factor* – DLF) e o fator de correção da gravidade do dano (*damage severity correction factor* – DSCF). Ambos os coeficientes se baseiam na energia de deformação modal para localizar e quantificar elementos com dano em estruturas tipo placa. O método é capaz de identificar as áreas danificadas mesmo para situações em que os elementos tenham danos menores que 10% e medições com ruídos maiores que 30%. Mas, nesses casos, pode ocorrer falhas na quantificação.

2.2.1.5 Métodos baseados nos coeficientes de amortecimento

A presença de dano em uma estrutura irá causar alterações na capacidade de amortecimento do sistema, como mostrado por Rytter (1993) para o caso de vigas engastadas com rachaduras. Entretanto, as mudanças no coeficiente de amortecimento são dependentes de diversos fatores, como o histórico de carregamento, o que dificulta determinar uma relação analítica entre dano e amortecimento.

Curadelli *et al.* (2008) mostraram que o coeficiente de amortecimento é uma propriedade mais sensível ao dano que as frequências naturais. Os autores analisaram a alteração dessas duas propriedades modais em três sistemas distintos: simulação numérica de um pórtico plano em concreto armado, ensaio de flexão pura de uma viga em concreto armado, e ensaio de um pórtico espacial de alumínio submetido à excitação sísmica. Para as três situações, o coeficiente de amortecimento mostrou-se como um bom indicador de dano, tendo potencial para estudos futuros.

2.2.2 Métodos Baseados na Matriz de Flexibilidade

A matriz de flexibilidade também pode ser utilizada para localizar e estimar a presença de dano nas estruturas. Ela é definida como o inverso da matriz de rigidez, relacionando a força estática aplicada com o resultante do deslocamento estrutural. Assim, cada coluna da matriz de flexibilidade equivale a um conjunto de deslocamentos nodais gerados por uma força unitária aplicada no grau de liberdade correspondente do sistema. A relação inversa entre a flexibilidade e o quadrado das frequências modais é responsável pela rápida conversão dos resultados (FARRAR; DOEBLING, 1997).

Com base nesse princípio, Bernal (2002) desenvolveu o Método dos Vetores de Localização de Dano (*Damage Locating Vectors – DLV*). Essa técnica de detecção de dano baseia-se nas mudanças da matriz de flexibilidade, sendo que os elementos danificados são identificados por possuírem forças internas sob a ação de certos vetores de carregamento igual a zero. Esses vetores são nomeados como vetores de localização de dano, e podem ser computados a partir dos dados de medições entre os estados íntegro e danificado da estrutura. Desse modo, esse método dispensa a necessidade de um modelo numérico da estrutura.

Fadel Miguel (2007) aplicou o DLV em estruturas treliçadas, mostrando a eficiência de uma técnica baseada na matriz de flexibilidade. O dano foi identificado com sucesso mesmo com o

número limitado de sensores utilizado na parte experimental. Além disso, a presença moderada de ruído e baixa intensidade de dano não foram um empecilho para o método.

2.2.3 Métodos Baseados na Teoria de Probabilidade Bayesiana

Devido a fatores incertos nas obras civis, como propriedades complexas e o impacto de ruídos ambientais no monitoramento de estruturas, a precisão de muitos métodos de detecção de dano é reduzida. Por essa razão, métodos baseados na teoria de probabilidade Bayesiana ganharam espaço nas últimas décadas. Essas técnicas tratam os parâmetros físicos a serem identificados como variáveis aleatórias. Desse modo, utilizando dados de medições reais e o teorema de Bayes, os modelos de probabilidade anteriores dos parâmetros a serem estimados são modificados, as estimativas ótimas são calculadas e as distribuições de probabilidade posteriores são fornecidas (ZHAO *et al.*, 2020).

Segundo Chang *et al.* (2003), o reconhecimento de padrões com uma abordagem estatística utilizando o teorema de Bayes determina o evento de dano mais provável pela comparação das probabilidades de dano relativas de diferentes eventos. Os dados estatísticos são obtidos por medições contínuas ou periódicas baseadas nas excitações ambientais ou forçadas. Assim, a probabilidade de dano relativa de um evento é obtida utilizando a diferença entre as propriedades modais obtidas experimentalmente e as previstas pelo modelo analítico.

Considerando o uso de um sistema de monitoramento na estrutura, Sohn e Law (1997) desenvolveram uma abordagem de probabilidade Bayesiana para combinar dados experimentais antigos com dados recém disponíveis. Os autores testaram o método em vários cenários para uma estrutura *shear-building* e duas estruturas de pórtico espacial. Concluiu-se que com menos de 10% de ruído nas medições, entre 10 e 30% dos graus de liberdade do sistema sendo monitorados, e apenas os modos de vibração fundamentais sendo estimados, o método proposto foi capaz de localizar e quantificar dano.

Zheng *et al.* (2014) aplicaram o teorema de Bayes para detecção de dano em estruturas treliçadas. A análise foi realizada no domínio da frequência, e aprimorou-se a estrutura de inferência probabilística pela revisão do Método de Monte Carlo via Cadeias de Markov. Isso possibilitou a identificação de dano tanto nos componentes da treliça como em suas juntas.

2.2.4 Métodos Baseados na Transformada de Wavelet

A transformada de Wavelet (*Wavelet Transform* - WT) é capaz de decompor um sinal em vários componentes wavelets, também conhecidos como níveis. Quando os diferentes componentes são unidos, o sinal original é recuperado (NEWLAND, 2005). Dessa forma, uma função pode ser representada em diferentes escalas e a conversão do sinal consegue ter uma melhor resolução no quesito tempo-frequência. Devido à performance da WT, esse método foi difundido na engenharia e ganhou enfoque nas áreas de extração de propriedades do sistema e reconhecimento de padrões.

Devido a capacidade da transformada de Wavelet de detectar pequenas discontinuidades, Liew e Wang (1998) aplicaram essa técnica na detecção de fissuras em vigas apoiadas. O método baseou-se na quebra do sinal da resposta dinâmica do sistema em uma série de funções base locais (wavelets). Nos testes realizados, as fissuras não causaram grandes mudanças nos 5 primeiros modos de vibração. Entretanto, os coeficientes wavelets ao longo da viga apontaram com clareza a localização da fissura.

Em 2014, Altammar *et al.* propuseram um método de detecção de fissuras em estruturas treliçadas de grande vão com base na WT. A partir dos 3 primeiros modos de vibração, calculou-se os coeficientes wavelets e aplicou-se a janela de filtragem. Com esses resultados, foi feita uma análise estatística para identificação do dano. O método apresentado determinou a correta localização das fissuras mesmo com a presença de 4% de ruído. Contudo, os autores destacam que danos próximos as juntas da estrutura foram mais difíceis de serem detectados.

2.2.5 Métodos Baseados na Atualização de Matrizes

Os métodos com atualização das matrizes do sistema se baseiam na modificação das matrizes (rigidez e amortecimento) para reprodução fidedigna da resposta dinâmica ou estática a partir dos dados medidos. Em resumo, ocorre a resolução de um problema de otimização a partir das equações de movimento e das medições experimentais, sendo que a comparação das matrizes originais e atualizadas fornecem um identificador de dano.

Amani (2004) propôs um método de localização e quantificação de dano para sistemas estruturais com amortecimento viscoso arbitrário, baseado na equação de autovalores do sistema danificado. Esse método foi validado em modelos numéricos e experimentais de pórticos de alumínio submetidos a excitação de base. Assim, foi possível identificar o dano

através da análise de variação das matrizes de rigidez e de amortecimento viscoso, porém a variação da matriz de amortecimento se mostrou um indicador mais sensível ao dano.

Utilizando o Algoritmo de Busca Harmônica (*Harmony Search Algorithm* – HS), Fadel Miguel *et al.* (2012) localizaram e quantificaram cenários de dano em uma viga engastada de alumínio. Os autores usaram o método SSI para identificar as propriedades modais dos cenários íntegro e danificado a partir de medições experimentais. A presença de dano foi considerada como um fator de redução da matriz de rigidez de cada elemento do sistema. Esse fator assumiu um valor entre 0 e 1, sendo que 0 representa a perda de rigidez total do elemento e 1 a condição íntegra. O método atingiu resultados excelentes, e mesmo com ruídos nas medições o HS mostrou-se promissor para identificação de danos em estruturais reais.

A resolução do problema de otimização dos métodos de detecção de dano baseado na atualização de matrizes apresenta algumas desvantagens causadas pelos algoritmos comumente utilizados. Por isso, Fadel Miguel *et al.* (2013) propuseram uma a resolução de otimização híbrida utilizando o Algoritmo Nelder-Mead (*Nelder-Mead algorithm* – NMA). O método foi aplicado numericamente em estruturas de pórtico plano e treliça plana, e experimentalmente em vigas engastadas de alumínio. Os resultados obtidos mostraram que o algoritmo de otimização híbrida (P-NMA) apresenta melhor performance que outros algoritmos da literatura, além de gerar bons resultados mesmo com a presença de ruído nos sinais de resposta.

Zeni (2018) desenvolveu modelos numéricos de estruturas em elementos finitos, em que os parâmetros modais caracterizavam a estrutura antes e depois do dano. Esse modelo foi responsável por simular a resposta dinâmica obtida experimentalmente, e foi base do algoritmo de otimização utilizado (*Backtracking Search Algorithm* – BSA). A rotina computacional foi capaz de localizar os cenários de dano em estruturas de pórtico plano, tanto numéricas como experimentais.

2.2.6 Métodos Baseados em Redes Neurais

A abordagem utilizando o aspecto de reconhecimento de padrões dentro da disciplina de Aprendizado de Máquina (*Machine Learning*) vem ganhando destaque no Monitoramento da Integridade Estrutural, principalmente pelo uso das redes neurais. Essa técnica se fundamenta no aprendizado entre as relações entre dados de entrada e de saída do sistema, onde um estado de dano é obtido de acordo com dados de propriedades sensíveis ao mesmo. Como exemplo de

dados de entrada, pode-se ter as cinco primeiras frequências naturais da estrutura ou até mesmo um conjunto de coeficientes de Wavelet (FARRAR; WORDEN, 2012).

Em 1992, Wu *et al.* utilizaram redes neurais para detectar dano em uma estrutura *shear-building* de três pavimentos. A partir de históricos de aceleração das respostas do sistema, a Transformada Rápida de Fourier foi responsável por gerar os dados de entrada da rede neural em frequência. Os dados de saída foram computados como o nível de dano de cada elemento estrutural e o algoritmo de treinamento escolhido foi o *Backpropagation*. O método foi capaz de distinguir os cenários de dano, porém, os autores ressaltam que a quantidade e posição dos sensores, além do número de dados de entrada para o processo de treinamento, é determinante para precisão dos resultados.

Mehrjoo *et al.* (2008) desenvolveram um método de detecção de dano em juntas de treliças com base em redes neurais. A metodologia foi aplicada em treliças planas de pontes, sendo utilizado como dados de entrada as frequências naturais e formas modais e como dados de saída a intensidade de dano nas juntas. A localização e a quantificação do dano foram determinadas com boa precisão, sendo suficiente o uso de cinco modos de vibração.

Considerando estruturas estaiadas, Nunes (2019) desenvolveu um procedimento padrão para detecção de danos utilizando redes neurais. Esse método foi aplicado em um estudo de caso na Passarela Estaiada km88 BR101, localizada no estado de Sergipe. Inicialmente, realizou-se a identificação do sistema com base em séries temporais de aceleração obtidas experimentalmente, que serviu para calibração do modelo numérico em elementos finitos. A rede neural foi desenvolvida em Matlab, sendo treinada a partir de cenários de dano simulados numericamente. Cerca de um ano depois, um novo ensaio de avaliação experimental foi feito, permitindo a localização e quantificação de danos no mastro e no tabuleiro da passarela.

Destaca-se o trabalho Villalba e Laier (2017) que traz uma revisão bibliográfica completa dos métodos baseados em redes neurais para detecção de dano. Foram apresentadas diversas metodologias publicadas a partir dos anos 2000, que são categorizadas de acordo com o seu objetivo específico. Os autores concluem que cenários de dano com muitos elementos comprometidos ainda são uma limitação para os métodos que alcançam o nível 3 (quantificação).

2.2.7 Exemplos de Trabalhos com Combinações de Métodos

Além dos métodos citados anteriormente, muitos trabalhos na área de SHM desenvolvidos utilizam a combinação de mais de um método da literatura. Como vantagem, podem ser obtidos resultados mais precisos de detecção, localização e quantificação dos cenários de dano.

Kaminski e Riera (1997) utilizaram a alteração das cinco primeiras frequências naturais e das formas modais para detectar a presença de dano em uma viga de alumínio engastada. Os autores simularam o dano como a redução do momento de inércia da seção transversal da viga, sendo na parte experimental realizado cortes de profundidades variadas no meio dos elementos selecionados. A abordagem se mostrou satisfatória, podendo identificar problemas como falhas em soldas em estruturas em tamanho real.

Por meio de uma abordagem de análise com energia de deformação modal e otimização com Algoritmo Genético (*Genetic Algorithm – GA*), Srinivas *et al.* (2010) detectaram e estimaram cenários de dano em vigas simplesmente apoiadas e estruturas de treliça plana. As variações da energia de deformação modal foram utilizadas na primeira fase do método para determinar os prováveis elementos danificados. Dessa forma, a fase de otimização usou menos variáveis, diminuindo o trabalho computacional. Testou-se diferentes função objetivo para o GA, sendo a mais eficiente a função com a combinação dos parâmetros de frequências naturais e MAC. Mesmo com ruídos de até 5% nas frequências naturais e 10% nas formas modais, o método se provou eficaz para quantificação de dano.

Em 2011, Shih *et al.* simularam cenários de dano em uma ponte treliçada buscando localizar áreas danificadas por mudanças na matriz de flexibilidade e energia de deformação modal, além da análise de alteração das frequências naturais. A metodologia multicritério se comprovou viável para detecção de danos com intensidade entre 20 e 50% utilizando os cinco primeiros modos de vibração da estrutura.

Guo e Li (2012) propuseram um método de detecção de dano em duas etapas. A primeira foi responsável pela identificação e localização do dano, sendo realizada a combinação de métodos baseados nas alterações das frequências e energia de deformação modal e na Teoria Bayesiana. Já a segunda etapa determinou a intensidade do dano estrutural com o uso de um Algoritmo Genético aprimorado. A precisão da técnica proposta foi confirmada em uma estrutura de treliça plana, obtendo-se uma redução do tempo computacional na fase de otimização.

Para determinar diversos cenários de dano em estruturas de treliça (corrosão interna, perda de rigidez e afrouxamento de parafusos), Garcia-Perez *et al.* (2013) utilizaram a combinação da transformada de Wavelet, decomposição de modo empírico (*empirical mode decomposition* – EMD) e Redes Neurais Artificiais para constatar dano estrutural. Os autores confirmaram que a metodologia proposta foi exata para localização de danos múltiplos, superando dificuldades encontradas por outros métodos.

Buscando identificar e localizar dano em pontes de concreto armado, Juliani (2014) comparou métodos baseados nas alterações das formas modais (MAC e COMAC), curvaturas das formas modais (Diferença de Curvatura Modal – DCM) e energia de deformação modal (Índice de Dano – ID). Com a aplicação dessas técnicas em um modelo reduzido de uma ponte, mostrou-se que os coeficientes MAC e COMAC não foram capazes de identificar danos nas longarinas da ponte. Entretanto, a DCM e o ID conseguiram localizar as danificações em todas as situações propostas.

Tran-Ngoc *et al.* (2019) utilizaram a combinação de algoritmos de otimização com redes neurais para identificação de dano na Ponte Nam O, uma estrutura treliçada localizada no Vietnã. Foram comparados os resultados individuais do Algoritmo de Busca Cuco (*Cuckoo Search Algorithm* – CS), Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO), Algoritmo Genético e Redes Neurais Artificiais com a combinação do CS com as ANN. Em todos os cenários testados, a combinação CS-ANN foi a que convergiu mais rapidamente para os resultados corretos de localização e quantificação de dano.

3 MODELOS DINÂMICOS DE ESTRUTURAS

A descrição de vibrações em estruturas pode ser feita por diversos modelos dinâmicos, seja por meio de modelos de elementos finitos (*finite element* – FE), modelos em espaço de estado ou modelos modais. Nesse capítulo são descritos alguns modelos matemáticos, ou seja, conjunto de equações capazes de representar o comportamento de um determinado sistema.

É dado maior enfoque na representação de sistemas lineares em espaço de estado, por ser a base teórica para o método de identificação de sistemas escolhido. O sistema pode ser considerado linear se ele satisfaz o princípio da superposição. Essa hipótese é satisfeita quando a resposta a uma combinação de excitações é igual a soma das respostas geradas por essas excitações individualmente.

Além disso, considerou-se modelos invariantes no tempo, sendo isso válido se o comportamento do sistema permanece constante ao longo do tempo. Desse modo, uma certa excitação gera sempre a mesma resposta, independentemente do momento em que ela ocorre. Ressalta-se que a hipótese de invariância pode não ser real em períodos muito longos, pois a estrutura pode ser afetada por diversos fatores, como variações de temperatura ou alterações físicas devido ao envelhecimento.

A seguir, são apresentados alguns modelos dinâmicos considerando as relações de tempo contínuo e tempo discreto, além das relações entre dados de entrada e de saída. Esses modelos foram detalhados por Van Overschee e De Moor (1996) e Peeters (2000).

3.1 SISTEMAS LINEARES

O comportamento dinâmico de um sistema com n_2 graus de liberdade é descrito pela equação de movimento (equação 3.1). Essa formulação escrita em termos diferenciais é obtida a partir das leis físicas, como as Leis de Newton para sistemas mecânicos.

$$\mathbf{M}\ddot{\vec{u}}(t) + \mathbf{C}_2\dot{\vec{u}}(t) + \mathbf{K}\vec{u}(t) = \vec{f}(t) = \mathbf{B}_2\vec{v}(t) \quad (3.1)$$

Têm-se que: $\mathbf{M} \in \mathbb{R}^{n_2 \times n_2}$ é matriz de massa, $\mathbf{C}_2 \in \mathbb{R}^{n_2 \times n_2}$ é a matriz de amortecimento, $\mathbf{K} \in \mathbb{R}^{n_2 \times n_2}$ é a matriz de rigidez, $\vec{u}(t) \in \mathbb{R}^{n_2}$ é o vetor de deslocamento, $\dot{\vec{u}}(t) \in \mathbb{R}^{n_2}$ é o vetor de velocidade,

$\vec{u}(t) \in \mathbb{R}^{n_2}$ é o vetor de aceleração, e $\vec{f}(t) \in \mathbb{R}^{n_2}$ é o vetor de forças. Esse vetor de forças pode ser decomposto pela matriz de distribuição dos atuadores $\mathbf{B}_2 \in \mathbb{R}^{n_2 \times m}$, que especifica a localização das entradas, e pelo vetor de excitação $\vec{v} \in \mathbb{R}^m$, que descreve as m entradas no tempo.

As matrizes de massa e de rigidez são calculadas de acordo com as dimensões (uni, bi ou tridimensional) e tipos de elementos finitos adotados para análise do sistema. Já a matriz de amortecimento pode ser determinada pelo amortecimento proporcional de Rayleigh (equação 3.2), realizando-se uma combinação linear das matrizes \mathbf{M} e \mathbf{K} com as constantes escalares α e β , definidas a partir das frequências naturais da estrutura.

$$\mathbf{C}_2 = \alpha\mathbf{M} + \beta\mathbf{K} \quad (3.2)$$

3.2 ESPAÇO DE ESTADO

Como alternativa da representação dinâmica de um sistema pelas equações de movimento, pode-se trabalhar com a definição de espaço de estado. Também conhecido como espaço de fase, esse espaço é $2n_2$ dimensional com eixos $x_1, x_2, \dots, x_{2n_2}$. Assim, um estado é representado por um ponto com coordenadas $x_1(t), x_2(t), \dots, x_{2n_2}(t)$, que são mutáveis de acordo com a evolução temporal.

Essa representação além de definir as relações entre as entradas e respostas do sistema, também pode ser utilizada para modelar as relações entre variáveis internas do sistema, como apresentado nos tópicos a seguir.

3.2.1 Modelo em Espaço de Estado no Tempo Contínuo

Para alterar as equações de movimento, se introduz o conceito de vetor de estado $\vec{x}(t) \in \mathbb{R}^n$, conforme a equação 3.3.

$$\vec{x}(t) = \begin{bmatrix} \vec{u}(t) \\ \dot{\vec{u}}(t) \end{bmatrix} \quad (3.3)$$

Dessa forma, o conjunto de n_2 equações diferenciais ordinárias de segunda ordem é substituído por um conjunto de $n = 2n_2$ equações diferenciais ordinárias de primeira ordem, obtendo-se equação de estado apresentada na equação 3.4.

$$\vec{\dot{x}}(t) = \mathbf{A}_c \vec{x}(t) + \mathbf{B}_c \vec{v}(t) \quad (3.4)$$

Onde $\mathbf{A}_c \in \mathbb{R}^{n \times n}$ é a matriz de estado e $\mathbf{B}_c \in \mathbb{R}^{n \times m}$ é a matriz de entradas (equação 3.5), sendo que o subíndice c representa o tempo contínuo.

$$\mathbf{A}_c = \begin{pmatrix} 0 & \mathbf{I} \\ -\mathbf{M}^{-1}\mathbf{K} & -\mathbf{M}^{-1}\mathbf{C}_2 \end{pmatrix}, \quad \mathbf{B}_c = \begin{pmatrix} 0 \\ \mathbf{M}^{-1}\mathbf{B}_2 \end{pmatrix} \quad (3.5)$$

Além disso, o espaço de estado também é definido pela equação de observação (equação 3.6). Nessa formulação, assume-se que em ensaios experimentais nem todos os n_2 graus de liberdade são medidos, sendo colocado sensores em l localizações.

$$\vec{y}(t) = \mathbf{C}_a \vec{\ddot{u}}(t) + \mathbf{C}_v \vec{\dot{u}}(t) + \mathbf{C}_d \vec{u}(t) \quad (3.6)$$

O vetor $\vec{y}(t) \in \mathbb{R}^l$ contém as saídas do sistema e $\mathbf{C}_a, \mathbf{C}_v, \mathbf{C}_d \in \mathbb{R}^{l \times n_2}$ são, respectivamente, as matrizes de localização das saídas de aceleração, velocidade e deslocamento de acordo com os pontos de medição das saídas. Assim, por meio do vetor de estado, a equação 3.6 pode ser modificada para a equação 3.7.

$$\vec{y}(t) = \mathbf{C}_c \vec{x}(t) + \mathbf{D}_c \vec{v}(t) \quad (3.7)$$

Onde $\mathbf{C}_c \in \mathbb{R}^{l \times n}$ é a matriz de respostas e $\mathbf{D}_c \in \mathbb{R}^{l \times m}$ é a matriz de transmissão direta. Essas matrizes se relacionam com as matrizes do modelo de elementos finitos, conforme a equação 3.8.

$$\mathbf{C}_c = (\mathbf{C}_d - \mathbf{C}_a \mathbf{M}^{-1} \mathbf{K} \quad \mathbf{C}_v - \mathbf{C}_a \mathbf{M}^{-1} \mathbf{C}_2), \quad \mathbf{D}_c = \mathbf{C}_a \mathbf{M}^{-1} \mathbf{B}_2 \quad (3.8)$$

Desse modo, a combinação das equações 3.4 e 3.7 forma o modelo clássico de espaço de estado no tempo contínuo (equação 3.9). Enquanto o vetor de estado $\vec{x}(t)$ contém os deslocamentos e velocidades de todos os graus de liberdade da estrutura, o vetor de saídas $\vec{y}(t)$ pode ser usado para calcular as respostas geradas a partir de um determinado conjunto de entradas.

$$\begin{aligned}\vec{\dot{x}}(t) &= \mathbf{A}_c \vec{x}(t) + \mathbf{B}_c \vec{v}(t) \\ \vec{y}(t) &= \mathbf{C}_c \vec{x}(t) + \mathbf{D}_c \vec{v}(t)\end{aligned}\quad (3.9)$$

Formas alternativas de representação do modelo em espaço de estado podem ser geradas para um sistema linear. Um exemplo disso é a transformação de similaridade, em que o vetor de estado é modificado mantendo-se a relação original de entradas e saídas, porém ocorre a perda do significado físico de deslocamentos e velocidades.

A transformação modal de estados é um caso especial de transformação de similaridade, que apresenta como vantagem termos expressos por coordenadas modais. Ela é definida pela equação 3.10.

$$\vec{x}(t) = \mathbf{\Psi} \vec{x}_m(t) \quad (3.10)$$

Onde $\vec{x}_m(t) \in \mathbb{C}^n$ é o vetor de estado expresso em termos das coordenadas modais e $\mathbf{\Psi} \in \mathbb{C}^{n \times n}$ é a matriz de autovetores (matriz modal).

Realizando a substituição da equação 3.10 nas equações 3.4 e 3.7, e inserindo a decomposição modal da matriz \mathbf{A}_c , determina-se o modelo de espaço de estado nas coordenadas modais apresentado na equação 3.11.

$$\begin{aligned}\vec{\dot{x}}_m(t) &= \mathbf{\Lambda}_c \vec{x}_m(t) + \mathbf{B}_m^T \vec{v}(t) \\ \vec{y}(t) &= \mathbf{C}_m \vec{x}_m(t) + \mathbf{D}_c \vec{v}(t)\end{aligned}\quad (3.11)$$

Onde $\mathbf{\Lambda}_c \in \mathbb{C}^{n \times n}$ é a matriz de autovalores, $\mathbf{B}_m^T \in \mathbb{C}^{n \times m}$ é a matriz modal de entradas, e $\mathbf{C}_m \in \mathbb{C}^{l \times n}$ é matriz modal de saídas, de acordo com as definições da equação 3.12.

$$\mathbf{\Lambda}_c = \mathbf{\Psi}^{-1} \mathbf{A}_c \mathbf{\Psi}, \quad \mathbf{B}_m^T = \mathbf{\Psi}^{-1} \mathbf{B}_c, \quad \mathbf{C}_m = \mathbf{C}_c \mathbf{\Psi}^{-1} \quad (3.12)$$

Como mostrado na equação 3.13, a matriz de autovalores possui estrutura diagonal com uma formulação dependente das frequências naturais ω_i (rad/s) e das razões de amortecimento crítico ξ_i do sistema de acordo com o respectivo modo de vibração i .

$$\mathbf{\Lambda}_c = \begin{pmatrix} \mathbf{\Lambda} & \mathbf{0} \\ \mathbf{0} & \mathbf{\Lambda}^* \end{pmatrix}, \quad \mathbf{\Lambda} = \begin{bmatrix} \ddots & & \\ & \lambda_i & \\ & & \ddots \end{bmatrix} \quad (3.13)$$

$$\lambda_i, \lambda_i^* = -\xi_i \omega_i + j\sqrt{1-\xi_i^2} \omega_i, \quad j^2 = -1$$

Já a matriz de autovetores é determinada pela equação 3.14.

$$\Psi = \begin{pmatrix} \Theta & \Theta^* \\ \Theta\Lambda & \Theta^*\Lambda^* \end{pmatrix} \quad (3.14)$$

Onde $\Theta \in \mathbb{C}^{n_2 \times n_2}$ são os autovetores do sistema original de equações de segunda ordem (3.1).

3.2.2 Modelo em Espaço de Estado no Tempo Discreto

Em modelos experimentais de identificação de sistemas, as medições são tomadas em instantes discretos de tempo. Ademais, em grande parte das simulações numéricas não existe uma solução analítica para calcular a resposta da estrutura no tempo contínuo. Por isso, é essencial a adaptação da análise exposta no capítulo anterior no tempo discreto.

Para isso, define-se uma taxa de amostragem Δt para realizar a discretização das equações no tempo contínuo resolvendo-as em instantes k , em que $t = k\Delta t$, $k \in \mathbb{N}$. Além disso, considera-se que duas amostras sucessivas de variáveis dependentes do tempo possuem comportamento constante. Ou seja, aplica-se a teoria Suporte de Ordem Zero (*Zero-Order Hold – ZOH*), também conhecida como retentor de amostras de ordem zero. A partir dessas duas suposições, chega-se no modelo em espaço de estado no tempo discreto, conforme equação 3.15.

$$\begin{aligned} \vec{x}_{k+1} &= \mathbf{A}\vec{x}_k + \mathbf{B}\vec{v}_k \\ \vec{y}_k &= \mathbf{C}\vec{x}_k + \mathbf{D}\vec{v}_k \end{aligned} \quad (3.15)$$

Onde $\vec{x}_k = \vec{x}(k\Delta t)$ é o vetor de estado no instante k , e \vec{v}_k \vec{y}_k são os vetores discretos de excitação e de medição nas saídas, respectivamente. Já \mathbf{A} , \mathbf{B} , \mathbf{C} e \mathbf{D} são, nesta ordem, as matrizes de estado, de entrada, de saída e de transmissão direta.

Segundo Juang (1994), na hipótese de ZOH, as matrizes \mathbf{C} e \mathbf{D} não são influenciadas pela amostragem discreta. Já as matrizes \mathbf{A} e \mathbf{B} são relacionadas com as matrizes no tempo contínuo de acordo com a equação 3.16.

$$\begin{aligned} \mathbf{A} &= e^{\mathbf{A}_c \Delta t}, \quad \mathbf{B} = \int_0^{\Delta t} e^{\mathbf{A}_c \tau'} d\tau \mathbf{B}_c = (\mathbf{A} - \mathbf{I})\mathbf{A}_c^{-1}\mathbf{B}_c \\ \mathbf{C} &= \mathbf{C}_c, \quad \mathbf{D} = \mathbf{D}_c \end{aligned} \quad (3.16)$$

Sendo \mathbf{I} igual a matriz identidade e τ definido pela equação 3.17.

$$\tau' = (k+1)\Delta t - \tau \quad (3.17)$$

Desse modo, as matrizes \mathbf{A} e \mathbf{B} podem ser calculadas pelas expansões das séries da equação 3.18.

$$\begin{aligned} \mathbf{A} &= e^{\mathbf{A}_c \Delta t} = \mathbf{I} + \mathbf{A}_c \Delta t + \frac{1}{2!} (\mathbf{A}_c \Delta t)^2 + \frac{1}{3!} (\mathbf{A}_c \Delta t)^3 + \dots \\ \mathbf{B} &= \int_0^{\Delta t} e^{\mathbf{A}_c \tau'} d\tau \mathbf{B}_c = \left[\mathbf{I} \Delta t + \frac{1}{2!} \mathbf{A}_c (\Delta t)^2 + \frac{1}{3!} \mathbf{A}_c^2 (\Delta t)^3 + \dots \right] \mathbf{B}_c \end{aligned} \quad (3.18)$$

Para encontrar os autovalores da matriz de estado discreta \mathbf{A} , realiza-se a decomposição de autovalores da matriz \mathbf{A}_c (equação 3.19).

$$\mathbf{A} = e^{\mathbf{A}_c \Delta t} = e^{\Psi \mathbf{A}_c \Psi^{-1} \Delta t} = \Psi e^{\mathbf{A}_c \Delta t} \Psi^{-1} = \Psi \mathbf{\Lambda}_d \Psi^{-1} = \Psi \begin{bmatrix} \ddots & & \\ & \mu_i & \\ & & \ddots \end{bmatrix} \Psi^{-1} \quad (3.19)$$

Assim, os autovalores discretos (μ_i) são iguais aos autovalores contínuos (λ_i). Sendo que μ_i pode ser relacionado com λ_i através da relação da equação 3.20.

$$\mu_i = e^{\lambda_i \Delta t} \Leftrightarrow \lambda_i = \frac{\ln(\mu_i)}{\Delta t} \quad (3.20)$$

A partir dos autovalores em tempo contínuo, as razões de amortecimento crítico do sistema são calculadas pela equação 3.21.

$$\xi_i = -\frac{\text{Re}(\lambda_i)}{|\lambda_i|} \quad (3.21)$$

Já as formas modais observáveis \mathbf{V} são obtidas pela equação 3.22.

$$\mathbf{V} = \mathbf{C} \Psi \quad (3.22)$$

3.2.3 Modelo Estocástico em Espaço de Estado

Diversas incertezas podem estar presentes em modelos experimentais, tais como ruídos e outras perturbações. Por isso, a consideração de um sinal determinístico de entrada \vec{v}_k não retrata os componentes estocásticos do modelo e do processo de medição. Com o acréscimo desses componentes, o modelo estocástico em espaço de estado é obtido, conforme a equação 3.23.

$$\begin{aligned}\vec{x}_{k+1} &= \mathbf{A}\vec{x}_k + \mathbf{B}\vec{v}_k + \vec{w}_k \\ \vec{y}_k &= \mathbf{C}\vec{x}_k + \mathbf{D}\vec{v}_k + \vec{z}_k\end{aligned}\quad (3.23)$$

Onde $\vec{w}_k \in \mathbb{R}^n$ é o vetor de perturbações e imprecisões do modelo dinâmico, e $\vec{z}_k \in \mathbb{R}^l$ é o ruído de medição devido à imprecisão do sistema de aquisição. Ambos os vetores são sinais não mensuráveis no instante k , podendo ser modelados como ruído branco gaussiano (sinal de variáveis aleatórias com média zero em que todas as frequências têm a mesma intensidade) e com as matrizes de covariância da equação 3.24.

$$\mathbf{E}\left[\begin{pmatrix} \vec{w}_p \\ \vec{z}_p \end{pmatrix} \begin{pmatrix} \vec{w}_p^T & \vec{z}_p^T \end{pmatrix}\right] = \begin{pmatrix} \mathbf{Q} & \mathbf{S} \\ \mathbf{S}^T & \mathbf{R} \end{pmatrix} \delta_{pq}\quad (3.24)$$

Sendo $\mathbf{E}[\cdot]$ o valor esperado, p e q dois instantes arbitrários de tempo, δ_{pq} o delta de Kronecker (se $p = q$ então $\delta_{pq} = 1$, caso contrário $\delta_{pq} = 0$), e \mathbf{Q} , \mathbf{R} e \mathbf{S} as matrizes covariância do ruído.

Considerando que a estrutura é excitada por vibrações ambientais, não é possível realizar a distinção entre a força excitadora e as perturbações na identificação de sistemas. Assim, a divisão do modelo pelos dos termos de entrada (\vec{v}_k , \vec{w}_k e \vec{z}_k) pode ser substituída apenas pelos termos de ruído. Arbitrando-se $\vec{v}_k = 0$ na equação 3.23, chega-se ao modelo estocástico discreto no espaço de estado (equação 3.25).

$$\begin{aligned}\vec{x}_{k+1} &= \mathbf{A}\vec{x}_k + \vec{w}_k \\ \vec{y}_k &= \mathbf{C}\vec{x}_k + \vec{z}_k\end{aligned}\quad (3.25)$$

Dessa forma, os dados de entrada são modelados implicitamente como ruído branco gaussiano. Caso essa suposição seja descumprida e os dados de entrada possuam componentes de frequência dominante, aparecerão espúrios na matriz de estado \mathbf{A} que irão aparecer nas frequências obtidas pelos seus autovalores.

Outras propriedades importantes do modelo estocástico são determinadas por Van Overschee e De Moor (1996). Presume-se que o processo estocástico é estacionário com média zero (equação 3.26).

$$\mathbf{E}\left[\begin{pmatrix} \vec{x}_k & \vec{x}_k^T \end{pmatrix}\right] = \mathbf{\Sigma}, \quad \mathbf{E}\left[\vec{x}_k\right] = 0\quad (3.26)$$

Onde $\mathbf{\Sigma}$ é a matriz de covariância dos estados, independentemente do tempo k .

Além disso, como \vec{w}_k e \vec{z}_k possuem média zero independente do estado atual, a correlação entre \vec{x}_k e esses termos de ruído é nula (equação 3.27).

$$\begin{aligned} \mathbf{E} \begin{bmatrix} \vec{x}_k & \vec{w}_k^T \end{bmatrix} &= 0 \\ \mathbf{E} \begin{bmatrix} \vec{x}_k & \vec{z}_k^T \end{bmatrix} &= 0 \end{aligned} \quad (3.27)$$

A matriz de covariância das respostas $\mathbf{R}_i \in \mathbb{R}^{l \times l}$ é definida pela equação 3.28, para um atraso arbitrário de tempo i .

$$\mathbf{R}_i = \mathbf{E} \begin{bmatrix} \vec{y}_{k+i} & \vec{y}_k^T \end{bmatrix} \quad (3.28)$$

Enquanto a matriz de covariâncias do estado no instante $k+1$ e da saída no instante k (*next state-output*) $\mathbf{G} \in \mathbb{R}^{n \times l}$ é dada pela equação 3.29.

$$\mathbf{G} = \mathbf{E} \begin{bmatrix} \vec{x}_{k+i} & \vec{y}_k^T \end{bmatrix} \quad (3.29)$$

A partir das definições citadas, Van Overschee e De Moor (1996) deduzem as propriedades das equações 3.30 e 3.31.

$$\begin{aligned} \mathbf{\Sigma} &= \mathbf{A}\mathbf{\Sigma}\mathbf{A}^T + \mathbf{Q} \\ \mathbf{R}_0 &= \mathbf{C}\mathbf{\Sigma}\mathbf{C}^T + \mathbf{R} \\ \mathbf{G} &= \mathbf{A}\mathbf{\Sigma}\mathbf{C}^T + \mathbf{S} \end{aligned} \quad (3.30)$$

$$\begin{aligned} \mathbf{R}_i &= \mathbf{C}\mathbf{A}^{i-1}\mathbf{G} \\ \mathbf{R}_{-i} &= \mathbf{G}^T (\mathbf{A}^{i-1})^T \mathbf{C}^T \\ i &= 1, 2, \dots \end{aligned} \quad (3.31)$$

As propriedades da equação 3.31 são fundamentais para identificação estocástica de sistemas. Como é mostrado, a sequência das covariâncias de resposta pode ser estimada a partir dos dados das medições. Desse modo, as matrizes de estado podem ser encontradas a partir da decomposição dessas sequências.

4 MÉTODO DE IDENTIFICAÇÃO ESTOCÁSTICA DE SUBESPAÇO

Com base no modelo estocástico no espaço de estado em tempo discreto, desenvolveu-se o Método de Identificação Estocástica de Subespaços baseado nas séries temporais (*Data-driven Stochastic Subspace Identification* – SSI-DATA). Segundo Van Overschee e De Moor (1996), o termo “subespaço” é utilizado devido o modelo ser gerado por meio de espaços linha e coluna de certas matrizes, que são obtidas através de dados de entrada e saída do sistema. Assim, o espaço coluna dessas matrizes possui informações sobre o modelo, enquanto o espaço linha possibilita a criação de uma sequência de estado.

Esse método busca cancelar ruídos não correlacionados usando o problema de realização estocástica. Para isso, as saídas do sistema são divididas e classificadas como saídas de referências passadas e saídas futuras. Todas essas respostas são organizadas em uma matriz bloco Hankel, sendo projetadas as linhas das saídas futuras nas linhas das saídas passadas, a fim de reter toda informação do passado que será útil para prever o futuro.

A descrição do SSI-DATA apresentada nesse capítulo foi proposta por Peeters (2000), que adaptou o método original de Van Overschee e De Moor (1996) com o conceito de sensores de referência. Segundo o autor, o uso de muitos sensores pode causar redundância de informações. Em teoria, todos os sinais carregam a mesma informação modal, desde que esses sensores não sejam colocados nos nós de uma forma modal. Por isso, ao incluir sensores de referência nessa análise, as matrizes utilizadas pelo método são reduzidas permitindo uma maior agilidade computacional com a mesma precisão do método de identificação.

4.1 DADOS EXPERIMENTAIS

Para a aplicação de um método estocástico de identificação de sistemas, requer-se que as respostas da estrutura estejam na forma do vetor discreto \vec{y}_k . As l saídas são divididas em um subconjunto de r sensores de referência e um subconjunto dos outros $l-r$ sensores, conforme a equação 4.1.

$$\vec{y}_k = \begin{bmatrix} \vec{y}_k^{ref} \\ \vec{y}_k \end{bmatrix}, \quad \vec{y}_k^{ref} = \mathbf{L} \vec{y}_k, \quad \mathbf{L} = [\mathbf{I}_r \quad \mathbf{0}] \quad (4.1)$$

Onde $\vec{y}_k^{ref} \in \mathbb{R}^r$ é o vetor das saídas de referência, $\vec{y}_k^{\sim} \in \mathbb{R}^{l-r}$ é o vetor com as demais saídas, e $\mathbf{L} \in \mathbb{R}^{r \times l}$ é a matriz de seleção das referências. Destaca-se que a escolha dos sensores de referência pode impactar na qualidade dos resultados.

Essas respostas medidas experimentalmente devem ser ordenadas em uma matriz bloco Hankel (matriz cujos elementos da antidiagonal são iguais) composta por $2i$ linhas e N colunas, sendo que cada uma das primeiras i linhas blocos possuem r linhas, enquanto as últimas i linhas bloco possuem l linhas. Além disso, como mostrado na equação 4.2, a matriz Hankel $\mathbf{H}^{ref} \in \mathbb{R}^{(r+l) \times N}$ pode ser dividida em saídas passadas (\mathbf{Y}_p^{ref}) e saídas futuras (\mathbf{Y}_f).

$$\mathbf{H}^{ref} = \frac{1}{\sqrt{N}} \begin{bmatrix} \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_0 & y_1 & \cdots & y_{N-1} \end{matrix} \\ \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_1 & y_2 & \cdots & y_N \end{matrix} \\ \vdots \\ \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_{i-1} & y_i & \cdots & y_{i+N-2} \end{matrix} \\ \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_i & y_{i+1} & \cdots & y_{i+N-1} \end{matrix} \\ \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_{i+1} & y_{i+2} & \cdots & y_{i+N} \end{matrix} \\ \vdots \\ \begin{matrix} \rightarrow ref & \rightarrow ref & \cdots & \rightarrow ref \\ y_{2i-1} & y_{2i} & \cdots & y_{2i+N-2} \end{matrix} \end{bmatrix} = \begin{bmatrix} \mathbf{Y}_{0i-1}^{ref} \\ \mathbf{Y}_{i2i-1}^{ref} \end{bmatrix} = \begin{bmatrix} \mathbf{Y}_p^{ref} \\ \mathbf{Y}_f \end{bmatrix} \begin{matrix} \updownarrow ri \\ \updownarrow li \end{matrix} \quad (4.2)$$

Onde i é um índice arbitrário associado com o número de atrasos no tempo em que as funções de covariância são estimadas, e N é igual ao número de colunas da matriz. Buscando utilizar todas as s amostras das respostas no tempo, considera-se $N = s - 2i + l$. Do ponto de vista estatístico do método, assume-se que $N, s \rightarrow \infty$.

Outra possível divisão da matriz \mathbf{H}^{ref} é obtida adicionando uma linha bloco nas saídas passadas de referência e omitindo a primeira linha bloco das saídas futuras. Como as referências são apenas um subconjunto das saídas, sobram $l-r$ linhas nessa nova divisão. Essas linhas são representadas por \mathbf{Y}_{ii}^{-ref} na equação 4.3.

$$\mathbf{H}^{ref} = \begin{bmatrix} \mathbf{Y}_{0i}^{ref} \\ \mathbf{Y}_{ii}^{ref} \\ \mathbf{Y}_{i+12i-1} \end{bmatrix} = \begin{bmatrix} \mathbf{Y}_p^{ref+} \\ \mathbf{Y}_{ii}^{-ref} \\ \mathbf{Y}_f^- \end{bmatrix} \begin{matrix} \updownarrow r(i+1) \\ \updownarrow l-r \\ \updownarrow l(i-1) \end{matrix} \quad (4.3)$$

4.2 FILTRO KALMAN

O filtro Kalman é um conceito fundamental do SSI-DATA, pois as matrizes do sistema são estimadas através da sua avaliação da sequência de estado. Esse filtro é uma técnica de estimação recursiva, ou seja, os dados conhecidos são utilizados para atualizar os parâmetros de um modelo buscando aproximar-se dos valores reais. Assim, o uso do filtro Kalman tem como objetivo fornecer uma previsão ótima do vetor de estado \vec{x}_k por meio do uso de observações das saídas anteriores no tempo e das matrizes disponíveis do sistema em conjunto com as covariâncias conhecidas de ruído. Essas previsões ótimas são representadas por \hat{x}_{k+1} .

Dado o estado inicial estimado $\hat{x}_0 = 0$, a covariância inicial do modelo de estado $\mathbf{P}_0 = E[\hat{x}_0 \hat{x}_0^T] = 0$ e as saídas medidas y_0, \dots, y_{k-1} , o estado estimado \hat{x}_k é definido pelas formulações recursivas da equação 4.4.

$$\begin{aligned} \hat{x}_k &= \mathbf{A}\hat{x}_{k-1} + \mathbf{K}_{k-1}(\bar{y}_{k-1} - \mathbf{C}\hat{x}_{k-1}) \\ \mathbf{K}_{k-1} &= (\mathbf{G} - \mathbf{A}\mathbf{P}_{k-1}\mathbf{C}^T)(\mathbf{R}_0 - \mathbf{C}\mathbf{P}_{k-1}\mathbf{C}^T)^{-1} \\ \mathbf{P}_k &= \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + (\mathbf{G} - \mathbf{A}\mathbf{P}_{k-1}\mathbf{C}^T)(\mathbf{R}_0 - \mathbf{C}\mathbf{P}_{k-1}\mathbf{C}^T)^{-1}(\mathbf{G} - \mathbf{A}\mathbf{P}_{k-1}\mathbf{C}^T)^T \end{aligned} \quad (4.4)$$

Onde \mathbf{K}_{k-1} é a matriz de ganho do filtro Kalman e \mathbf{P}_k é a matriz de covariância de estado.

Assim, a matriz da sequência de estado do filtro Kalman $\hat{\mathbf{X}}_i \in \mathbb{R}^{n \times N}$ é definida pela equação 4.5.

$$\hat{\mathbf{X}}_i = \begin{bmatrix} \hat{x}_i & \hat{x}_{i+1} & \cdots & \hat{x}_{i+N-1} \end{bmatrix} \quad (4.5)$$

4.3 TEORIA DO SSI-DATA

O Método de Identificação Estocástica de Subespaços baseado nas séries temporais tem como primeira etapa a projeção do bloco de linhas das saídas futuras no espaço das saídas de referência passadas. Desse modo, toda informação passada que seja útil para prever o futuro é retida. A notação e definição dessa projeção é mostrada na equação 4.6.

$$\mathbf{P}_i^{ref} = \mathbf{Y}_f / \mathbf{Y}_p^{ref} = \mathbf{Y}_f (\mathbf{Y}_p^{ref})^T \left(\mathbf{Y}_p^{ref} (\mathbf{Y}_p^{ref})^T \right)^{\dagger} \mathbf{Y}_p^{ref} \quad (4.6)$$

Como apresentado na equação 4.2, as matrizes $\mathbf{Y}_f \in \mathbb{R}^{li \times N}$ e $\mathbf{Y}_p^{ref} \in \mathbb{R}^{ri \times N}$ são partições da matriz Hankel e $(\cdot)^\dagger$ representa a pseudo-inversa (Moore-Penrose) de uma matriz. Porém, destaca-se que a definição dada pela equação 4.6 não indica a forma de cálculo de \mathbf{P}_i^{ref} . Essa projeção é calculada por meio de um algoritmo de decomposição QR, conforme é apresentado no próximo subtópico.

Segundo Van Overschee e De Moor (1996), o principal teorema da identificação estocástica de subespaços afirma que a projeção \mathbf{P}_i^{ref} pode ser fatorizada no produto da matriz de observabilidade estendida \mathbf{O}_i e da sequência de estado do filtro Kalman $\hat{\mathbf{X}}_i$ (equação 4.7).

$$\mathbf{P}_i^{ref} = \mathbf{O}_i \hat{\mathbf{X}}_i \quad (4.7)$$

Buscando separar o ruído das informações necessárias para determinar os parâmetros modais, aplica-se a decomposição em valores singulares (SVD). Assim, os valores nulos e seus vetores singulares correspondentes são omitidos, de acordo com a equação 4.8.

$$\mathbf{P}_i^{ref} = \mathbf{U}_1 \mathbf{S}_1 \mathbf{V}_1^T \quad (4.8)$$

Então, as matrizes \mathbf{O}_i e $\hat{\mathbf{X}}_i$ são obtidas a partir de $\mathbf{U}_1 \in \mathbb{R}^{li \times n}$, $\mathbf{S}_1 \in \mathbb{R}^{n \times n}$ e $\mathbf{V}_1 \in \mathbb{R}^{N \times n}$, conforme a equação 4.9.

$$\begin{aligned} \mathbf{O}_i &= \mathbf{U}_1 \mathbf{S}_1^{1/2} \\ \hat{\mathbf{X}}_i &= \mathbf{O}_i^\dagger \mathbf{P}_i^{ref} \end{aligned} \quad (4.9)$$

Ressalta-se que existem variantes do método SSI-DATA pela multiplicação da projeção \mathbf{P}_i^{ref} por duas matrizes pesos \mathbf{W}_1 e \mathbf{W}_2 (equação 4.10). Nessas variantes, cada algoritmo fornece matrizes numericamente diferentes, porém as matrizes finais do sistema são equivalentes entre si. A versão componente principal não-ponderado (*unweighted principal component – UPC*) é utilizada nesse trabalho, ou seja, antes do processo de decomposição adota-se pesos unitários.

$$\mathbf{W}_1 \mathbf{P}_i^{ref} \mathbf{W}_2 = [\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \mathbf{S}_1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^T \\ \mathbf{V}_2^T \end{bmatrix} = \mathbf{U}_1 \mathbf{S}_1 \mathbf{V}_1^T \quad (4.10)$$

Caso a separação entre as saídas futuras e saídas passadas de referência seja feita como mostrado na equação 4.3, a projeção é definida pela equação 4.11.

$$\mathbf{P}_{i-1}^{ref} = \mathbf{Y}_f^- / \mathbf{Y}_p^{ref+} = \mathbf{O}_{i-1} \hat{\mathbf{X}}_{i+1} \quad (4.11)$$

Dessa forma, a matriz de observabilidade \mathbf{O}_{i-1} é obtida removendo-se as últimas l linhas da matriz \mathbf{O}_i , e a equação 4.12 mostra o cálculo da sequência de estado $\hat{\mathbf{X}}_{i+1}$.

$$\hat{\mathbf{X}}_{i+1} = \mathbf{O}_{i-1}^\dagger \mathbf{P}_{i-1}^{ref} \quad (4.12)$$

Por fim, as matrizes do sistema \mathbf{A} e \mathbf{C} são calculadas pelo conjunto de equações lineares que são obtidas pelo empilhamento dos modelos de espaço de estados para instantes de tempo i a $i + N - 1$, como mostra a equação 4.13.

$$\begin{bmatrix} \mathbf{A} \\ \mathbf{C} \end{bmatrix} = \begin{bmatrix} \hat{\mathbf{X}}_{i+1} \\ \mathbf{Y}_{ii} \end{bmatrix} \hat{\mathbf{X}}_i^\dagger \quad (4.13)$$

Onde $\mathbf{Y}_{ii} \in \mathbb{R}^{l \times N}$ é uma matriz Hankel com apenas um bloco (equação 4.2).

4.4 ALGORITMO E IMPLEMENTAÇÃO

A implementação computacional do algoritmo do SSI-DATA baseia-se na fatoração RQ da matriz Hankel. Como mostra a equação 4.14, \mathbf{H}^{ref} é escrita pela matriz triangular inferior $\mathbf{R} \in \mathbb{R}^{(r+l) \times N}$ e a matriz ortogonal $\mathbf{Q} \in \mathbb{R}^{N \times N}$.

$$\mathbf{H}^{ref} = \mathbf{RQ}^T = \begin{array}{c} ri \\ r \\ l-r \\ l(i-1) \end{array} \begin{array}{c} \Downarrow \\ \Downarrow \\ \Downarrow \\ \Downarrow \end{array} \begin{array}{ccccc} ri & r & l-r & l(i-1) & N \\ \leftrightarrow & \leftrightarrow & \leftrightarrow & \leftrightarrow & \leftrightarrow \\ \left[\begin{array}{cccc} \mathbf{R}_{11} & 0 & 0 & 0 \\ \mathbf{R}_{21} & \mathbf{R}_{22} & 0 & 0 \\ \mathbf{R}_{31} & \mathbf{R}_{32} & \mathbf{R}_{33} & 0 \\ \mathbf{R}_{41} & \mathbf{R}_{42} & \mathbf{R}_{43} & \mathbf{R}_{44} \end{array} \right] & \left[\begin{array}{c} \mathbf{Q}_1^T \\ \mathbf{Q}_2^T \\ \mathbf{Q}_3^T \\ \mathbf{Q}_4^T \end{array} \right] \begin{array}{c} \Downarrow \\ \Downarrow \\ \Downarrow \\ \Downarrow \end{array} \end{array} \begin{array}{c} ri \\ r \\ l-r \\ l(i-1) \end{array} \quad (4.14)$$

Assim, a projeção \mathbf{P}_i^{ref} pode ser definida em termos de \mathbf{R} e \mathbf{Q} , de acordo com a equação 4.15.

$$\mathbf{P}_i^{ref} = \mathbf{Y}_f / \mathbf{Y}_p^{ref} = \begin{bmatrix} \mathbf{R}_{21} \\ \mathbf{R}_{31} \\ \mathbf{R}_{41} \end{bmatrix} \mathbf{Q}_1^T \quad (4.15)$$

Em seguida, aplica-se a decomposição em valores singulares em \mathbf{P}_i^{ref} , conforme a equação 4.16.

$$\mathbf{P}_i^{ref} = [\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \mathbf{S}_1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^T \\ \mathbf{V}_2^T \end{bmatrix} = \mathbf{U}_1 \mathbf{S}_1 \mathbf{V}_1^T \quad (4.16)$$

Então, as matrizes \mathbf{U}_1 e \mathbf{S}_1 são utilizadas para obtenção da matriz de observabilidade (equação 4.17).

$$\mathbf{O}_i = \mathbf{U}_1 \mathbf{S}_1^{1/2} \quad (4.17)$$

Por meio do algoritmo 2 de Fadel Miguel (2007), a matriz de estado \mathbf{A} e a matriz de saída \mathbf{C} são calculadas. Para essa operação, o autor define a matriz $\underline{\mathbf{O}}_i = \mathbf{O}_{i-1}$ e a matriz $\overline{\mathbf{O}}_i$, que é obtida descartando-se as primeiras l linhas de \mathbf{O}_i . Desse modo, \mathbf{A} é obtida pela equação 4.18 e \mathbf{C} é a matriz resultante das primeiras l linhas de \mathbf{O}_i .

$$\mathbf{A} = \underline{\mathbf{O}}_i \dagger \overline{\mathbf{O}}_i \quad (4.18)$$

Com a identificação dessas duas matrizes do sistema, realiza-se a análise modal para obtenção dos parâmetros modais da estrutura (frequências naturais, razões de amortecimento e formas modais), de acordo com as equações 3.19 a 3.22.

4.5 DIAGRAMA DE ESTABILIZAÇÃO

Devido à presença de ruído em diversas etapas da identificação de sistemas (imprecisões da modelagem, ruído nas medições e erros computacionais), os valores singulares na projeção \mathbf{P}_i^{ref} (equação 4.8) não são realmente zero. Por isso, deve-se distinguir entre os resultados quais são os modos físicos da estrutura.

O diagrama de estabilização, exemplificado pela Figura 4.1, surge como ferramenta para comparar os valores estimados para diferentes ordens do modelo. Cada propriedade modal de uma ordem $n + 1$ é analisada em função dos valores obtidos no modelo de ordem inferior n . Se o erro relativo entre frequência, amortecimento e forma modal correspondentes a um mesmo modo não supera os limites pré-estabelecidos, considera-se que aquele é um polo estável e é um modo do sistema.

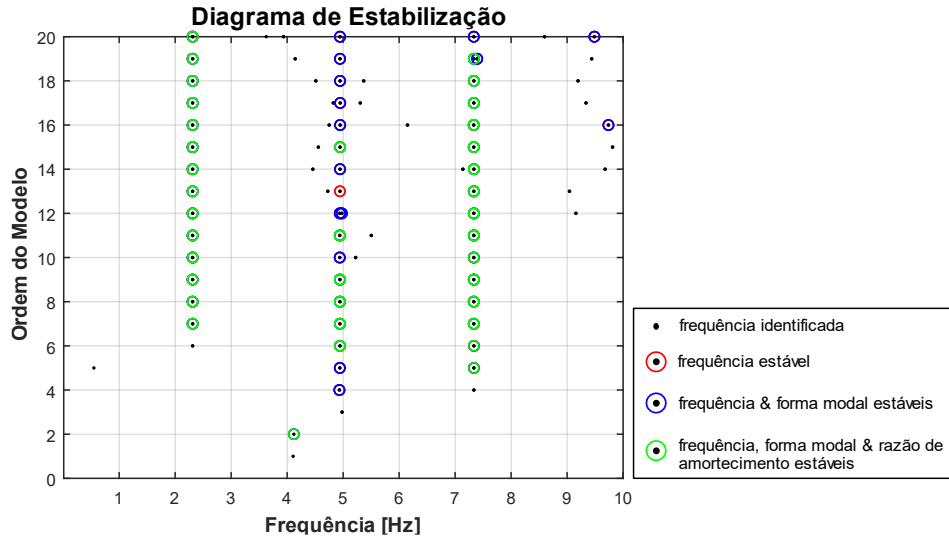


Figura 4.1 – Exemplo de Diagrama de Estabilização

Nesse trabalho escolheu-se como limites de erro relativo: 1% para as frequências naturais, 5% para as razões de amortecimento e 10% para as formas modais. Diante disso, um polo estável do sistema requer as condições expostas na equação 4.19.

$$\begin{aligned} \frac{|f^{(n)} - f^{(n+1)}|}{f^{(n)}} &< 1\% \\ \frac{|\xi^{(n)} - \xi^{(n+1)}|}{\xi^{(n)}} &< 5\% \\ 1 - \text{MAC}(n, n+1) &< 10\% \end{aligned} \quad (4.19)$$

Onde MAC é o Critério de Concordância Modal, proposto por Allemang e Brown (1982), que é calculado pelas formas modais ψ_i e ψ_j , de acordo com a equação 4.20.

$$\text{MAC}(i, j) = \frac{\left| \begin{matrix} \overrightarrow{\psi}_i^T & \overrightarrow{\psi}_j \end{matrix} \right|^2}{\left(\begin{matrix} \overrightarrow{\psi}_i^T & \overrightarrow{\psi}_i \end{matrix} \right) \left(\begin{matrix} \overrightarrow{\psi}_j^T & \overrightarrow{\psi}_j \end{matrix} \right)} \quad (4.20)$$

Vale ressaltar que a ordem máxima do modelo (n_{max}) está sujeita a condição $ri \geq n_{max}$. Caso esse critério não seja atendido, não será possível calcular diferentes números de valores e vetores singulares da matriz de projeção \mathbf{P}_i^{ref} para determinar a matriz de observabilidade \mathbf{O}_i .

5 MONITORAMENTO DA INTEGRIDADE ESTRUTURAL

A detecção de dano em estruturas pelo Monitoramento da Integridade Estrutural depende da comparação de dois estados diferentes. Inicialmente, na fase de projeto e construção, deve-se prever um sistema de monitoramento com sensores (de deslocamento, de velocidade ou de aceleração) e sistema de aquisição de dados. Com a obra finalizada e a estrutura em funcionamento, as propriedades modais do sistema são adquiridas no cenário íntegro a partir do conjunto de dados obtidos pelo monitoramento. Ao longo do tempo, essas propriedades modais são determinadas periodicamente para o acompanhamento de possíveis alterações. A Figura 5.1 representa esquematicamente o processo de SHM.

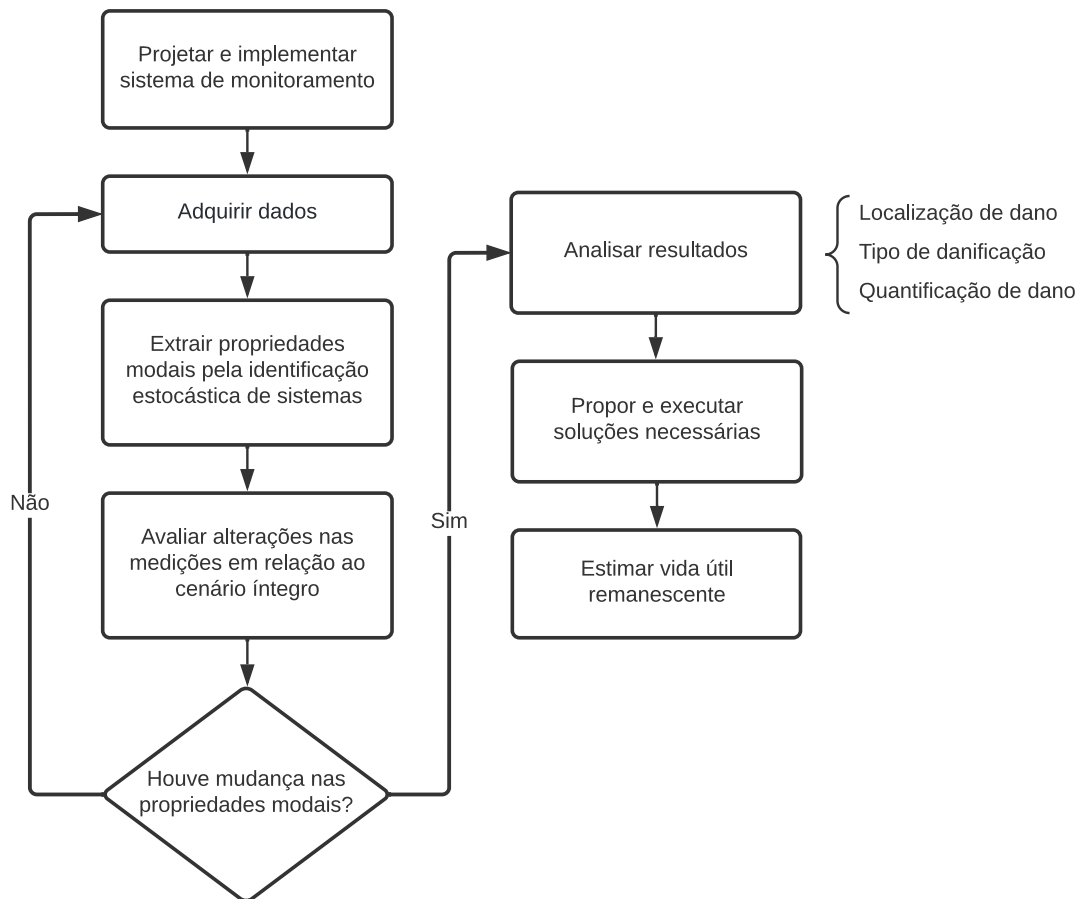


Figura 5.1 – Metodologia do Monitoramento de Integridade Estrutural

Salienta-se que pequenas mudanças nas características dinâmicas do sistema podem não representar um cenário danificado. Visto que variações ambientais (como temperatura e umidade) causam oscilações nessas propriedades, é necessário a escolha de um ou mais métodos de detecção de dano para avaliação estrutural.

Nesse trabalho, aplicaram-se métodos baseados na atualização de matrizes do sistema e em redes neurais, sendo as respectivas metodologias detalhadas nos tópicos a seguir. Ambos os métodos empregados buscaram atingir o nível 3 de quantificação de dano visando superar as limitações encontradas na literatura.

5.1 DETECÇÃO DE DANO COM BASE NA ATUALIZAÇÃO DE MATRIZES

Os métodos de detecção de dano com base na atualização de matrizes resolvem um problema de otimização, em que a função objetivo depende da variação das propriedades modais. Para isso, requer-se um modelo em elementos finitos compatível com a estrutura analisada, a fim de se ter um objeto de comparação com os dados obtidos experimentalmente. Essa comparação busca minimizar as diferenças entre os parâmetros identificados pela estrutura real com os parâmetros do modelo.

Com o objetivo de localizar e quantificar cenários danificados, o dano foi tratado como uma alteração nos valores de rigidez. Isso foi feito por meio da consideração de um coeficiente de redução de rigidez α_j que varia entre 0 e 1, onde 1 significa que não há dano e 0 significa a perda completa de rigidez daquele elemento j . Dessa forma, α_j atua sobre cada matriz de rigidez elementar \mathbf{k}_j para todos os N_e elementos da estrutura, conforme equação 5.1.

$$\mathbf{K} = \sum_{j=1}^{N_e} \alpha_j \mathbf{k}_j \quad (5.1)$$

Então, o dano estrutural é estimado através da atualização do modelo numérico no qual são introduzidas variações em todos os coeficientes α_j . Esse modelo é modificado continuamente até que a diferença com os resultados experimentais seja minimizada. Portanto, o problema a ser solucionado é um problema de minimização definido pela equação 5.2.

$$\begin{aligned} & \text{Encontrar } \alpha \\ & 0 > \alpha \geq 1 \\ & \text{Min } \Pi(\alpha) = |E - A(\alpha)|^2 \end{aligned} \quad (5.2)$$

Sendo $\Pi(\alpha)$ a função objetivo dependente do coeficiente de redução de rigidez, E as características modais experimentais, e $A(\alpha)$ as características modais analíticas calculadas a partir do modelo numérico da estrutura em função do coeficiente α .

Escolheu-se como função objetivo a equação 5.3, utilizada por Fadel Miguel *et al.* (2012). Essa equação se baseia nas frequências naturais e formas modais obtidas analítica e experimentalmente, e vem sendo usada em diversos trabalhos (ZENI, 2018; FADEL MIGUEL *et al.*, 2013), provando-se robusta na localização e quantificação de dano.

$$\Pi(\alpha) = \sum_{j=1}^{Nm} \left[\left(\frac{\delta\omega_j(\alpha)}{\omega_j} \right)^a - \left(\frac{\delta\omega_j}{\omega_j} \right)^e \right]^2 + \sum_{j=1}^{Nm} \sum_{k=1}^{Nn} \left[\left(\delta\psi_{kj}(\alpha) \right)^a - \left(\delta\psi_{kj} \right)^e \right]^2 \quad (5.3)$$

Onde Nm é o número de modos analisados, Nn é o número de deslocamentos nodais, os sobrescritos a e e representam os termos relativos aos dados analíticos e experimentais, ω_j e ψ_{kj} são a frequência natural e a forma modal do modo j , e $\delta\psi_{kj}$ e $\delta\omega_j$ são as variações fracionárias das frequências naturais e formas modais do modo j .

Para resolver o problema de minimização nesse trabalho, empregou-se um algoritmo Metaheurístico. Apesar de métodos baseados em gradientes serem mais rápidos, eles não são aplicáveis em funções objetivo que não são continuamente diferenciáveis. Assim, foi escolhido o Algoritmo de Otimização da Baleia, que é descrito no subtópico abaixo.

5.1.1 Algoritmo de Otimização de Baleia

O Algoritmo de Otimização da Baleia (*Whale Optimization Algorithm – WOA*) foi desenvolvido por Mirjalili e Lewis em 2016. O WOA é um algoritmo de otimização metaheurístico que imita o comportamento de caça das baleias jubarte. Esse comportamento é simulado com um agente aleatório ou com o melhor agente da rodada na perseguição da presa. Além disso, utiliza-se uma espiral para simular o mecanismo de ataque de rede de bolhas das baleias, como apresentado na Figura 5.2.



Figura 5.2 – Comportamento das baleias jubarte em redes de bolhas (Mirjalili e Lewis, 2016)

Esse algoritmo assume que a atual melhor solução candidata é a presa alvo ou está próxima da solução ótima. Depois que o agente de busca ótimo é definido, os outros agentes terão suas posições atualizadas em direção ao agente ótimo. Esse procedimento é representado pela equação 5.4.

$$\begin{aligned}\overline{D} &= \left| \overline{C} \cdot \overline{X}^*(t) - \overline{X}(t) \right| \\ \overline{X}(t+1) &= \overline{X}^*(t) - \overline{A} \cdot \overline{D}\end{aligned}\tag{5.4}$$

Onde t indica a atual iteração, \overline{A} e \overline{C} são vetores de coeficiente, \overline{X}^* é o vetor de posição da melhor solução obtida, \overline{X} é o vetor de posição e “.” é a operação de multiplicação de elemento por elemento. Destaca-se que \overline{X}^* deve ser atualizado em cada iteração, caso haja uma melhor solução.

Os vetores \overline{A} e \overline{C} são calculados pela equação 5.5, a partir do vetor \overline{a} , que diminui de 2 a 0 ao longo das iterações, e do vetor \overline{r} , que é um vetor aleatório em $[0,1]$.

$$\begin{aligned}\overline{A} &= 2\overline{a} \cdot \overline{r} - \overline{a} \\ \overline{C} &= 2\overline{r}\end{aligned}\tag{5.5}$$

O ataque de rede de bolhas das baleias é alcançado por dois procedimentos. O primeiro é o mecanismo de encolhimento, que é gerado pela diminuição do valor de \overline{a} ao longo das iterações. O segundo é a atualização de posição em espiral, em que se calcula a distância entre a baleia em (X, Y) e a presa em (X^*, Y^*) , considerando uma função bidimensional. Então, utiliza-se a equação 5.6 para imitar o movimento em formato de hélice das baleias.

$$\begin{aligned}\overline{X}(t+1) &= \overline{D}' e^{bl} \cos(2\pi l) + \overline{X}^*(t) \\ \overline{D}' &= \left| \overline{X}^*(t) - \overline{X}(t) \right|\end{aligned}\tag{5.6}$$

Onde b é uma constante para definir o formato da espiral logarítmica e l é um número aleatório em $[-1,1]$.

Destaca-se que as baleias nadam simultaneamente ao redor da presa dentro de um círculo de encolhimento e ao longo de um caminho de forma espiral. Para modelar esse comportamento, os autores assumiram a probabilidade de 50% para escolha de um dos dois caminhos para atualizar a posição das baleias no processo de otimização. Isso é apresentado na equação 5.7, em que p é um número aleatório em $[0,1]$.

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A}\vec{D} & \text{se } p < 0,5 \\ \vec{D}e^{bl} \cos(2\pi l) + \vec{X}^*(t) & \text{se } p \geq 0,5 \end{cases} \quad (5.7)$$

A busca pela presa também é feita pela abordagem de variação do vetor \vec{A} . Buscando fazer as baleias caçarem aleatoriamente de acordo com suas posições, usa-se \vec{A} com valores superiores a 1 ou inferiores a -1, o que força o agente de busca distanciar-se da baleira de referência. Em outras palavras, diferente do ataque de rede de bolhas, a posição dos agentes na busca pela presa é atualizada de forma aleatória ao invés de utilizar o agente ótimo. Matematicamente, essa etapa é modelada pela equação 5.8, onde \vec{X}_{rand} é o vetor de posição aleatória escolhido da população de baleias.

$$\begin{aligned} \vec{D} &= \left| \vec{C}\vec{X}_{rand} - \vec{X} \right| \\ \vec{X}(t+1) &= \vec{X}_{rand} - \vec{A}\vec{D} \end{aligned} \quad (5.8)$$

Em suma, o WOA é resumido pelo pseudocódigo apresentado na Figura 5.3.

```

Inicialize a população de baleias  $X_i$  ( $i = 1, 2, \dots, n$ )
Calcule a aptidão de cada agente de busca
 $X^*$  = melhor agente de busca
Enquanto ( $t < \text{número máximo de iterações}$ )
  Para cada agente de busca
    Atualize  $a$ ,  $A$ ,  $C$ ,  $l$ , e  $p$ 
    Se 1 ( $p < 0,5$ )
      Se 2 ( $|A| < 1$ )
        Atualize a posição do agente de busca atual
      Senão 2 ( $|A| \geq 1$ )
        Selecione um agente de busca aleatório  $X_{rand}$ 
        Atualize a posição do atual agente de busca
      Fim se 2
    Senão 1 ( $p \geq 0,5$ )
      Atualize a posição do atual agente de busca
    Fim se 1
  Fim para
  Confira se algum agente de busca vai além do espaço de busca e altere
  Calcule a aptidão de cada agente de busca
  Atualize  $X^*$  se houver uma melhor solução
   $t = t + 1$ 
Fim enquanto
Retorne  $X^*$ 

```

Figura 5.3 – Pseudocódigo do Algoritmo de Otimização da Baleia (Mirjalili e Lewis, 2016)

5.2 DETECÇÃO DE DANO COM BASE EM REDES NEURAIS

Os métodos de detecção de dano com base em redes neurais constroem um modelo que fornece uma relação entre os parâmetros modais (dados de entrada) e as propriedades estruturais (dados de saída). Essa relação entre os dados de um sistema é determinada através de uma fase de treinamento inspirada na estrutura e operação do cérebro humano. Dessa forma, as Redes Neurais Artificiais (*Artificial Neural Network – ANN*) tentam reproduzir comportamentos humanos de aprendizado, associação, generalização e abstração. Isso ocorre através de elementos processadores (neurônios artificiais) interconectados que efetuam operações simples e transmitem seus resultados para os indivíduos vizinhos.

Um neurônio artificial j possui um conjunto de entradas S_i (dendritos) e uma saída S_j (axônio). As conexões (sinapses) formadas entre os neurônios possuem valores numéricos que representam a força de cada vínculo. Esses valores são chamados de pesos sinápticos (ω_{ij}) e são utilizados para armazenar o conhecimento. Com a formação da rede neural, diferentes dados de entrada são aplicados sobre cada neurônio, sendo esses valores ponderados pelo peso de cada sinapse, conforme apresenta a Figura 5.4.




Figura 5.4 – Modelo de um neurônio artificial

Caso a atividade de um neurônio atinja um determinado valor da função de ativação f , o neurônio propaga pelo axônio o sinal recebido. O estado de ativação é definido pelo somatório das m entradas ponderadas pelos respectivos pesos sinápticos somando-se um termo de polarização θ_j (*bias*), de acordo com a equação 5.9.

$$S_j = f \left(\sum_{i=1}^m S_i \omega_{ij} + \theta_j \right) \quad (5.9)$$

Destaca-se que a função de ativação pode ter vários formatos, tais como: a função sigmoide, função linear e a função degrau unitário. Essas três funções são genericamente representadas na Figura 5.5.




Figura 5.5 – Exemplos de funções de ativação

Cada rede neural artificial pode assumir uma arquitetura diferente de acordo com a forma que os neurônios se organizam. A distribuição dos elementos processadores ocorre em camadas, consistindo em uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas (Figura 5.6). Os neurônios na camada de entrada estão conectados às entradas globais da rede, enquanto os neurônios de saída geram as informações ao ambiente externo. Já os neurônios nas camadas ocultas vão estar conectados somente a outros neurônios. Assim, a arquitetura de uma rede neural é formada pela quantidade de camadas existentes e a quantidade de elementos em cada uma delas.

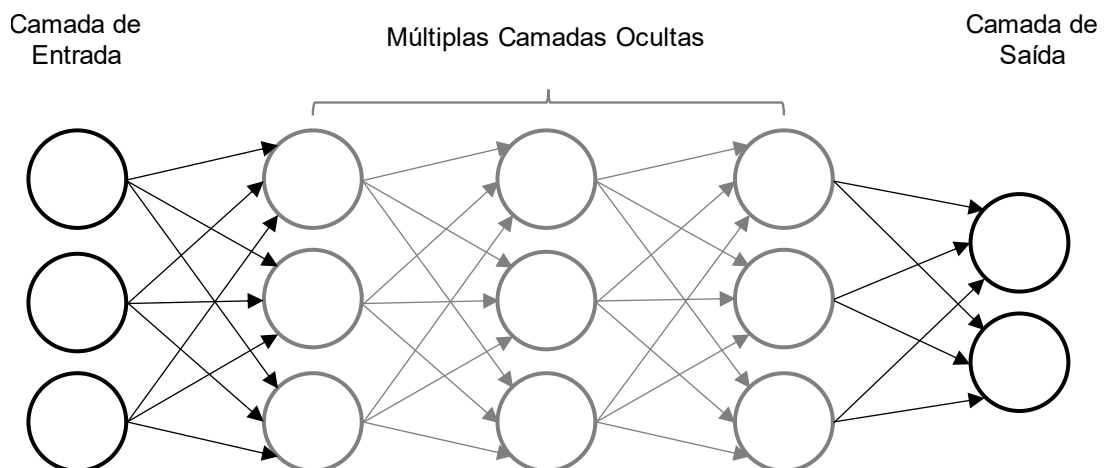


Figura 5.6 – Exemplo de arquitetura de uma rede neural

O funcionamento das redes neurais artificiais é dividido nas etapas de recuperação da informação (*recall*) e de aprendizado (*learning*). Na fase de recuperação de informação, as saídas da rede são calculadas de acordo com as entradas fornecidas. Já na fase de aprendizado, os pesos sinápticos são atualizados para a aquisição do conhecimento.

O processo de aprendizado pode ser dividido por dois algoritmos: o aprendizado supervisionado (*supervised learning*) e o aprendizado não supervisionado (*unsupervised learning*). O algoritmo de aprendizado é considerado supervisionado quando o treinamento gera seus resultados por rótulos verdadeiros de cada conjunto, ou seja, há uma resposta correta. Porém, quando os dados de entrada não vêm com rótulos pré-estabelecidos o algoritmo é chamado de não supervisionado. Enquanto o aprendizado supervisionado aplicado na detecção de dano requer dados de todos os cenários danificados possíveis, o aprendizado não supervisionado necessita apenas dos dados da condição normal do sistema (cenário íntegro). Porém, segundo Farrar e Worden (2012), não é possível diagnosticar cenários de dano além do nível 2 (localização) no aprendizado não supervisionado. Por isso, nesse trabalho, utilizou-se o aprendizado supervisionado.

Os dados de entrada para o aprendizado das redes neurais podem ser obtidos por meio de dados experimentais de sistemas similares e/ou de modelos numéricos da estrutura em questão. Então, esse conjunto é utilizado para classificar a informação de dano (seja por rótulos de identificação, de localização ou de quantificação) formando os dados de saída. As informações disponíveis para o aprendizado da ANN podem ser divididas em conjuntos de treino, validação e teste. Nesse trabalho, criou-se o banco de dados de cada sistema com base nos modelos em elementos finitos, sendo que os dados foram divididos da seguinte forma: 70% para treinamento, 20% para validação e 10% para teste.

Adotou-se como dados de entrada as primeiras frequências naturais e/ou formas modais do sistema. Quando considerado as frequências naturais, o valor de cada frequência danificada j utilizada no treinamento ($\omega_{j_{\text{danificada}}}$) foi normalizado pela respectiva frequência j na condição íntegra ($\omega_{j_{\text{íntegra}}}$), de acordo com a equação 5.10. Quando considerado as formas modais, os componentes de cada forma modal foram normalizados fixando-se o maior deslocamento como 1. Essa correção foi fundamental para melhorar o desempenho de previsão da rede neural.

$$\omega_{j_{\text{danificada}}} = \frac{\omega_{j_{\text{íntegra}}} - \omega_{j_{\text{danificada}}}}{\omega_{j_{\text{íntegra}}}} \quad (5.10)$$

Já os dados de saída foram arbitrados de forma similar ao proposto no método de detecção de dano baseado na atualização das matrizes. Ou seja, a fim de simular a redução de rigidez causada pelo dano, considerou-se um coeficiente com variação de 0 a 1 para cada elemento.

Entretanto, enquanto os Algoritmos Metaheurísticos possuem limites inferiores e superiores para os valores das variáveis analisadas, as redes neurais não possuem uma forma de limitar os valores dos dados de saída. Por isso, a depender dos dados e do processo de treinamento da ANN, os coeficientes de redução de rigidez obtidos para cada elemento podem ser ligeiramente menores que zero ou maiores que um. Destaca-se que as arquiteturas de rede foram determinadas por um processo de tentativa e erro, buscando obter os melhores resultados.

Dentre as topologias de redes existentes, escolheu-se trabalhar com a Rede *Feedforward*. Nesse tipo de rede, o fluxo de processamento das informações ocorre apenas no sentido das saídas, ou seja, não há o retorno de sinais para as camadas anteriores. As redes foram implementadas através da função `feedforwardnet` do Matlab R2012b (parte do pacote *Deep Learning Toolbox*). Essa função tem como objetivo mapear padrões entre dados de entrada e saída, de acordo com os parâmetros e funções utilizadas na estrutura de recuperação de informação e aprendizado.

Como função de treinamento, adotou-se a função de Levenberg-Marquardt, sendo o desempenho da rede medido pelo erro quadrático médio (*mean square error* – MSE). Além disso, nas camadas ocultas utilizou-se como função de ativação a função tangente hiperbólica, um tipo específico de função sigmoide. Já para a camada de saída, foi aplicada a função de ativação linear. Na Tabela 5.1, destacam-se outros valores escolhidos como critérios de parada do processo de treinamento das ANNs.

Tabela 5.1 – Parâmetros utilizados no treinamento das ANN

Critérios de parada	Valores adotados
Epochs*	1000
MSE	1e-7
Gradiente	1e-7
Máxima quantidade de falhas de validação	10

*Epoch: um conjunto de passagens completas pelos dados de treinamento

6 SIMULAÇÃO NUMÉRICA DE ENSAIOS EXPERIMENTAIS

Para testar a eficácia dos métodos de detecção de dano propostos nesse trabalho, simularam-se numericamente ensaios experimentais de três estruturas: uma viga engastada-livre, uma treliça plana de 10 barras e uma passarela treliçada de pedestres. As duas primeiras serviram como comparação dos resultados já obtidos por outros autores, enquanto a terceira estrutura foi utilizada para análises de múltiplos cenários de dano.

Os códigos foram desenvolvidos em Matlab e podem ser resumidos em quatro rotinas:

- modelagem da estrutura: criação de modelo em elementos finitos para estruturas de viga de Timoshenko e de treliça plana (MONTEIRO, 2022a);
- identificação modal estocástica: implementação do Método de Integração de Newmark (MONTEIRO, 2022b) e do algoritmo do SSI-DATA, desenvolvimento de diagrama de estabilização e escolha de modos estáveis (MONTEIRO, 2022c);
- método de detecção de dano com base na atualização das matrizes: resolução de problema de minimização pelo WOA programado por Mirjalili (2016);
- método de detecção de dano com base em redes neurais: resolução pelo pacote *Deep Learning Toolbox* do Matlab.

A fim de simular uma excitação ambiental nas estruturas estudadas, aplicou-se uma excitação aleatória do tipo ruído branco gaussiano gerada pela função `wgn` do Matlab. Então, as respostas do sistema em deslocamentos, velocidades e acelerações foram calculadas pelo Método de Integração de Newmark com um passo de tempo de 0,0005 s. Buscando situações mais próximas das condições de campo, também se simulou a presença de ruído nos sinais de aceleração com a função `awgn` do Matlab acrescentando porcentagens de ruído em relação ao sinal original. Por fim, o método SSI-DATA foi utilizado para obtenção dos parâmetros modais base para os métodos de detecção de dano.

Destaca-se que as funções `wgn` e `awgn` geram resultados aleatórios a cada iteração. Por isso, foi utilizada a mesma semente de geração de números aleatórios, buscando evitar respostas diferentes a cada ciclo da simulação numérica. Entretanto, quando realizado testes com a presença de diferentes sementes na geração de números aleatórios, as frequências encontradas apresentaram oscilações menores que 1%.

A Figura 6.1 sintetiza a metodologia proposta para simulação numérica dos ensaios experimentais e detecção de dano.

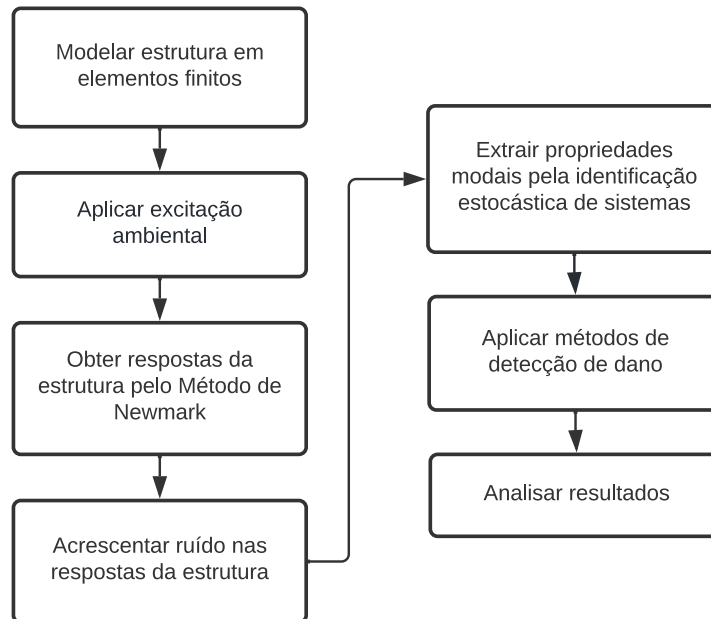


Figura 6.1 – Metodologia da simulação numérica de ensaios experimentais

6.1 VIGA ENGASTADA-LIVRE

Primeiramente, analisou-se uma viga metálica com 750 mm de comprimento e seção transversal quadrada tipo caixão com dimensão externa de 25,4 mm e espessura de 1 mm. A estrutura estudada por Kaminski Jr. e Riera (1997) foi modelada com 25 elementos de viga de Timoshenko, de acordo com a Figura 6.2. O peso específico, módulo de elasticidade, coeficiente de Poisson e coeficiente de corte de Timoshenko da viga são, respectivamente, 28 kN/m³, 68,6 GPa, 0,3 e 0,5. Além disso, acrescentou-se em todos os graus de liberdade uma massa concentrada de 18,2 g para representar a presença de acelerômetros nos ensaios experimentais. Para montagem da matriz de amortecimento, considerou-se como razão de amortecimento 1% no primeiro e quinto modo de vibração.




Figura 6.2 – Viga modelada com 25 elementos

Como cenários de dano, adotaram-se os três casos estudados por Zeni (2018):

- cenário 1: barra 20 com 20% de redução da rigidez;
- cenário 2: barra 8 com 30% de redução da rigidez;
- cenário 3: barras 5 e 12 com, respectivamente, 50% e 30% de redução da rigidez.

Os dois primeiros casos são comuns aos trabalhos de Fadel Miguel *et al.* (2012) e Fadel Miguel *et al.* (2013). Destaca-se que os três trabalhos citados utilizaram métodos de detecção de dano baseados na atualização de matrizes utilizando os algoritmos BSA, HS e P-NMA, respectivamente.

Na etapa de identificação modal, definiu-se como metade do número de linhas bloco da matriz Hankel $i = 30$. Além disso, considerou-se 3% e 5% como níveis de ruído nos sinais de aceleração para avaliar a variação dos parâmetros modais e a robustez dos procedimentos de detecção de dano. As respectivas frequências naturais obtidas pelo modelo em elementos finitos e pela identificação estocástica de sistemas são apresentadas nas Tabelas 6.1 e 6.2.

Tabela 6.1 – Frequências naturais do modelo FE da viga (Hz)

Modo de vibração	Modelo FE			
	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3
1	26,5600	26,5561	26,2459	25,3154
2	164,3250	163,8733	163,7602	161,3316
3	450,9722	447,0483	445,1953	446,4628

Tabela 6.2 – Frequências naturais identificadas na viga (Hz)

Modo de vibração	SSI-DATA (3% de ruído)				SSI-DATA (5% de ruído)			
	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3
1	26,5657	26,5622	26,2662	25,3229	26,5657	26,5622	26,2662	25,3229
2	160,8429	160,4204	160,3151	157,9811	160,8425	160,4201	160,3148	157,9808
3	392,3989	389,7449	388,4807	389,3414	392,3984	389,7441	388,4799	389,3406

Nota-se que as duas primeiras frequências identificadas pelo SSI-DATA, em ambas as situações de ruído, são extremamente próximas aos valores originais do modelo FE. Entretanto, o valor da terceira frequência apresenta um erro em torno de 10. A partir do quarto modo de vibração a discrepância entre os valores teóricos e identificados foi ainda maior. Por isso, a detecção de dano foi realizada apenas com os dados dos três primeiros modos de vibração da estrutura.

6.1.1 Detecção de Dano com Base na Atualização de Matrizes

No método de detecção de dano pelo processo de otimização, foram utilizados 100 agentes de busca em 200 iterações. Dessa forma, encontraram-se os resultados mostrados nas Figuras 6.3 e 6.4 de acordo com os níveis de ruído empregados para três cenários de danificação. Em todas as situações, o dano foi localizado e quantificado. Observou-se apenas uma pequena imprecisão no cenário 1 com 3% de ruído e no cenário 3 com 5% de ruído, porém a redução de rigidez detectada não foi maior que 1,5% e esses erros podem ser desprezados.

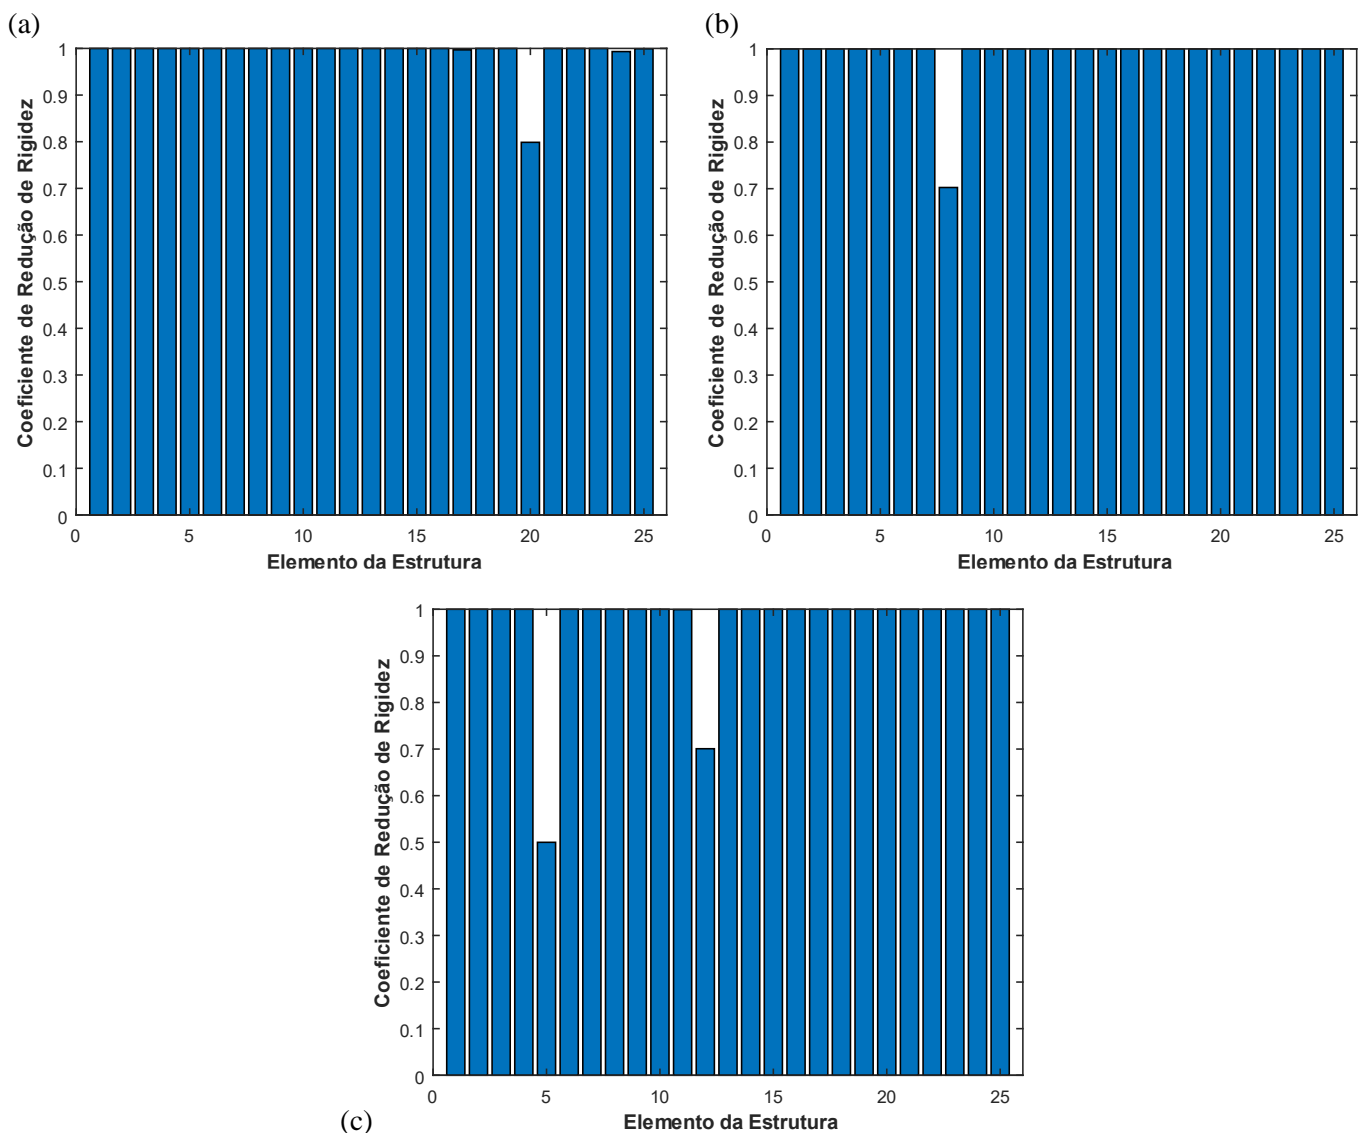


Figura 6.3 – WOA (viga com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3

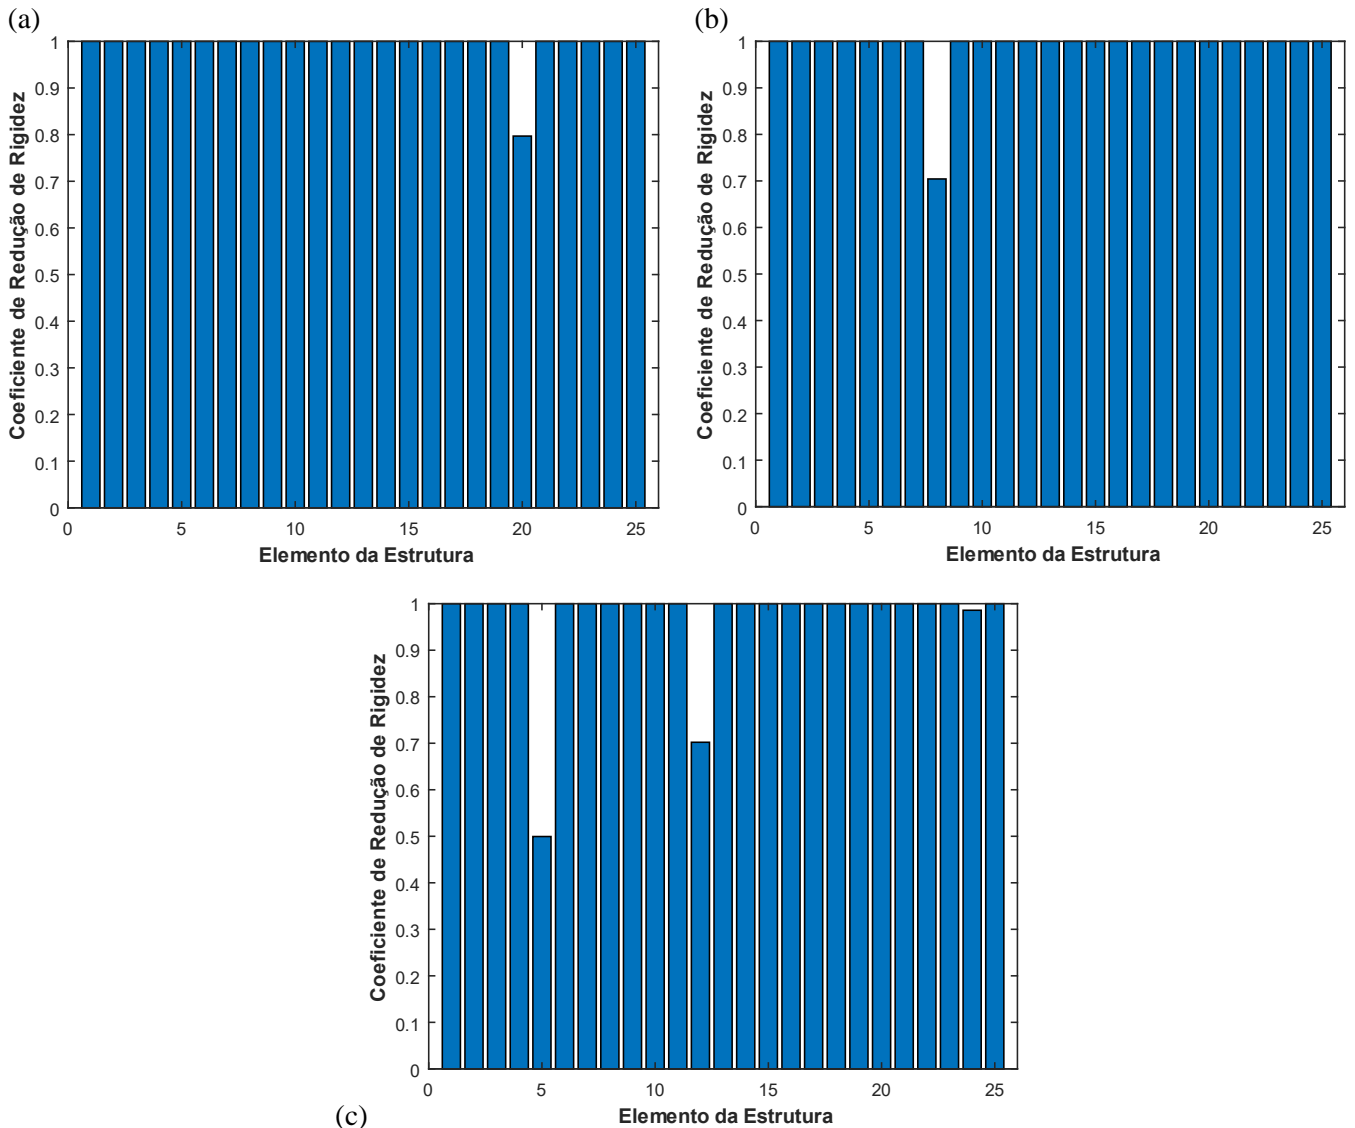


Figura 6.4 – WOA (viga com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3

6.1.2 Detecção de Dano com Base em Redes Neurais

No treinamento das redes neurais para o caso da viga em balanço, utilizou-se como dado de entrada a primeira forma modal considerando apenas os graus de liberdade verticais. Como dados de saída, foram adotados os elementos do sistema sendo que seus valores variam conforme as taxas de dano. Assim, a criação dos dados de treinamento foi feita a partir do modelo de elementos finitos, sendo inclusos casos de dano simples e casos de dano múltiplo com dois elementos danificados. Nesses cenários, as variações da redução de rigidez em cada elemento foram de 10% a 60% em intervalos de 10%, totalizando 1950 conjuntos. Após alguns testes de variações da arquitetura da rede, optou-se por apenas uma camada oculta com 25 neurônios, formando a arquitetura apresentada na Figura 6.5.




Figura 6.5 – Arquitetura da rede neural proposta para a viga

Os resultados gerados pela rede neural para os três cenários são mostrados nas Figuras 6.6 e 6.7 conforme os níveis de ruído aplicados. A quantificação foi precisa nos casos de dano simples, enquanto no caso de dano múltiplo houve diferenças de até 6,06%. Além disso, pequenas taxas de redução de rigidez foram quantificadas em alguns elementos, mas o valor máximo obtido foi de 5,33% no elemento 23 no cenário 2 com 5% de ruído.

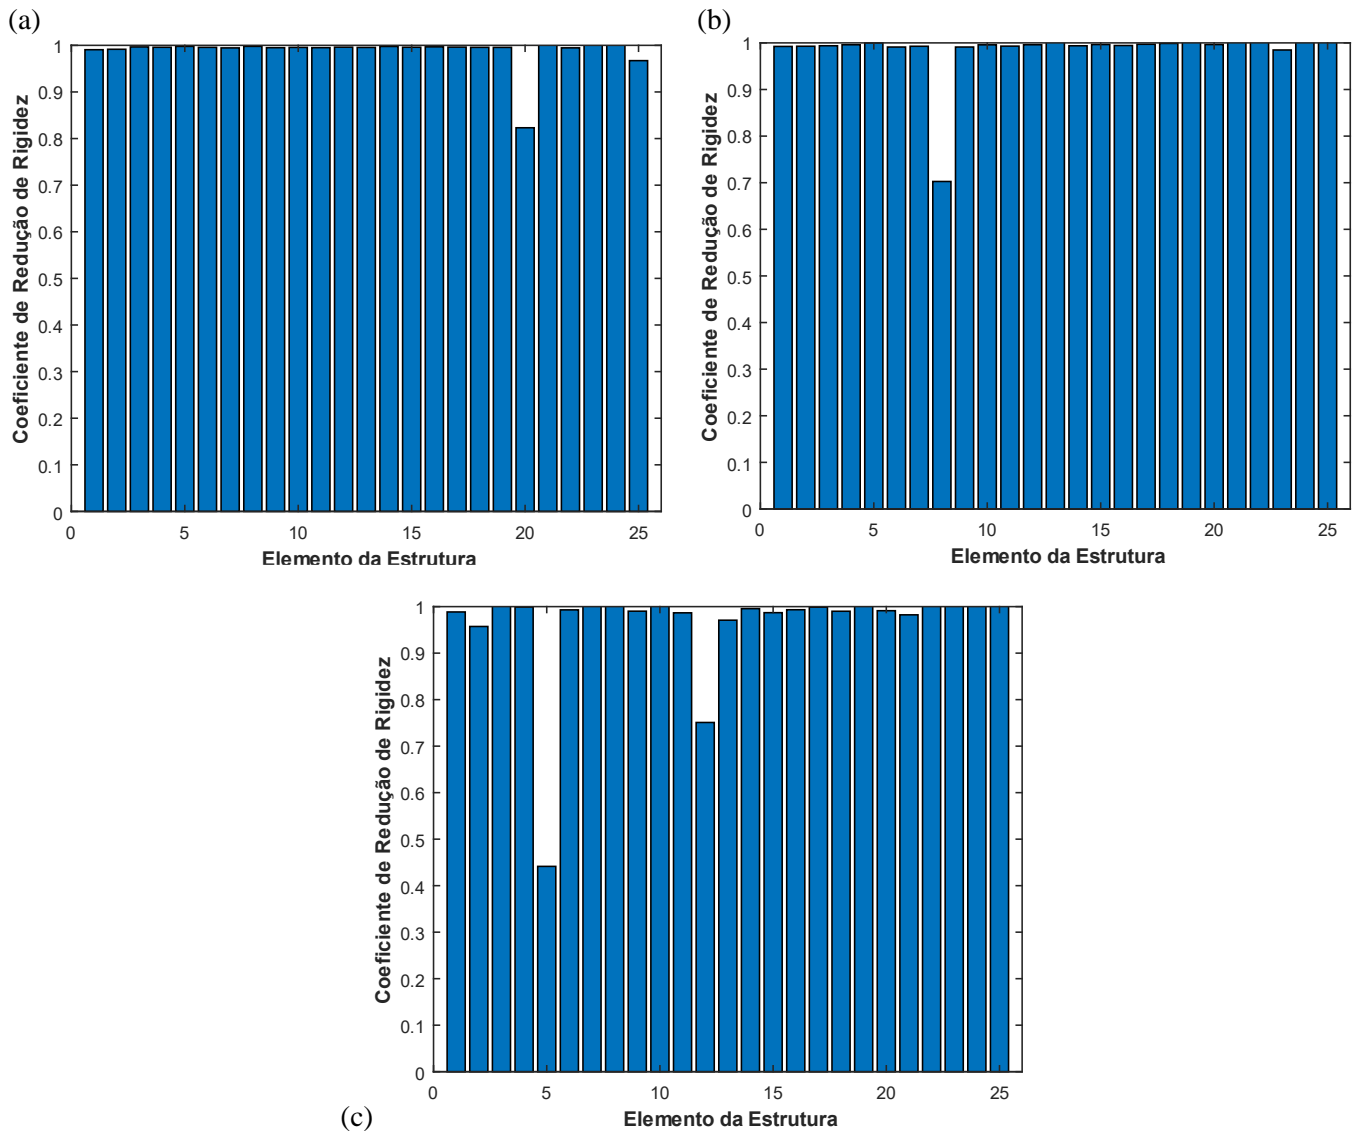


Figura 6.6 – ANN (viga com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3

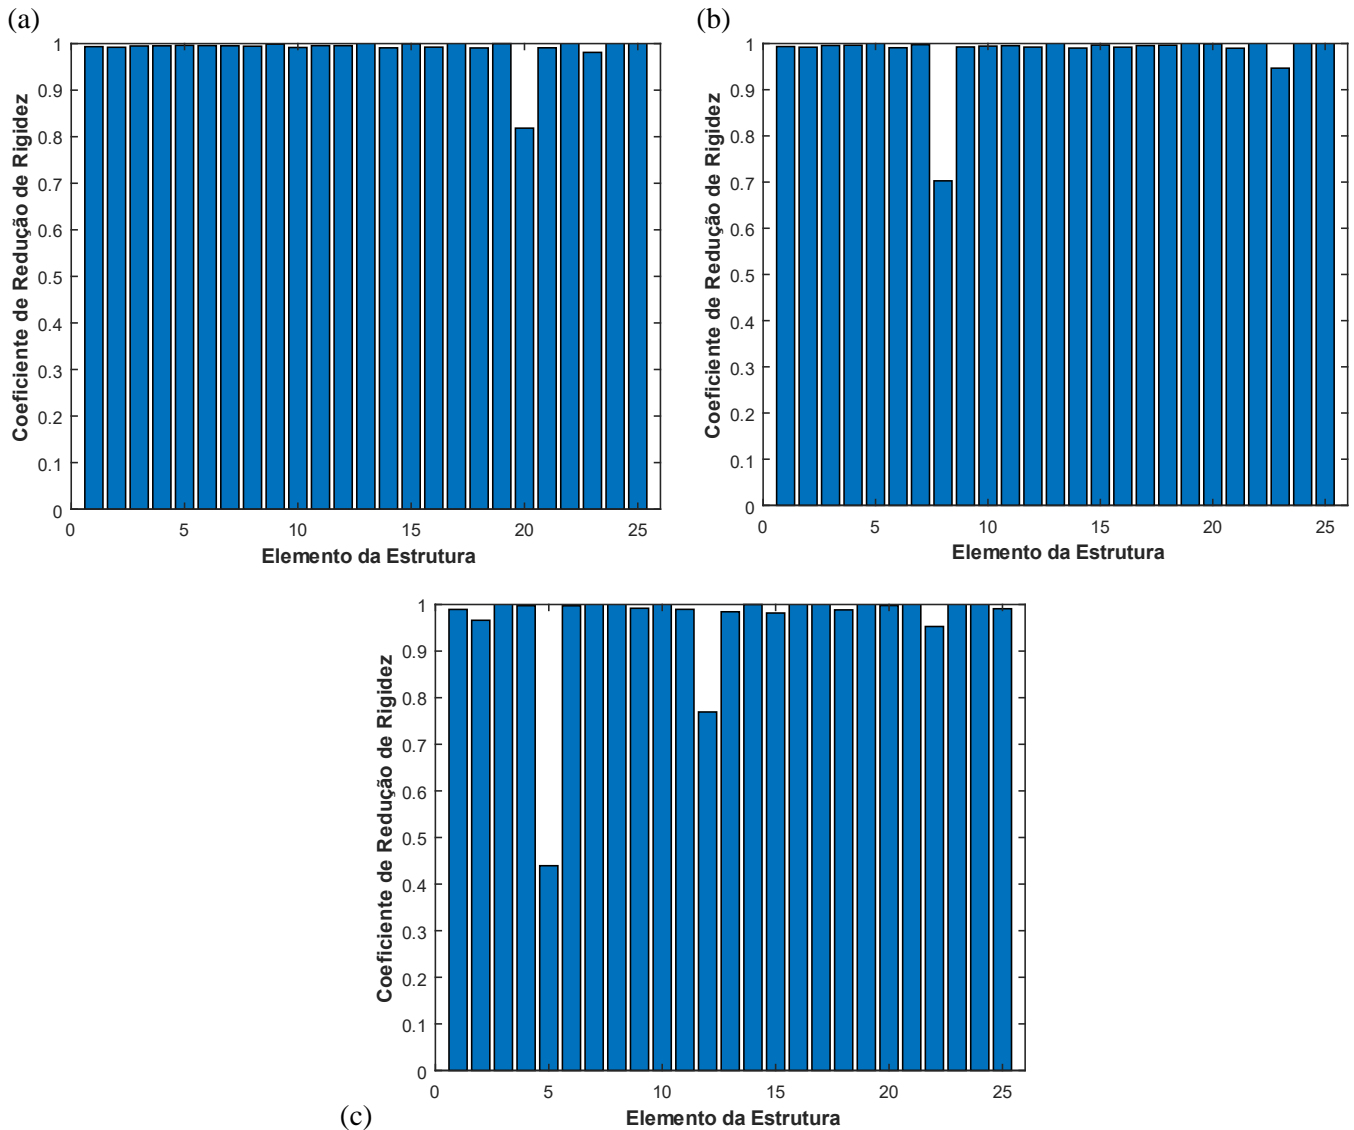


Figura 6.7 – ANN (viga com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3

6.1.3 Comparação dos Resultados das Metodologias Aplicadas

No caso da viga engastada-livre, os dois métodos foram eficientes na identificação e localização do dano. O processo de otimização pelo Algoritmo de Otimização da Baleia quantificou os três cenários, enquanto as redes neurais geraram pequenas discrepâncias no cenário de dano múltiplo. Entretanto, como apresentado na Tabela 6.3, os valores de dano estimado pelas ANNs foram próximos dos valores exatos em ambos os casos de ruído. Em comparação com outros autores, as redes neurais tiveram um desempenho similar na detecção de dano em comparação com os resultados apresentados por Zeni (2018) e Fadel Miguel *et al.* (2012), como mostrado no Anexo A. Já as soluções geradas pelo WOA superaram os resultados dos autores mencionados e os de Fadel Miguel *et al.* (2013), chegando em resultados mais exatos.

Tabela 6.3 – Situação de dano estimada para a viga

Cenário de dano	Elemento	Dano exato	Dano estimado			
			WOA (3%)	WOA (5%)	ANN (3%)	ANN (5%)
1	20	0,8	0,7987	0,7969	0,8232	0,8184
2	8	0,7	0,7026	0,7043	0,7027	0,7027
3	5	0,5	0,4999	0,4995	0,4415	0,4394
	12	0,7	0,7007	0,7021	0,7509	0,7694

6.2 TRELIÇA DE 10 BARRAS

A segunda estrutura analisada foi uma treliça de 10 barras estudada por Begambre e Laier (2009), conforme Figura 6.8. Todos os elementos possuem: massa específica de 7700 kg/m^3 , módulo de elasticidade de 195 GPa , momento de inércia de $3 \times 10^{-8} \text{ m}^4$ e seção transversal de $4,2 \times 10^{-4} \text{ m}^2$. Arbitrou-se como razão de amortecimento 1% no 1º e 3º modo de vibração.




Figura 6.8 – Treliça de 10 barras

Buscando comparar os resultados obtidos por Begambre e Laier (2009) e Fadel Miguel *et al.* (2013), analisou-se o cenário de redução da rigidez de 15% nas barras 2 e 8 simultaneamente. Ambos os autores utilizaram uma abordagem de otimização híbrida, sendo que Begambre e Laier utilizaram uma combinação dos algoritmos PSO e Simplex, enquanto Fadel Miguel *et al.* empregaram o P-NMA. Conforme esses dois trabalhos, adotou-se 3% de ruído nos sinais de resposta dos cenários íntegro e danificado. No método SSI-DATA, definiu-se como metade do número de linhas bloco da matriz Hankel $i = 20$.

As frequências naturais obtidas pelo modelo em elementos finitos e pela identificação estocástica de sistemas são apresentadas na Tabela 6.4. Devido à pequena quantidade de elementos da treliça, foram utilizados apenas os três primeiros modos de vibração para a detecção de dano.

Tabela 6.4 – Frequências naturais da treliça (Hz)

Modo de vibração	Modelo FE		SSI-DATA	
	Cenário íntegro	Cenário danificado	Cenário íntegro	Cenário danificado
1	174,9996	170,5968	174,8116	170,4073
2	500,6687	484,7274	496,6709	480,9747
3	600,8525	593,0745	593,8417	586,3163

6.2.1 Detecção de Dano com Base na Atualização de Matrizes

A detecção de dano pelo algoritmo WOA na treliça foi realizada com 50 agentes de busca em 100 iterações. Assim, obteve-se a solução exata apresentada na Figura 6.9.

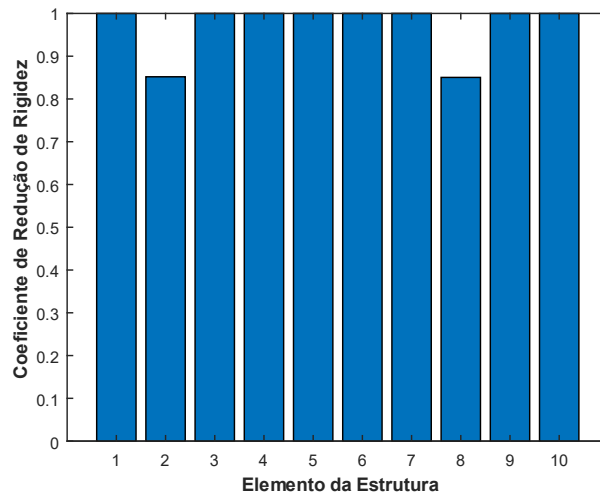


Figura 6.9 – WOA: treliça

6.2.2 Detecção de Dano com Base em Redes Neurais

Para o treinamento da rede neural da treliça, usou-se como dado de entrada a primeira forma modal com seus 8 graus de liberdade. Como dados de saída, foram adotadas as barras da estrutura de forma similar ao caso anterior. Dessa forma, os dados de treinamento foram criados a partir do modelo de elementos finitos com casos de dano simples. Nesses cenários, as variações da redução de rigidez em cada elemento foram de 10% a 70% em intervalos de 5%, totalizando 715 conjuntos. Após alguns testes da arquitetura da rede, optou-se por apenas uma camada oculta com 35 neurônios, formando a arquitetura apresentada na Figura 6.10. Então, gerou-se a solução apresentada na Figura 6.11. Nota-se que mesmo treinando a rede neural com casos de dano simples apenas, o método conseguiu localizar e quantificar o cenário de dano múltiplo proposto.




Figura 6.10 – Arquitetura da rede neural proposta para a treliça




Figura 6.11 – ANN: treliça

6.2.3 Comparação dos Resultados das Metodologias Aplicadas

Os resultados das duas metodologias de detecção de dano são mostrados na Tabela 6.5 em conjunto com as soluções obtidas por Begambre e Laier (2009) e Fadel Miguel *et al.* (2013). Ambos os métodos utilizados nesse trabalho localizaram e quantificaram o cenário danificado corretamente. Pela comparação dos valores, nota-se que o algoritmo WOA forneceu as melhores respostas de forma global. Vale ressaltar que a ANN não possui uma forma de limitar os valores dos dados de saída como um algoritmo de otimização. Por isso, alguns elementos não danificados tiveram seus valores ligeiramente maiores que 1.

Tabela 6.5 – Situação de dano estimada para a treliça

Barra	Dano exato	Dano estimado			
		Begambre & Laier	Fadel Miguel et al.	WOA	ANN
1	1	1	0,9995	1	0,9974
2	0,85	0,8476	0,8537	0,8509	0,8544
3	1	0,9987	1	1	1,0447
4	1	0,9862	0,9998	1	1,0087
5	1	0,9829	0,9946	1	1,0115
6	1	0,9992	1	1	1
7	1	1	1	1	1,0165
8	0,85	0,8503	0,8500	0,8508	0,8460
9	1	0,9996	1	1	0,9977
10	1	1	1	1	1,0094

6.3 PASSARELA TRELIÇADA

Por último, analisou-se uma passarela de pedestres de treliça Warren, com vão de 39 m e altura de 2,23 m, como apresentado na Figura 6.12. A estrutura possui módulo de elasticidade igual a 200 GPa, massa específica de 7850 kg/m³ e razões de amortecimento de 1% no 1º e 5º modo de vibração. As informações referentes a cada barra são dadas pela Tabela 6.6.




Figura 6.12 – Passarela de pedestres de treliça Warren

Tabela 6.6 – Área das seções transversais das barras

Grupo	Nº. do elemento	Área (m ²)
Banzo inferior	1-13	0,0060
Barras diagonais	14-41	0,0040
Banzo superior	42-55	0,0080

Foram propostos cenários de dano buscando mostrar a influência da posição e intensidade do dano com a assertividade das metodologias de detecção. Os casos englobam 2 cenários de dano simples e 3 cenários de dano múltiplo, sendo eles:

- cenário 1: barra 7 com 20% de redução da rigidez;
- cenário 2: barra 54 com 20% de redução da rigidez;
- cenário 3: barras 26 e 27 com, respectivamente, 30% e 20% de redução da rigidez;
- cenário 4: barras 5 e 46 com, respectivamente, 30% e 20% de redução da rigidez;
- cenário 5: barras 7, 45 e 52 com, respectivamente, 40%, 30% e 30% de redução da rigidez.

Para avaliar a variação dos parâmetros modais na identificação estocástica de sistemas e a robustez dos procedimentos de detecção de dano, considerou-se 3% e 5% como níveis de ruído nos sinais de aceleração. Mesmo com essas perturbações, foram reconhecidas 8 frequências naturais com boa precisão considerando apenas modelos de ordem até 20 e adotando-se $i = 30$. O diagrama de estabilização para o cenário íntegro com 3% de ruído é dado pela Figura 6.13.

Nesse diagrama, os pontos em preto denotam a frequência identificada e os círculos coloridos a estabilidade daquele valor de acordo com a tolerância empregada pela equação 4.19. Nota-se que mesmo com a excitação ambiental e a presença de ruído nas respostas da estrutura, o método prova-se extremamente potente para identificação de sistemas com as primeiras frequências naturais menores que 100 Hz, como as construções civis.

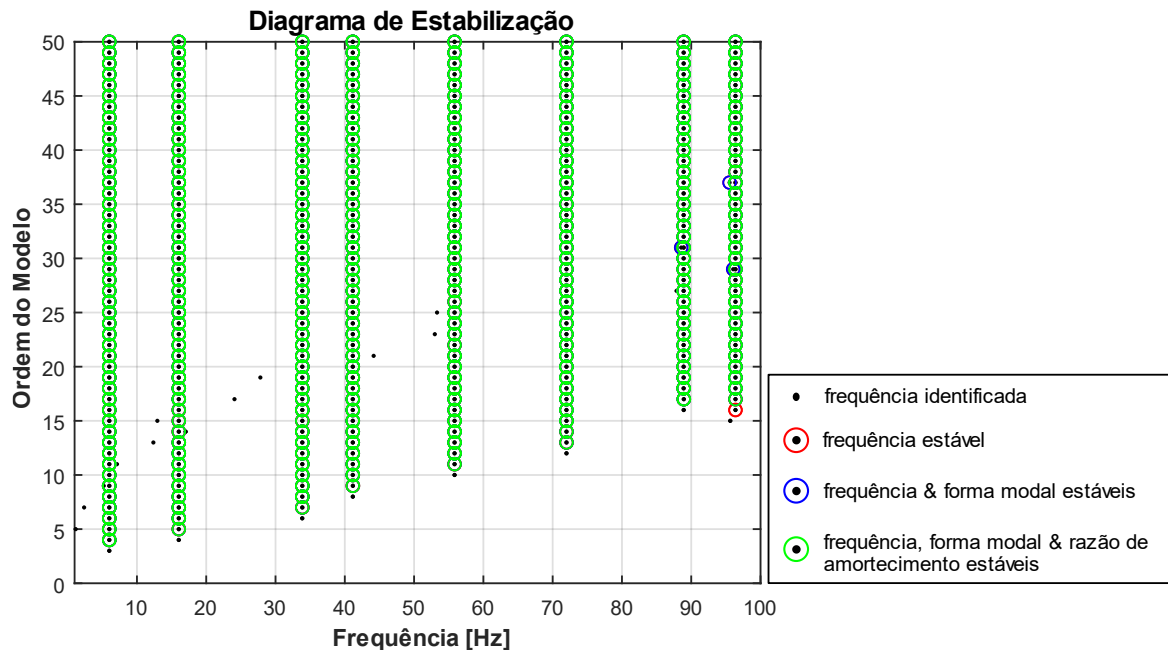


Figura 6.13 – Diagrama de estabilização da passarela no cenário íntegro (3% de ruído)

A detecção de dano da passarela foi realizada com os dados dos cinco primeiros modos de vibração da estrutura, sendo as frequências naturais obtidas pelo modelo em elementos finitos mostrados na Tabela 6.7. Já as Tabelas 6.8 e 6.9 apresentam as frequências geradas pelo SSI-DATA de acordo com os níveis de ruído.

Tabela 6.7 – Frequências naturais do modelo FE da passarela (Hz)

Modo de vibração	Modelo FE					
	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5
1	5,9960	5,9820	5,9914	5,9956	5,9305	5,8432
2	16,0362	16,0362	16,0165	15,9580	15,8068	15,7378
3	33,9157	33,5875	33,8185	33,8582	33,8292	32,4809
4	41,2447	41,2447	41,2422	41,1463	41,0693	40,8871
5	55,9769	55,9769	55,7379	55,5528	55,4004	55,5217

Tabela 6.8 – Frequências naturais identificadas na passarela considerando 3% de ruído (Hz)


Modo de vibração	SSI-DATA (3% de ruído)					
	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5
1	6,0096	5,9954	6,0049	6,0092	5,9414	5,8527
2	16,0398	16,0398	16,0212	15,9638	15,8050	15,7310
3	33,8875	33,5625	33,7912	33,8309	33,8013	32,4464
4	41,1606	41,1607	41,1582	41,0664	40,9921	40,8164
5	55,8083	55,8083	55,5662	55,3816	55,2281	55,3500

Tabela 6.9 – Frequências naturais identificadas na passarela considerando 5% de ruído (Hz)

Modo de vibração	SSI-DATA (5% de ruído)					
	Cenário íntegro	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5
1	6,0096	5,9954	6,0049	6,0092	5,9414	5,8527
2	16,0399	16,0399	16,0213	15,9640	15,8052	15,7312
3	33,8860	33,5612	33,7896	33,8294	33,7998	32,4451
4	41,1604	41,1604	41,1579	41,0662	40,9919	40,8165
5	55,8028	55,8029	55,5612	55,3772	55,2240	55,3458

6.3.1 Detecção de Dano com Base na Atualização de Matrizes

No método de detecção de dano pelo processo de otimização, foram utilizados 100 agentes de busca em 500 iterações. As Figuras 6.14 e 6.15 contêm as respostas desse método para os casos analisados conforme os níveis de ruído considerados. Em todos os cenários o dano foi mensurado corretamente, sendo verificadas perturbações apenas no cenário 5 com ruído de 5%. Porém, essas irregularidades identificadas nas barras 4, 14, 40, 44 e 47 ficaram em torno de 1,6%.



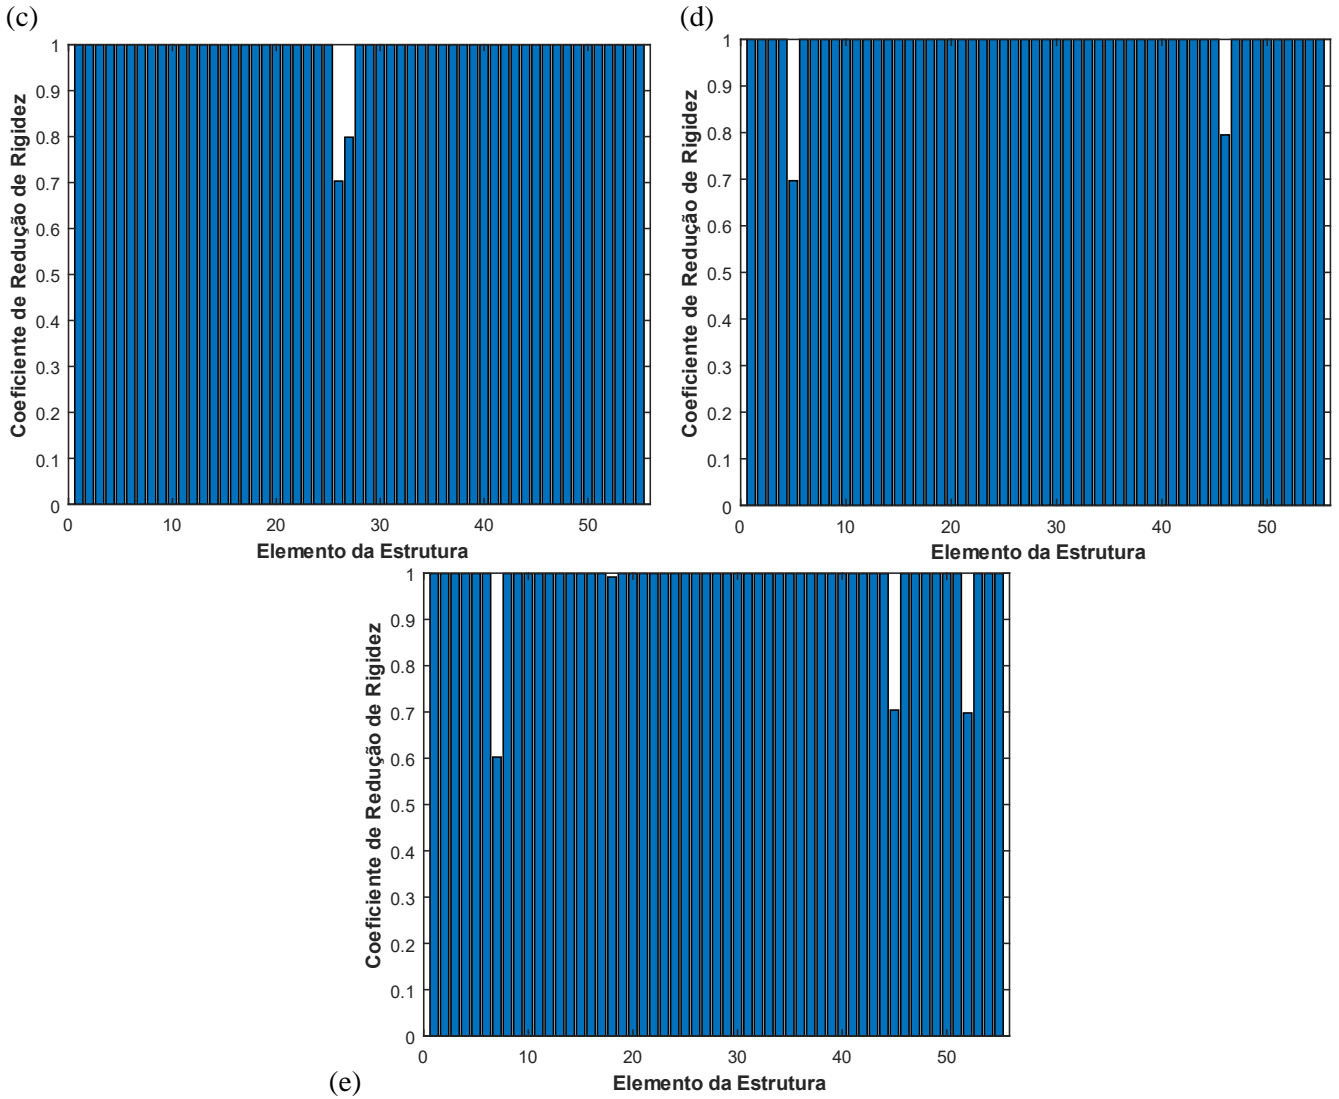
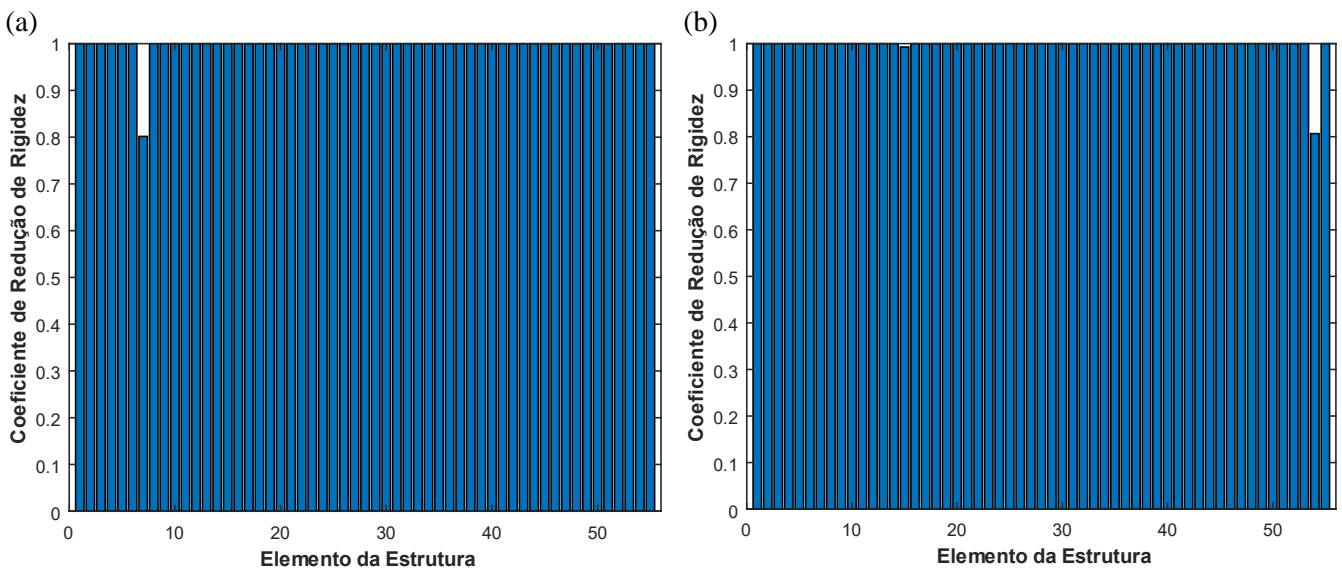


Figura 6.14 – WOA (passarela com 3% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4, (e) cenário 5



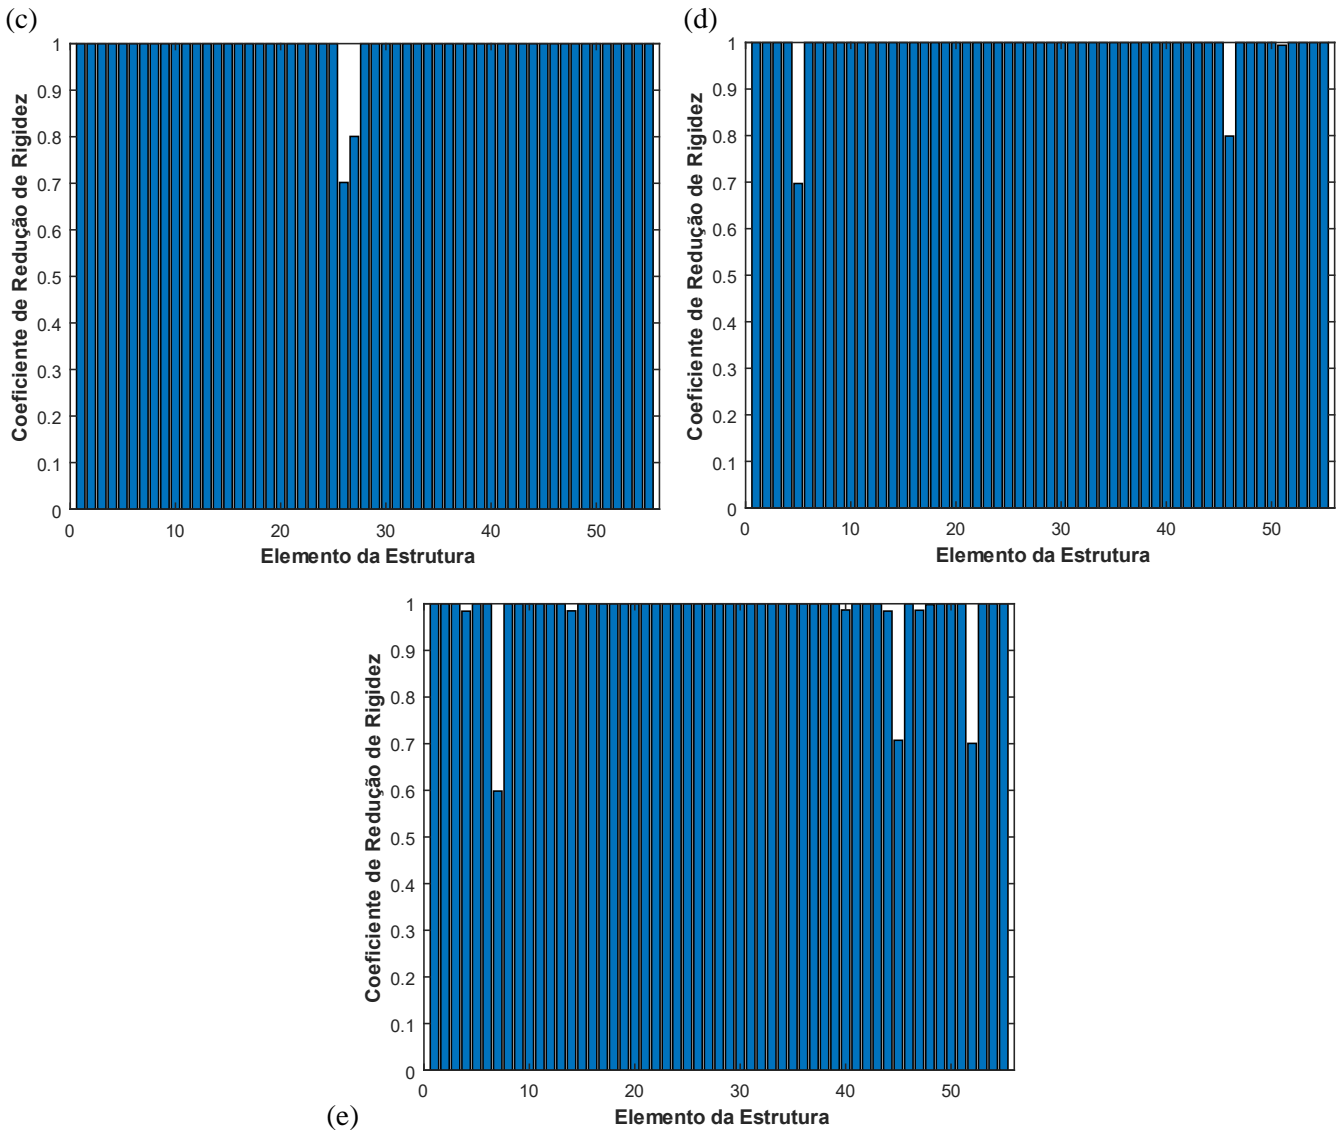


Figura 6.15 – WOA (passarela com 5% de ruído): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4, (e) cenário 5

6.3.2 Detecção de Dano com Base em Redes Neurais

No caso da passarela treliçada, apesar de diversos testes de arquitetura de rede neural e de formulação dos dados de treinamento, não foi possível convergir para um treinamento satisfatório. A relação entre os valores de saída gerados pela ANN e os valores alvo foram significativamente discrepantes como mostra a Figura 6.16. Dessa forma, nenhum dos cinco cenários de dano puderam ser avaliados por esse método.

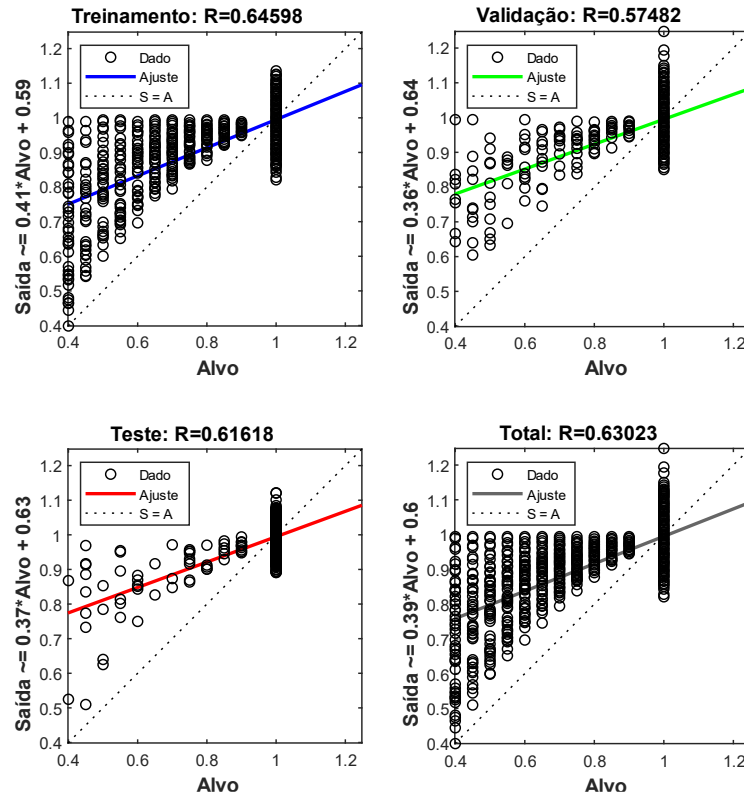


Figura 6.16 – Valores preditos pela ANN para a passarela de pedestres

6.3.3 Comparação dos Resultados das Metodologias Aplicadas

Na análise da passarela de pedestres de treliça Warren, só foi possível detectar dano utilizando o método baseado na atualização de matrizes devido às limitações encontradas no método baseado em redes neurais. Entretanto, como mostra a Tabela 6.10, os valores encontrados utilizando o algoritmo WOA foram extremamente satisfatórios mesmo com a presença de ruído. No nível de ruído de 3%, apenas uma imprecisão foi encontrada no elemento 18 com uma redução de rigidez menor que 1%. Já considerando 5% de ruído no sistema, pequenos erros foram encontrados em três cenários, porém no valor máximo de 1,6% de dano no cenário 5.

Tabela 6.10 – Situação de dano estimada para a passarela

Cenário de dano	Elemento	Dano exato	Dano estimado			
			WOA (3%)	WOA (5%)	ANN (3%)	ANN (5%)
1	7	0,8	0,8015	0,8016	-	-
2	54	0,8	0,7992	0,8067	-	-
3	26	0,7	0,7032	0,7018	-	-
	27	0,8	0,7987	0,8006	-	-
4	5	0,7	0,6968	0,6971	-	-
	46	0,8	0,7951	0,7989	-	-
5	7	0,6	0,6026	0,5984	-	-
	45	0,7	0,7041	0,7073	-	-
	52	0,7	0,6979	0,7007	-	-

7 ENSAIO EXPERIMENTAL

O desempenho dos métodos de detecção de dano também foi verificado em um sistema real através de ensaios experimentais, sendo os códigos desenvolvidos previamente aplicados para análise de uma régua de aço, simulando uma viga em balanço. Os ensaios para determinação dos parâmetros modais foram realizados no laboratório do Grupo de Mecânica Aplicada (GMAp) da Universidade Federal do Rio Grande do Sul (UFRGS) por meio de acelerômetros e pelo sistema de aquisição Pulse 12 channel Brüel&Kjaer Type 3560 C.

Inicialmente, as propriedades do sistema (geometria, massa específica e módulo de elasticidade) foram determinadas, sendo essas a base para a modelagem numérica (MONTEIRO, 2022a). Então, realizaram-se os ensaios dinâmicos na condição íntegra para comparação posterior com os cenários com danos. O dano foi introduzido progressivamente na estrutura através de cortes que reduziram as seções transversais de elementos específicos. Em cada etapa de dano, repetiram-se os ensaios dinâmicos para aquisição dos respectivos acelerogramas. Com esses dados, o algoritmo do Método de Identificação Estocástica de Subespaço (MONTEIRO, 2022c) foi empregado para calcular os modos de vibração. Por fim, os métodos de detecção de dano foram aplicados e os resultados analisados. Essa metodologia para realização dos ensaios experimentais é sintetizada pela Figura 7.1.

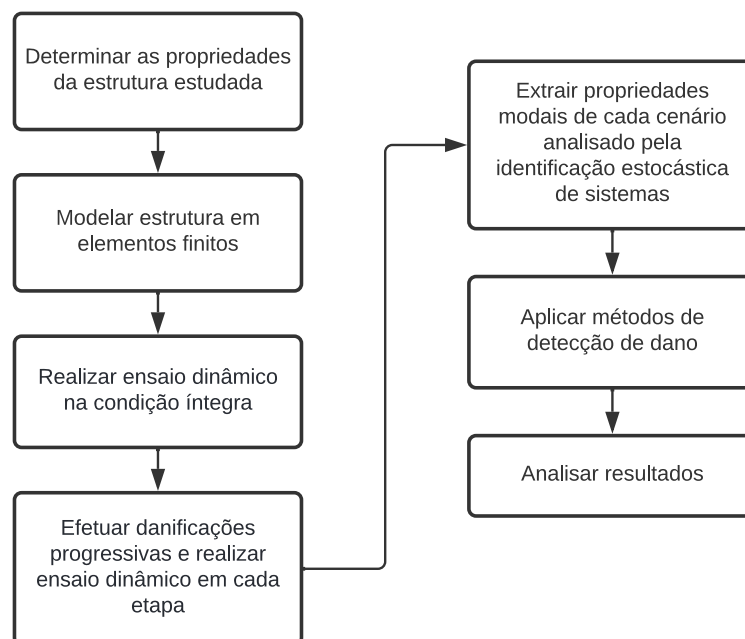


Figura 7.1 – Metodologia dos ensaios experimentais

7.1 RÉGUA DE AÇO

A estrutura analisada foi uma régua de aço de 420 mm de comprimento, 39,5 mm de largura e 1,2 mm de espessura. A massa específica, módulo de elasticidade, coeficiente de Poisson e coeficiente de corte de Timoshenko da régua são, respectivamente, 8193,9 kg/m³, 210 GPa, 0,3 e 0,5. Esse sistema foi modelado com 28 elementos de viga de Timoshenko, conforme a Figura 7.2.




Figura 7.2 – Régua de aço

Como apresentado na Figura 7.3, os ensaios experimentais foram realizados com três acelerômetros, sendo as propriedades desses dispositivos descritas na Tabela 7.1.



Figura 7.3 – Régua experimental e sistema de aquisição

Tabela 7.1 – Propriedades dos acelerômetros utilizados

Posição	Acelerômetros			
	Marca	Modelo	Nº de série	Massa (g)
Nó 11	PCB Piezotronics	352C33	86702	5,631
Nó 19	PCB Piezotronics	352C33	86703	7,949
Nó 29	Brüel&Kjær	4514 B 4x	51467x	8,723

Para determinar os parâmetros modais experimentalmente, foram dados pequenos deslocamentos na régua deixando o sistema em vibração livre. Assim, os acelerogramas dos três pontos medidos foram utilizados como dados de entrada no método SSI-DATA, sendo adotado $i = 50$ e $n_{max} = 30$. A Figura 7.4 exemplifica um dos sinais adquiridos.




Figura 7.4 – Acelerograma no nó 29 (condição íntegra)

Primeiramente, identificaram-se os modos de vibração na condição íntegra da régua. Como mostra a Figura 7.5, as cinco primeiras frequências naturais foram determinadas com estabilidade. Os valores obtidos são comparados com o modelo numérico na Tabela 7.2. Nota-se que as frequências teóricas e experimentais são extremamente próximas, sendo que a maior diferença é de 2,16% na primeira frequência natural.


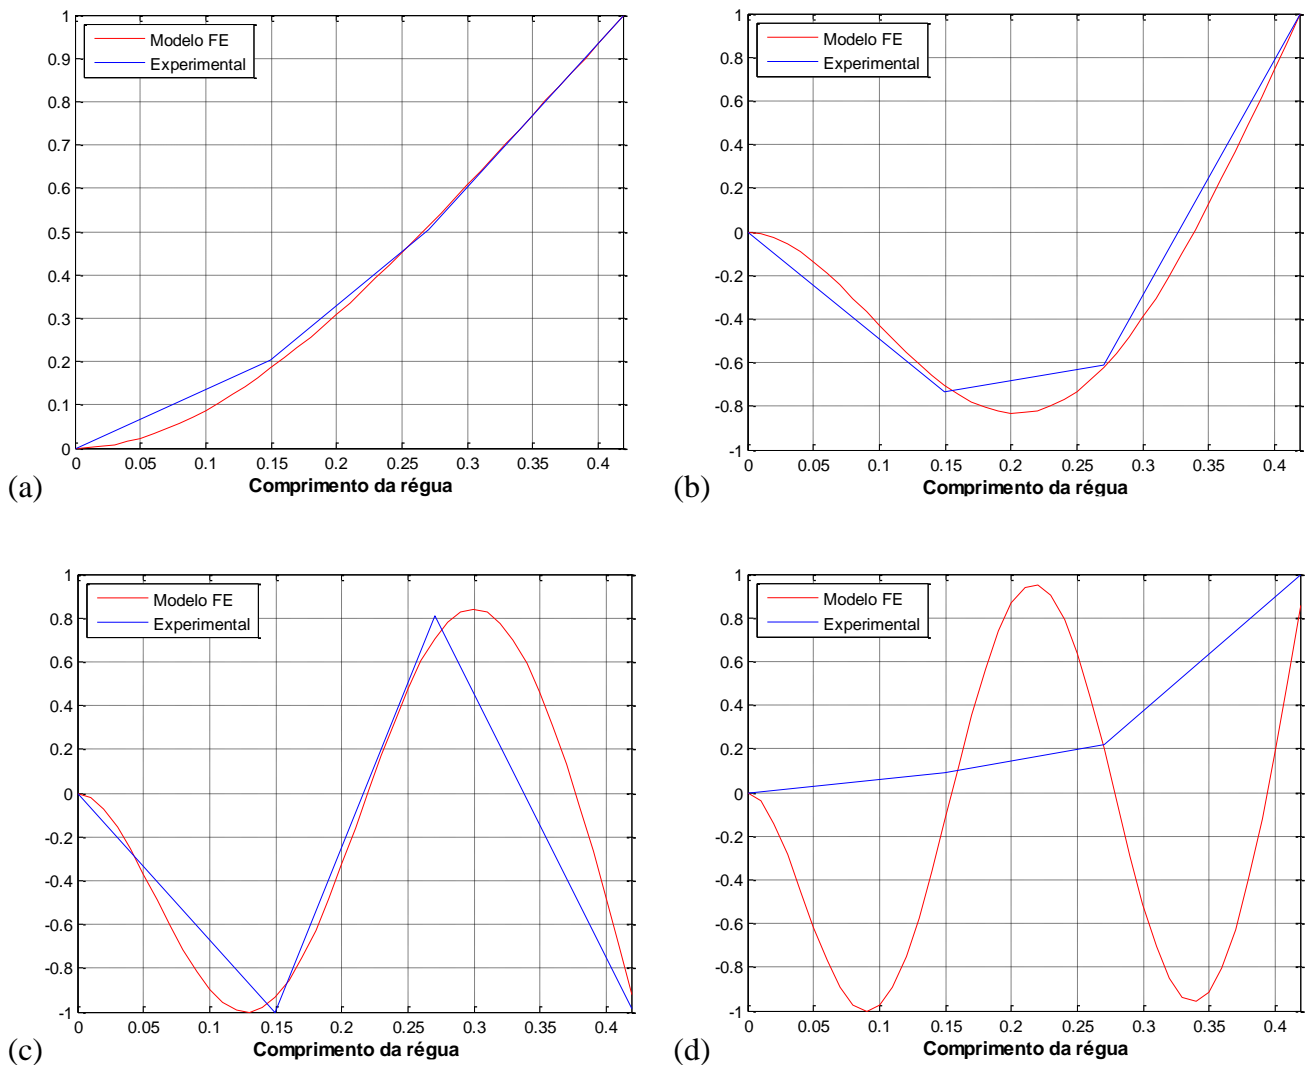


Figura 7.5 – Diagrama de estabilização da régua no cenário íntegro

Tabela 7.2 – Frequências naturais da régua no cenário íntegro (Hz)

Modo de vibração	Modelo FE Cenário íntegro	SSI-DATA Cenário íntegro
1	4,9341	4,8270
2	30,5389	29,9510
3	85,6315	85,4507
4	178,8478	177,6512
5	281,9240	277,3123

As formas modais identificadas no cenário íntegro são expostas na Figura 7.6 em conjunto com as formas modais do modelo numérico. Como foram utilizados apenas três acelerômetros, a quarta e a quinta formas modais não puderam ser determinadas pela falta de mais pontos de aquisição de dados. Entretanto, as três primeiras formas modais identificadas apresentam correlações de 99,9% com o modelo numérico, como mostrado pelo Critério de Concordância Modal na Figura 7.7. Por isso, nas análises de detecção de dano, utilizaram-se as primeiras 5 frequências naturais e as 3 primeiras formas modais.



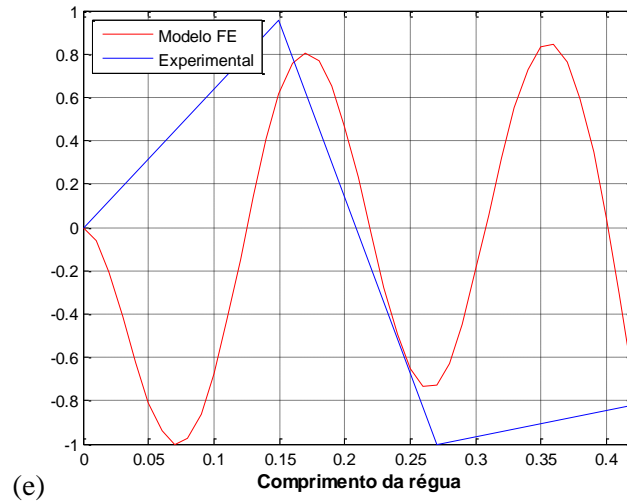


Figura 7.6 – Formas modais numéricas e experimentais: (a) modo 1, (b) modo 2, (c) modo 3, (d) modo 4, (e) modo 5




Figura 7.7 – MAC das formas modais experimentais e numéricas no cenário íntegro

Em seguida, realizaram-se cortes laterais em alguns elementos da régua a fim de representar possíveis danificações. Os cenários analisados foram:

- cenário 1: redução da largura do elemento 13 para 33 mm;
- cenário 2: redução da largura do elemento 13 para 18,5 mm;
- cenário 3: redução das larguras dos elementos 8 e 13 para 32 mm e 18,5 mm respectivamente;
- cenário 4: redução das larguras dos elementos 8 e 13 para 17,5 mm e 18,5 mm respectivamente.

Assim, repetiu-se o ensaio a cada etapa progressiva de dano. As frequências naturais identificadas experimentalmente são apresentadas na Tabela 7.3.

Tabela 7.3 – Frequências naturais da régua identificadas nos cenários danificados (Hz)

Modo de vibração	SSI-DATA			
	Cenário 1	Cenário 2	Cenário 3	Cenário 4
1	4,8137	4,7989	4,7922	4,6853
2	29,9172	29,5635	29,5126	29,4792
3	84,8619	84,7127	84,6237	83,4732
4	176,5049	175,2284	174,5207	171,8705
5	275,5140	275,4523	274,1301	273,9630

A partir desses valores, os métodos de detecção de dano foram aplicados, como é descrito nos tópicos a seguir.

7.1.1 Detecção de Dano com Base na Atualização de Matrizes

No método de detecção de dano pelo processo de otimização, foram utilizados 50 agentes de busca em 150 iterações. Dessa forma, encontraram-se os resultados mostrados na Figura 7.8.

No cenário 1, o dano no elemento 13 foi localizado, quantificando-se uma redução da rigidez de 15,95%. Outros três elementos tiveram pequenas quedas de rigidez, porém essas imprecisões foram menores que 7%.

No cenário 2, a danificação no elemento 13 também foi localizada estimando-se uma redução de rigidez de 41,52%.

No cenário 3, o dano no elemento 13 não foi localizado, entretanto, identificou-se 10,71% e 11,18% de redução de rigidez nos elementos 14 e 15 respectivamente. O dano no elemento 8 também não foi localizado, porém o método apontou uma redução de rigidez de 14,15% no elemento 6. Além disso, o algoritmo de otimização indicou 20,37% de dano no elemento 21.

No cenário 4, a danificação nos elementos 8 e 13 foi localizada, estimando-se 46,18% e 36,51% de redução de rigidez, respectivamente.

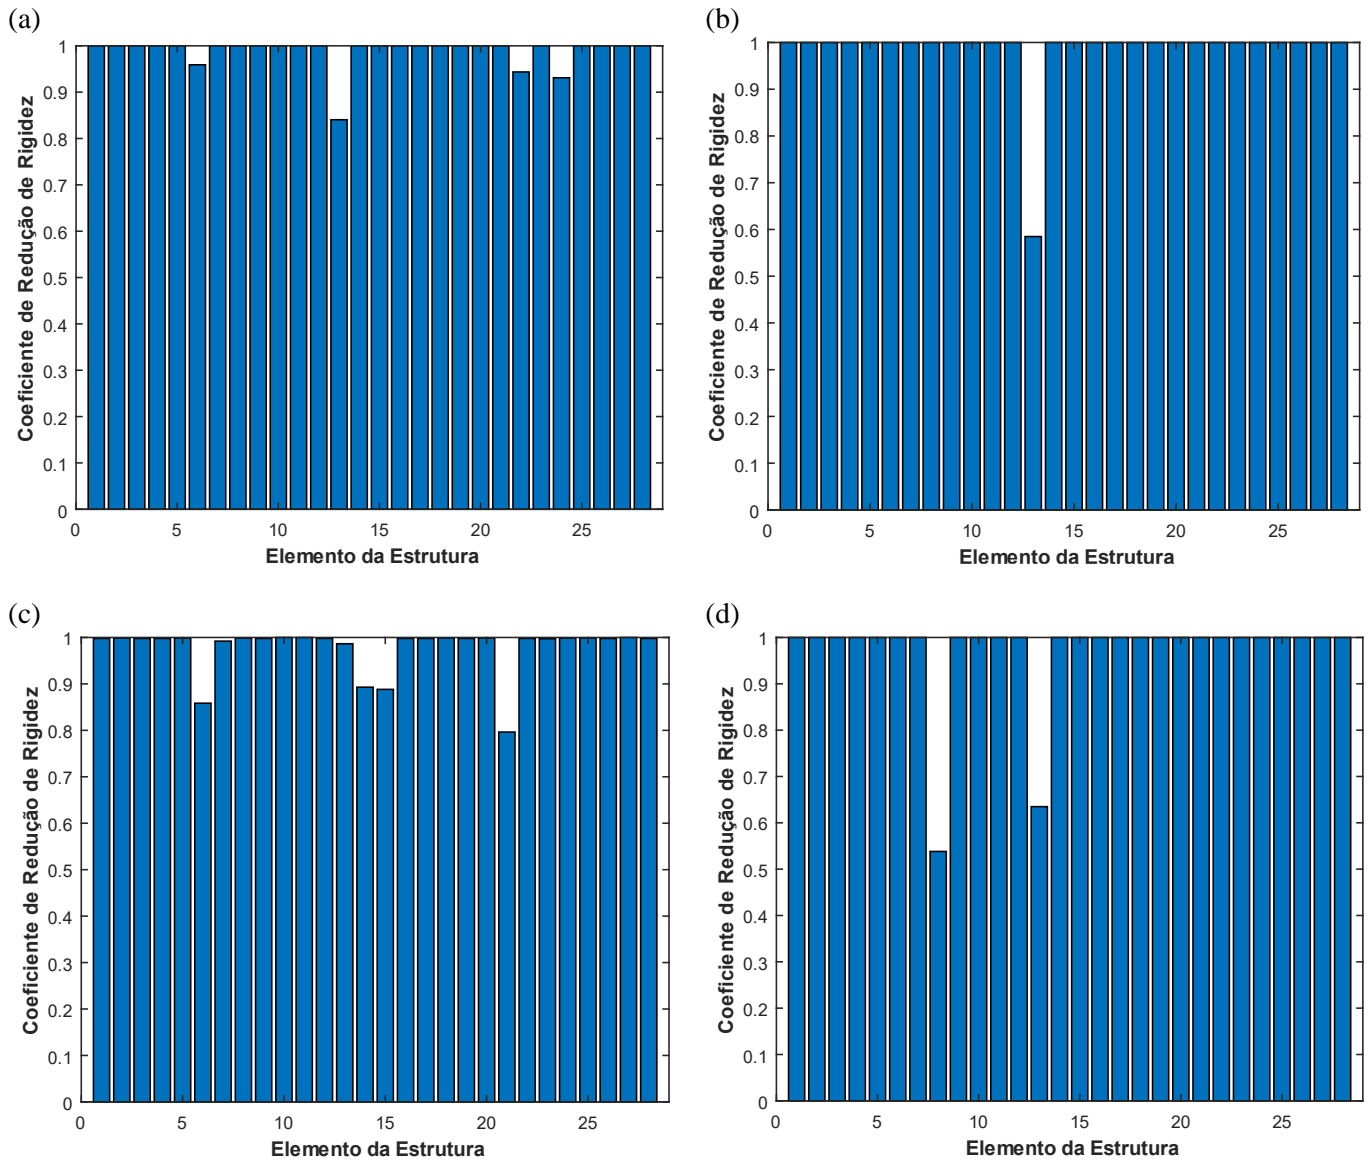


Figura 7.8 – WOA (régua): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4

7.1.2 Detecção de Dano com Base em Redes Neurais

No treinamento das redes neurais para o caso da régua de aço, utilizaram-se como dados de entrada as cinco primeiras frequências naturais. Como dados de saída, foram adotados os elementos do sistema sendo que seus valores variam conforme as taxas de dano. Assim, a criação dos dados de treinamento foi feita a partir do modelo de elementos finitos, sendo inclusos apenas casos de dano simples. Nesses cenários, as variações da redução de rigidez em cada elemento foram de 5% a 60% em intervalos de 5%, totalizando 336 conjuntos. Após alguns testes de variações da arquitetura da rede, optou-se por três camadas ocultas com 5, 14 e 25 componentes, formando a arquitetura apresentada na Figura 7.9.




Figura 7.9 – Arquitetura da rede neural proposta para a régua

Os resultados gerados pela rede neural para os quatro cenários analisados são mostrados na Figuras 7.10.

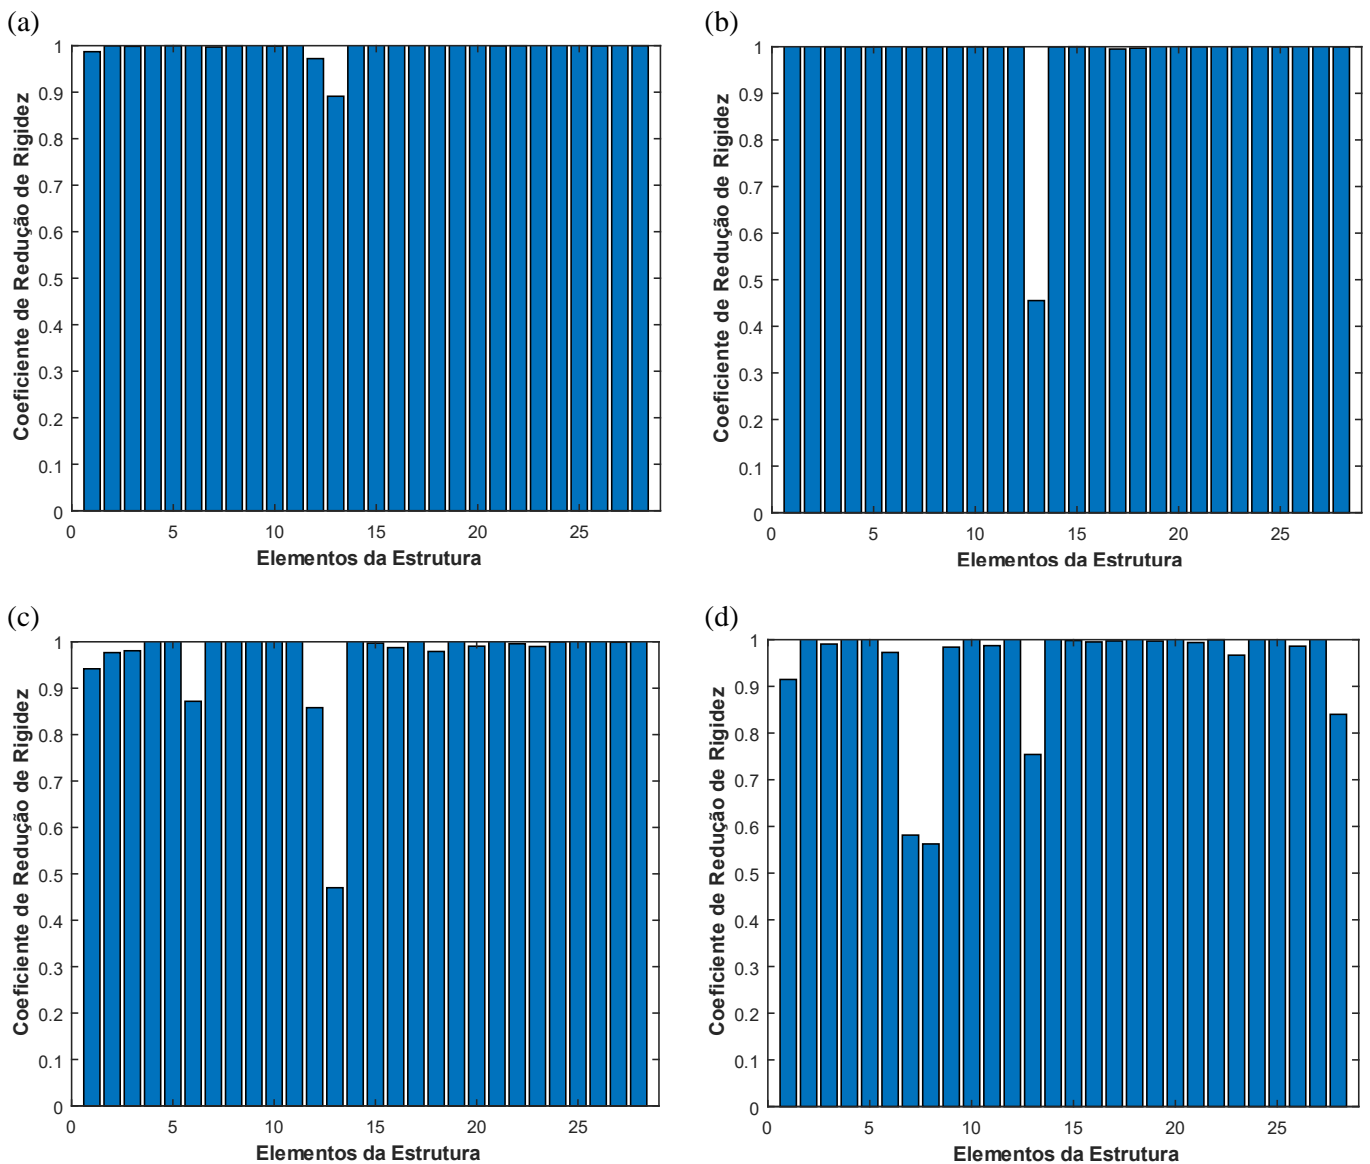


Figura 7.10 – ANN (régua): (a) cenário 1, (b) cenário 2, (c) cenário 3, (d) cenário 4

No cenário 1, o dano no elemento 13 foi localizado com 10,88% de redução de rigidez.

No cenário 2, a danificação no elemento 13 também foi localizada, quantificando-se 54,04% de redução de rigidez.

No cenário 3, identificou-se 52,99% de dano no elemento 13 e 14,20% no elemento 12. Já o dano no elemento 8 não foi localizado, porém quantificou-se 12,82% de redução de rigidez no elemento 6. Além disso, alguns elementos apresentaram pequenas taxas de dano, sendo o valor máximo 5,82%.

No cenário 4, identificou-se 41,86% e 43,75% de dano nos elementos 7 e 8 respectivamente. A danificação no elemento 13 também foi identificada, quantificando-se 24,58%. Destaca-se que nesse cenário foi encontrado o dano 15,99% no elemento 28, além de imprecisões em outros elementos de até 8,52%.

7.1.3 Comparação dos Resultados das Metodologias Aplicadas

Os dois métodos estudados apresentaram bons resultados de localização de dano nos testes experimentais, principalmente nos cenários de dano simples. Nos casos de dano múltiplo, não foi possível localizar a danificação no elemento 8 com a menor taxa de redução da largura da seção transversal em ambas as metodologias, porém identificou-se dano no elemento vizinho 6.

Os resultados de detecção de dano dos cenários 3 e 4 pelo método baseado em redes neurais apresentaram mais imprecisões. Entretanto, não foram utilizados casos de dano múltiplo no treinamento, pois uma maior base de dados estava prejudicando o aprendizado da rede e, conseqüentemente, os resultados gerados.

Ressalta-se que ambos os métodos utilizaram como ferramenta base modelos numéricos. Dessa forma, pequenas divergências entre os dados experimentais e numéricos podem prejudicar o desempenho das metodologias de detecção de dano. Além disso, apenas três pontos de aceleração foram medidos nos ensaios experimentais, o que também pode ter influenciado na precisão dos resultados obtidos e na presença de danos falso-positivos nos casos de dano múltiplo. Porém, mesmo com essas limitações, as metodologias se provaram eficazes para determinar a vizinhança do local do dano e até mesmo estimar taxas de perda de rigidez.

8 APLICAÇÃO EM ESTRUTURA CIVIL

Por fim, os métodos de detecção de dano foram aplicados e verificados em uma estrutura civil que é utilizada como *benchmark* na comunidade científica, a Ponte Z24 localizada na Suíça. Neste trabalho, analisou-se um caso de dano múltiplo gerado pelo recalque da fundação de um dos pilares do sistema.

Inicialmente, obtiveram-se os dados experimentais que foram base para identificação estocástica de sistemas dos cenários íntegro e danificado aplicando o algoritmo do SSI-DATA (MONTEIRO, 2022c). Em seguida, a estrutura foi modelada em elementos finitos, sendo esse modelo numérico atualizado de acordo com a referência do cenário íntegro buscando representar os parâmetros modais do sistema da forma mais fidedigna possível. Então, os métodos de detecção de dano foram aplicados e os resultados analisados. Essa metodologia para análise de estrutura civil é sintetizada pela Figura 8.1.

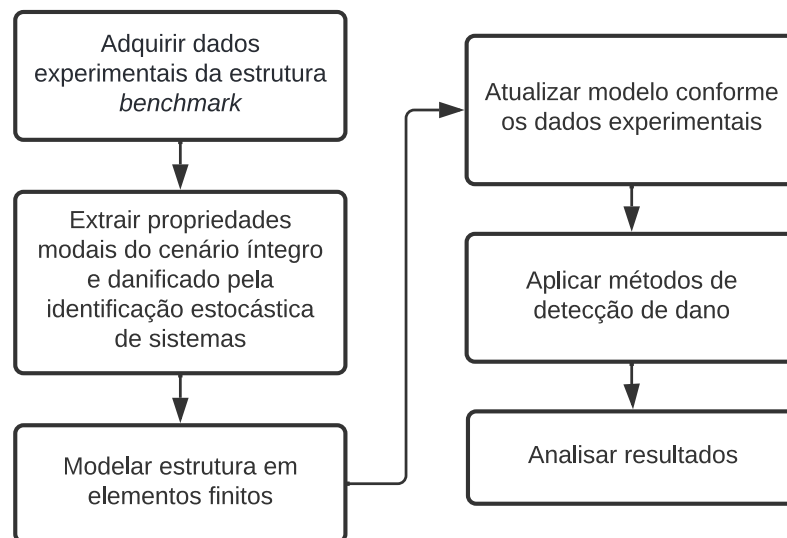


Figura 8.1 – Metodologia da aplicação dos métodos em estrutura real

8.1 PONTE Z24

A Ponte Z24 foi selecionada pelo projeto de pesquisa BE-3175 do programa europeu Brite-Euram, SIMCES (*System Identification to Monitor Civil Engineering Structures*), como objeto de estudo no desenvolvimento de uma metodologia de monitoramento da integridade estrutural. O trabalho coordenado pela Universidade Católica de Leuven (Departamento de Engenharia Civil, Divisão de Mecânica Estrutural) englobou o monitoramento da estrutura durante um ano

e a execução de ensaios de dano progressivo antes da demolição da ponte em 1998 (DE ROECK, 2003). Os dados obtidos nesse projeto estão disponíveis para comunidade científica¹ e se tornaram um *benchmark* na identificação modal estocástica e detecção de dano.

Essa obra de arte especial era localizada no Cantão de Berna na Suíça, conectando Koppigen e Utzenstorf, e transpunha a Rodovia A1, que ligava as cidades de Berna e Zurique. A ponte possuía três vãos, duas faixas e cerca de 60 m de comprimento (Figura 8.2). Os dois pilares intermediários eram fixos na viga, enquanto os encontros eram compostos por três pilares biapoiados de cada lado. Todos os apoios eram rotacionados em relação ao eixo longitudinal da estrutura formando uma ponte esconsa. A viga era em seção caixão com duas células de concreto protendido (Figura 8.3).




Figura 8.2 – Visão geral da Ponte Z24 (adaptado de KRÄMER, 1999)




Figura 8.3 – Seção transversal da Ponte Z24 (MASCIOTTA *et al.*, 2016)

¹ Disponível em: < <https://bwk.kuleuven.be/bwm/z24> >. Acesso em: 06 de dez. 2022.

Ao total, foram executados 17 ensaios de dano progressivo (*progressive damage tests* - PDT), que são descritos detalhadamente por Krämer (1999), incluindo as considerações e equipamentos utilizados. A Tabela 8.1 apresenta o primeiro conjunto de testes realizados considerando o recalque de fundação do pilar Koppigen.

Tabela 8.1 – Cenários de dano da Ponte Z24 (MAECK e DE ROECK, 2003)

PDT	Data	Cenário de dano
1	04.08.1998	Primeira medição de referência
2	09.08.1998	Segunda medição de referência
3	10.08.1998	Recalque do pilar, 20 mm
4	12.08.1998	Recalque do pilar, 40 mm
5	17.08.1998	Recalque do pilar, 80 mm
6	18.08.1998	Recalque do pilar, 95 mm
7	19.08.1998	Inclinação da fundação
8	20.08.1998	Terceira medição de referência

Os cenários de recalque da fundação foram simulados pelo rebaixamento do pilar ($x = 44$ m) e causaram diversas rachaduras na viga, como ilustra a Figura 8.4. Neste trabalho, considerou-se como cenário íntegro o PDT 2 e como cenário de dano o recalque de 95 mm do pilar (PDT 6).

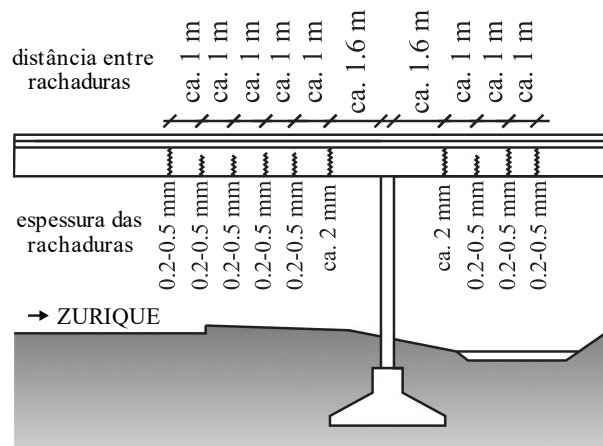


Figura 8.4 – Rachaduras na viga da Ponte Z24 após recalque de fundação (adaptado de TEUGHELIS e DE ROECK, 2004)

8.1.1 Identificação dos Parâmetros Modais

Os parâmetros modais da Ponte Z24 foram identificados pelo Método de Identificação Estocástica de Subespaço a partir dos dados dos ensaios de vibração ambiental (Figura 8.5), que foram realizados em horário de alto fluxo de veículos. Conforme a Figura 8.6, a estrutura foi ensaiada a partir de 9 configurações (*setups*) de 15 acelerômetros no tabuleiro (2 triaxiais, 3 biaxiais e 10 uniaxiais), 2 acelerômetros triaxiais em um dos pilares e 3 acelerômetros de

referência (1 triaxial e 2 uniaxiais), totalizando 33 registros. A frequência e o tempo de aquisição foram, respectivamente, 100 Hz e 655,36 s.




Figura 8.5 – Exemplo de sinal de aceleração (PDT-06)

No método SSI-DATA, adotou-se como número de atrasos de tempo $i = 50$ e ordem máxima do modelo $n_{max} = 30$. Assim, foram identificadas as frequências naturais apresentadas nas Tabelas 8.2 e 8.3 para os PDT-02 e PDT-06 respectivamente.

Tabela 8.2 – Frequências naturais da ponte identificadas no cenário íntegro (Hz)

Modo	SSI-DATA – Cenário íntegro									Média	Desvio padrão
	Setup 1	Setup 2	Setup 3	Setup 4	Setup 5	Setup 6	Setup 7	Setup 8	Setup 9		
1	3,88	3,86	3,87	3,88	3,87	3,89	3,87	3,88	3,88	3,87	0,01
2	5,02	5,01	5,03	5,02	5,03	5,03	5,01	4,96	4,95	5,01	0,03
3	9,78	9,75	9,78	9,79	9,79	9,76	9,82	9,75	9,85	9,79	0,03
4	10,31	10,33	10,36	10,30	10,30	10,29	10,27	10,36	10,29	10,31	0,03
5	12,76	12,84	12,80	12,85	12,82	12,77	12,80	12,68	12,82	12,79	0,05
6	13,58	13,48	13,48	13,53	13,36	13,51	13,44	13,58	13,56	13,50	0,07

Tabela 8.3 – Frequências naturais da ponte identificadas no cenário danificado (Hz)

Modo	SSI-DATA – Cenário danificado									Média	Desvio padrão
	Setup 1	Setup 2	Setup 3	Setup 4	Setup 5	Setup 6	Setup 7	Setup 8	Setup 9		
1	3,65	3,63	3,64	3,67	3,67	3,67	3,64	3,65	3,67	3,66	0,02
2	4,92	4,91	4,93	4,92	4,93	4,92	4,92	4,94	4,89	4,92	0,02
3	9,22	9,28	9,17	9,25	9,26	9,26	9,27	9,25	9,23	9,24	0,03
4	9,63	9,71	9,61	9,70	9,71	9,68	9,66	9,72	9,74	9,68	0,04
5	12,34	12,15	12,02	12,05	12,09	12,05	12,07	12,08	12,53	12,15	0,17
6	13,55	13,27	13,15	13,45	13,26	13,52	13,48	13,80	13,51	13,44	0,19

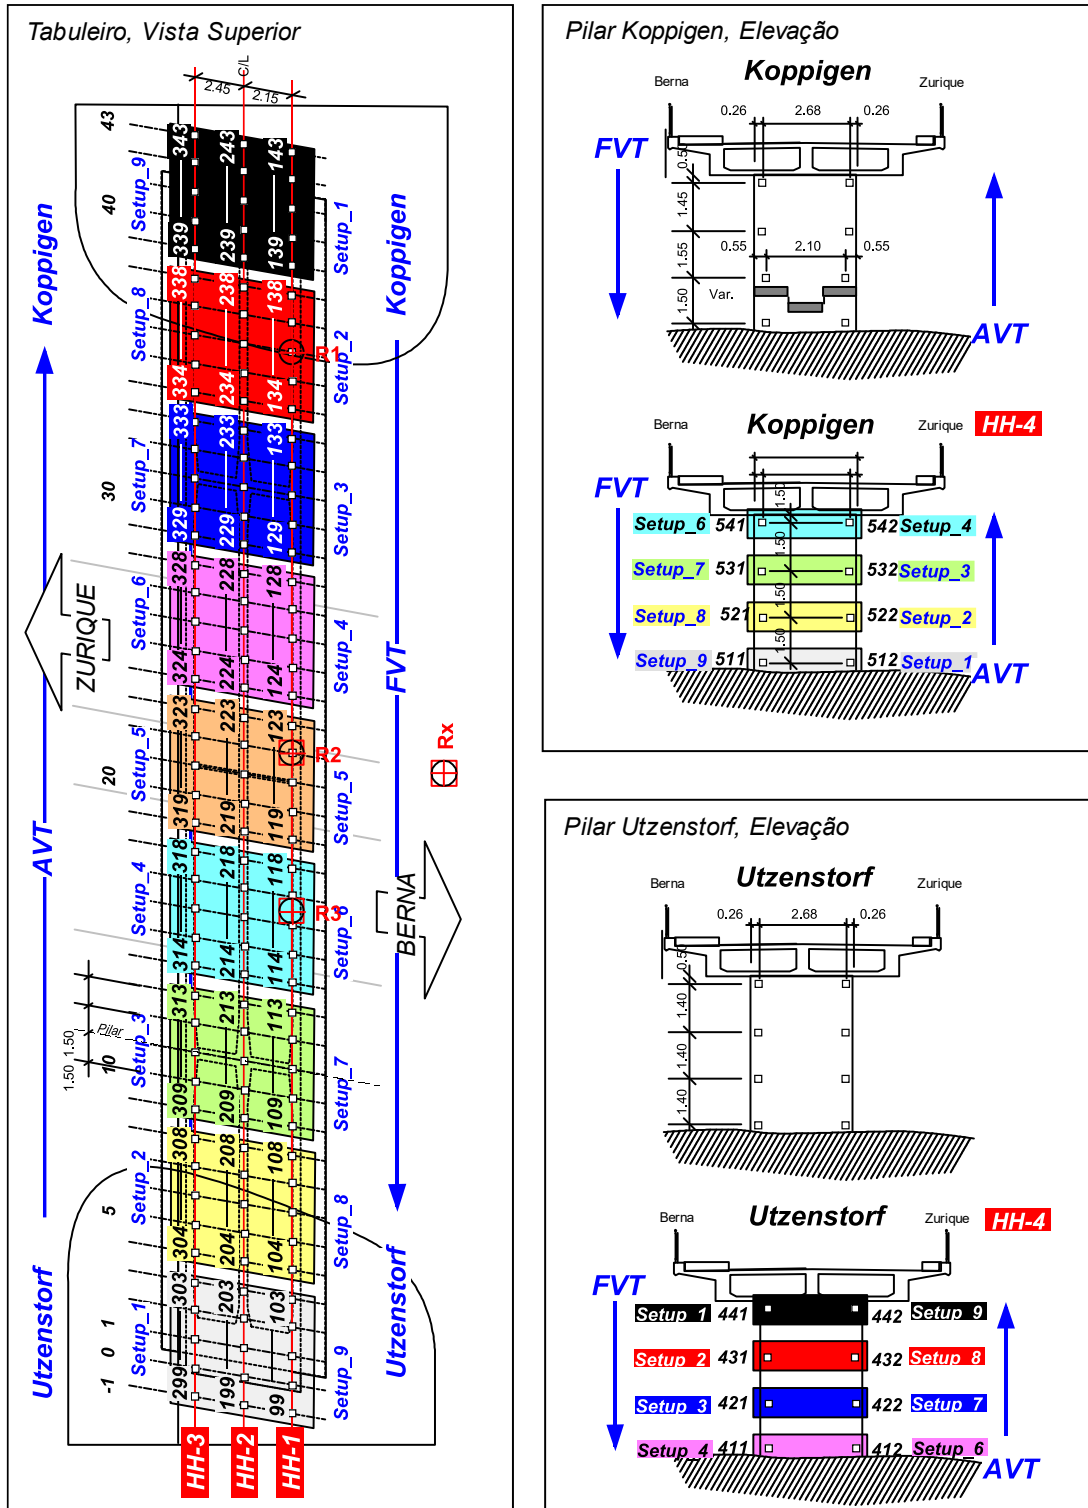


Figura 8.6 – Posição dos acelerômetros e sensores de referência (adaptado de KRÄMER, 1999)

8.1.2 Desenvolvimento e Atualização do Modelo em Elementos Finitos

O modelo numérico utilizado neste trabalho foi desenvolvido por Teughels e De Roeck (2004) e Reynders *et al.* (2010) no ANSYS com elementos de viga (6 graus de liberdade por nó). Os

autores modelaram a estrutura com 82 elementos na representação da viga e 44 elementos nos pilares e encontros, de acordo com a Figura 8.7. Inicialmente, considerou-se como módulo de elasticidade $E_0 = 37,5$ GPa e módulo de cisalhamento $G_0 = 20$ GPa. Elementos de massa foram acrescentados para representar as vigas transversais e fundações, considerando massas concentradas translacionais e componentes inerciais rotativos.




Figura 8.7 – Modelo FE da Ponte Z24 (adaptado de REYNDERS *et al.*, 2010)

Para representar a influência do solo no sistema, os autores incluíram elementos de mola ao redor dos pilares e na base dos encontros. Neste trabalho, com base em Reynders *et al.* (2010), os parâmetros de rigidez adotados para as molas foram:

- abaixo dos pilares ($x = 14$ e 44 m): $K_{v,p} = 180 \times 10^6$ N/m³ e $K_{h,p} = 210 \times 10^6$ N/m³;
- abaixo dos pilares dos encontros ($x = 0$ e 58 m): $K_{v,c} = K_{h,c} = 100 \times 10^6$ N/m³;
- nos encontros: $K_{v,a} = 180 \times 10^6$ N/m³ e $K_{h,a} = 200 \times 10^6$ N/m³;
- ao redor dos pilares: $K_{v,ac} = K_{h,ac} = 100 \times 10^6$ N/m³.

Então, esse modelo numérico teve os valores dos módulos de elasticidade e cisalhamento do tabuleiro da ponte e parâmetros de rigidez do solo atualizados de acordo com as seis frequências naturais identificadas no cenário íntegro apresentadas na Tabela 8.2. Isso foi feito por meio de um problema de minimização utilizando o Algoritmo de Otimização da Baleia e a função objetivo apresentada na equação 8.1.

$$\Pi(\phi) = \sum_{j=1}^{Nm} \frac{1}{2} \left[\left(\frac{\omega_j^2(\phi) - \tilde{\omega}_j^2}{\tilde{\omega}_j^2} \right)^2 \right] \quad (8.1)$$

Onde Nm é o número de modos analisados, $\tilde{\omega}_j$ é a frequência natural identificada do modo j , e ω_j é a frequência natural do modelo numérico em função das variáveis ϕ . Foram consideradas 36 variáveis a serem atualizadas: 17 módulos de elasticidade e 17 módulos de cisalhamento,

sendo os módulos dos elementos intermediários interpolados a partir dos elementos principais; e as rigidezes $K_{v,p}$ e $K_{h,a}$. A Figura 8.8 apresenta os resultados da atualização dos parâmetros de rigidez a flexão (EI_y) e a rigidez a torção (GI_x) em comparação com valores iniciais do modelo. Os valores atualizados para os parâmetros de rigidez do solo foram $K_{v,p} = 147,5 \times 10^6$ N/m³ e $K_{h,a} = 146,4 \times 10^6$ N/m³.




Figura 8.8 – Valores iniciais e atualizados da rigidez à flexão e rigidez à torção

As diferenças entre as frequências experimentais e numéricas do modelo atualizado foram menores que 1%, conforme a Tabela 8.4.

Tabela 8.4 – Frequências naturais experimentais e do modelo numérico (Hz)

Modo de vibração	Modelo FE		SSI-DATA	Diferença (%)
	Inicial	Atualizado		
1	3,73	3,86	3,87	-0,26
2	5,14	5,04	5,01	0,70
3	9,64	9,75	9,79	-0,33
4	10,25	10,37	10,31	0,52
5	12,52	12,81	12,79	0,14
6	13,35	13,39	13,50	-0,85

A partir do modelo atualizado, foram estabelecidas 9 regiões do tabuleiro da ponte, de acordo com a Figura 8.9, visando diminuir a quantidade de coeficientes de redução de rigidez nos métodos de detecção de dano. As regiões foram definidas buscando representar as áreas de influência dos pilares e encontros, além de partições da viga/tabuleiro.




Figura 8.9 – Regiões da Ponte Z24 para análise de dano

8.1.3 Detecção de Dano com Base na Atualização de Matrizes

A detecção de dano pelo algoritmo WOA na Ponte Z24 foi realizada utilizando apenas a primeira parcela da equação 5.3, ou seja, a função objetivo desse problema englobou a minimização da diferença entre as frequências naturais íntegras e danificadas ao invés da função multiobjetivo com a consideração das formas modais. Foram adotados 30 agentes de busca em 60 iterações. Assim, obteve-se a solução apresentada na Figura 8.10.

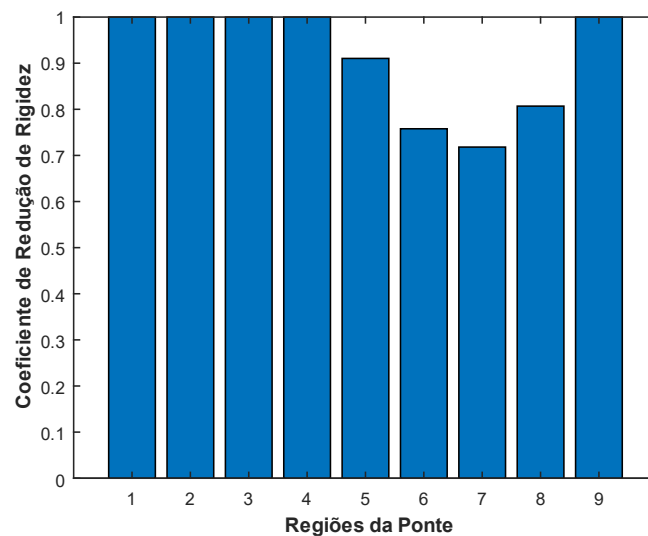


Figura 8.10 – WOA: Ponte Z24

8.1.4 Detecção de Dano com Base em Redes Neurais

Para o treinamento da rede neural da Ponte Z24, usaram-se como dados de entrada as seis primeiras frequências naturais. Como dados de saída, foram adotadas as regiões do tabuleiro da estrutura de forma similar ao método anterior. Dessa forma, os dados de treinamento foram criados a partir do modelo de elementos finitos com casos de dano simples. Nesses cenários, as

variações da redução de rigidez em cada elemento foram de 20% a 95% em intervalos de 5%, totalizando 144 conjuntos. Após alguns testes da rede, optou-se por acrescentar os casos do cenário íntegro do modelo numérico e experimental nos dados de treinamento. Além disso, utilizaram-se três camadas ocultas com 5, 18 e 9 neurônios, formando a arquitetura apresentada na Figura 8.11. Então, gerou-se a solução apresentada na Figura 8.12.




Figura 8.11 – Arquitetura da rede neural proposta para a Ponte Z24




Figura 8.12 – ANN: Ponte Z24

8.1.5 Comparação dos Resultados das Metodologias Aplicadas

No caso da Ponte Z24, ambos os métodos de detecção de dano conseguiram localizar a região danificada principal (região 7), onde ocorreu o recalque da fundação do pilar e as rachaduras nas regiões adjacentes da viga. Os danos secundários de fissuração nas regiões vizinhas ao pilar (regiões 6 e 8) também foram localizados pelo método com base na atualização de matrizes, sendo apenas a região 6 identificada no método baseado em redes neurais. Contudo, por não haver uma resposta quantitativa real, não foi possível verificar os níveis de dano identificados, principalmente porque as duas metodologias tiveram resultados distintos, como apresentado na Tabela 8.5. Além disso, destaca-se que imprecisões em elementos não danificados foram

encontradas nas duas soluções, chegando em uma redução de rigidez de 8,97% pelo algoritmo WOA e 4,76% pela ANN na região 5.

Tabela 8.5 – Situação de dano estimada para a Ponte Z24

Região	Dano estimado	
	WOA	ANN
1	1	1,0019
2	1	0,9826
3	1	1,0436
4	1	1,0424
5	0,9103	0,9524
6	0,7578	0,9324
7	0,7181	0,3842
8	0,8069	1,0034
9	1	0,9986

Vale ressaltar que o modelo de elementos finitos adotado como base para os dois métodos é simplificado, sendo construído apenas com elementos de barra com seis graus de liberdade por nó. Dessa forma, as metodologias poderiam apresentar resultados mais precisos caso fosse adotado um modelo numérico mais robusto. Porém, além de gerar um maior custo operacional, não há informações suficientes das características físicas e geométricas da ponte na literatura, portanto, diversos parâmetros precisariam ser estimados.

Outro fator que pode ter impactado nos resultados obtidos pelo método de detecção de dano com base na atualização de matrizes foi a desconsideração das formas modais, devido as diferenças entre os modelos experimentais e numéricos. Entretanto, após a atualização do modelo FE o sistema deixou de ser simétrico, o que permitiu a identificação, localização e quantificação de dano com as seis primeiras frequências naturais (primeira parcela da equação 5.3).

9 CONSIDERAÇÕES FINAIS

Este trabalho abordou a aplicação e comparação de métodos de detecção de dano com base na atualização de matrizes e em redes neurais por meio de simulações numéricas e ensaios experimentais, a partir de dados obtidos pela identificação estocástica de sistemas. Inicialmente, apresentou-se o Método de Identificação Estocástica de Subespaço baseado nas séries temporais, que foi implementado numericamente em Matlab, para obtenção dos parâmetros modais de estruturas, como frequências naturais e formas modais. Todos os sistemas e casos avaliados tiveram modelos dinâmicos desenvolvidos em elementos finitos, seja por meio do desenvolvimento de modelos FE de barras no Matlab ou pela utilização do *software* ANSYS. Assim, nas estruturas estudadas através de dados numéricos (viga engastada-livre, treliça de 10 barras e passarela de pedestres) ou experimentais (régua metálica e Ponte Z24) foi possível avaliar o desempenho das metodologias estudadas para identificar, localizar e quantificar dano. Destacam-se como principais conclusões dessa dissertação:

- O método de identificação de sistemas utilizado, o SSI-DATA, provou ser eficiente para identificação de frequências naturais e formas modais dos primeiros modos de vibração de estruturas. Desse modo, esse método se mostra uma ferramenta robusta na aquisição dos parâmetros modais no âmbito de construções civis.
- O algoritmo de otimização utilizado, o WOA, se mostrou como uma ótima ferramenta na localização e quantificação de dano no método baseado na atualização das matrizes, além de superar resultados encontrados por outros autores na literatura.
- As redes neurais artificiais apresentaram resultados promissores na localização e quantificação de dano, porém a metodologia utilizada nesse trabalho traz limitações de desempenho na etapa de treinamento. Isso ocorreu com a consideração de um número elevado de coeficientes de redução de rigidez como dados de saída, mesmo com a variação da arquitetura da rede e parâmetros de treinamento.
- No ensaio experimental desenvolvido, verificou-se que os dois métodos estudados são eficazes na localização e quantificação de danos simples, principalmente em cenários de maior redução de rigidez. Já nos casos de dano múltiplo, os métodos apresentaram maiores imprecisões em elementos vizinhos aos elementos

danificados, porém, com reduções de rigidez maiores que 40%, foi possível localizar e quantificar corretamente os elementos com dano.

- No estudo da Ponte Z24, foi possível verificar a eficácia dos dois métodos na localização de dano provando que ambas as metodologias podem ser empregadas em estruturas civis reais. Além disso, mesmo com a adoção de um modelo em elementos finitos simplificado, de regiões da estrutura para condensação dos coeficientes de rigidez e de avaliação baseada apenas nas frequências naturais, os métodos conseguiram estimar possíveis danos causados pelo recalque de fundação. Entretanto, se nessa análise houvesse diferenças maiores que 5% entre as frequências do modelo numérico e as frequências experimentais a detecção de dano poderia ser inviabilizada, principalmente no método baseado em redes neurais que utilizaram como dados de treinamento resultados do modelo FE. Por isso, salienta-se a necessidade da atualização de modelos numéricos seguindo os parâmetros modais experimentais.

As metodologias de detecção de dano desenvolvidas a partir de dados obtidos pelo Monitoramento de Integridade Estrutural podem ser usadas em trabalhos futuros no estudo de novas estruturas, ou até mesmo visando o aprimoramento dentro dos níveis de detecção de dano de Rytter (1993). Como principais sugestões para trabalhos futuros têm-se:

- instrumentação e monitoramento de uma estrutura civil a longo prazo buscando acompanhar possíveis deteriorações e a influência da variação da temperatura nos parâmetros modais no sistema;
- uso de outros parâmetros modais e suas derivadas, como as razões de amortecimento e energia de deformação modal, nos métodos de detecção de dano com base na atualização de matrizes e redes neurais;
- estudo de diferentes métodos de atualização de modelos numéricos, buscando reproduzir de forma fidedigna os parâmetros modais das estruturas;
- aplicação de novas técnicas da disciplina de Aprendizado de Máquina para a detecção de dano, tais como: Regressão de Vetores de Suporte (*Support Vector Regression – SVR*) e Regressão por Processos Gaussianos (*Gaussian Process Regression – GPR*).

REFERÊNCIAS

ABDEL WAHAB, M. M.; DE ROECK, G. Damage Detection in Bridges Using Modal Curvatures: Application to a Real Damage Scenario. **Journal of Sound and Vibration**. V. 226, n. 2, p. 217-235. 1999.

AKAIKE, H. Stochastic Theory of Minimal Realization. **IEEE Transactions on Automatic Control**. V. 19, n. 6, p.667-674. 1974.

ALLEMANG, R. J. The Modal Assurance Criterion (MAC): Twenty Years of Use and Abuse. In: Proceedings of the 20th International Modal Analysis Conference (IMAC), 2002, Los Angeles, California, USA. **Proceedings...** Los Angeles: IMAC, 2002.

ALLEMANG, R. J.; BROWN, D. L. A Correlation Coefficient for Modal Vector Analysis. In: Proceedings of the 1st International Modal Analysis Conference (IMAC), 1982, Orlando, Florida, USA. **Proceedings...** Orlando: IMAC, 1982. p. 110-116.

ALTAMMAR, H.; DHINGRA, A.; KAUL, S. Use of Wavelets for Mixed-Mode Damage Diagnostics in Warren Truss Structures. In: Proceedings of the ASME 2014 International Design Engineering Technical Conferences & Computers and Information in Engineering Conference (IDETC/CIE), 2014, Buffalo, New York, USA. **Proceedings...** Buffalo: IDETC/CIE, 2014.

AMANI, M. G. **Identificación de sistemas y evaluación del daño estructural**. 2004. 159 f. Tesis (Doctorado en Ingeniería Estructural) – Instituto de Estructuras/Facultad de Ciencias Exactas y Tecnología, Universidad Nacional de Tucumán, Tucumán.

AMANI, M. G.; RIERA, J. D.; CURADELLI, R. O. Identification of changes in the stiffness and damping matrices of linear structures through ambient vibrations. **Structural Control and Health Monitoring**. V. 14, n. 9, p. 1155-1169. 2007.

AN, Y.; CHATZI, E.; SIM, S-H.; LAFLAMME, S.; BLACHOWSKI, B.; OU, J. Recent progress and future trends on damage identification methods for bridge structures. **Structural Control and Health Monitoring**. V. 26:e2416. 2019.

BEGAMBRE, O.; LAIER, J. E. A hybrid Particle Swarm Optimization – Simplex algorithm (PSOS) for structural damage identification. **Advances in Engineering Software**. V. 40, p. 883-891. 2009.

BENDAT, J. S.; PIERSOL, A. G. **Engineering Applications of Correlation and Spectral Analysis**. 2nd ed. New York: Wiley, 1993.

BERNAL, D. Load Vectors for Damage Localization. **Journal of Engineering Mechanics**. V. 128, n. 1, p. 7-14. 2002.

BRINCKER, R.; ZHANG, L.; ANDERSEN, P. Modal Identification from Ambient Responses using Frequency Domain Decomposition. In: Proceedings of the International Modal Analysis Conference (IMAC), 18., 2000, San Antonio. **Proceedings...** Santo Antonio: IMAC, 2000, p. 625-630.

CARDEN, E. P.; FANNING, P. Vibration Based Condition Monitoring: A Review. **Structural Health Monitoring**. V. 3, n. 4, p. 355-377. 2004.

CARINI, M. R. **Identificação das Propriedades Dinâmicas de Estruturas submetidas a Ações Ambientais**. 2021. 245 f. Tese (Doutorado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre.

CHANG, P. C.; FLATAU, A.; LIU, S. C. Review Paper: Health Monitoring of Civil Infrastructure. **Structural Health Monitoring**. V. 2, n. 3, p. 257-267. 2003.

COLE, H. A. On-the-line analysis of random vibrations. In: AIAA/ASME Structural Dynamics and Materials Conference, 9., 1968, Palm Springs. **Proceedings...** Palm Springs: American Institute of Aeronautics and Astronautics, 1968.

CORNWELL, P.; DOEBLING, S. W.; FARRAR, C. R. Application of The Strain Energy Damage Detection Method to Plate-Like Structures. **Journal of Sound and Vibration**. V. 224, n. 2, p. 359-374. 1999.

CURADELLI, R. O.; RIERA, J. D.; AMBROSINI, D.; AMANI, M. G. Damage detection by means of structural damping identification. **Engineering Structures**. V. 30, p. 3497-3504. 2008.

DE ROECK, G. The state-of-the-art of damage detection by vibration monitoring: the SIMCES experience. **Journal of Structural Control**. V. 10, p. 127-134. 2003.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. E.; SHEVITZ, D. W. **Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in Their Vibration Characteristics: A Literature Review**. Los Alamos Laboratory Report LA-13070-MS, Los Alamos, EUA, 1996.

FADEL MIGUEL, L. F. **Identificação de Sistemas e Avaliação da Integridade de Estruturas Treliçadas**. 2007. 184 f. Tese (Doutorado em Estruturas) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre.

FADEL MIGUEL, L. F.; LOPEZ, R. H.; MIGUEL, L. F. F. A hybrid approach for damage detection of structures under operational condition. **Journal of Sound and Vibration**. V.332, n. 18, p. 4241-4260. 2013.

FADEL MIGUEL, L. F.; MIGUEL, L. F. F.; KAMINSKI Jr., J.; RIERA, J. D. Damage detection under ambient vibration by harmony search algorithm. **Expert Systems with Applications**. V. 39, n. 10, p. 9704-9714. 2012.

FAN, W.; QIAO, P. A strain energy-based damage severity correction factor method for damage identification in plate-type structures. **Mechanical Systems and Signal Processing**. V. 28, p. 660-678. 2012.

FAN, W.; QIAO, P. Vibration-based Damage Identification Methods: A Review and Comparative Study. **Structural Health Monitoring**. V. 10, n. 1, p. 83-111. 2011.

FARRAR, C. R.; DOEBLING, S. W. An overview of modal-based damage identification methods. In: Proceedings of the EUROMECH 365, International Workshop: DAMAS 97, 1997, Sheffield, United Kingdom. **Proceedings...** Sheffield: DAMAS 97, 1997.

FARRAR, C. R.; DOEBLING, S. W., NIX, D. A. Vibration-based structural damage identification. **Philosophical Transactions**. V. 359, n. 1778, p. 131-149. 2001.

FARRAR, C. R.; WORDEN, K. **Structural health monitoring: a machine learning perspective**. John Wiley & Sons, 2012. 643 p.

GARCIA-PEREZ, A.; AMEZQUITA-SANCHEZ, J. P.; DOMINGUEZ-GONZALEZ, A.; SEDAGHATI, R.; OSORNIO-RIOS, R.; ROMERO-TRONCOSO, R. J. Fused empirical mode decomposition and wavelets for locating combined damage in a truss-type structure through vibration analysis. **Journal of Zhejiang University-SCIENCE A (Applied Physics & Engineering)**. V. 14, n. 9, p. 615-630. 2013.

GKM CONSULTANTS. **Structural health monitoring overview**. Disponível em: <<https://www.gkmconsultants.com/en/applications/structural-health/>> acesso em 04/08/2022.

GUO, H. Y.; LI, Z. L. Structural damage identification based on Bayesian theory and improved immune genetic algorithm. **Expert Systems with Applications**. V. 39, p. 6426-6434. 2012.

HEARN, G.; TESTA, R. B. Modal Analysis for Damage Detection in Structures. **Journal of Structural Engineering**. V. 117, n. 10, p. 3042-3063. 1991.

IBRAHIM, S. R.; MIKULCIK, E. C. A Time Domain Modal Vibration Test Technique. **The Shock and Vibration Bulletin**. Washington, D.C., v. 43, n. 4, p. 21-37, 1973.

JUANG, J. N. **Applied System Identification**. New Jersey: Prentice Hall, 1994. 394 p.

JUANG, J. N.; PAPPA, R. S. An Eigensystem Realization Algorithm for Modal Parameter Identification and Model Reduction. **Journal of Guidance Control and Dynamics**. Hampton, v. 8, n. 5, p. 620-627, 1985.

JULIANI, T. M. **Detecção de danos em pontes em escala reduzida pela identificação modal estocástica**. 2014. 189 f. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

KAMINSKI JR, J.; RIERA, J. D. Structural damage detection by means vibration test. **Proceedings of the 14th International Conference on Structural Mechanics in Reactor Technology – SMiRT 14**. Lyon, France, 1997. **Proceedings...** Lyon: SMiRT 14, 1997.

KRÄMER, C. **Brite-Euram Project SIMCES, Task A1 and A2: long term monitoring and bridge tests**. Technical report 168'349/20e, EMPA, Dübendorf, Switzerland, 1999.

LIEW, K. M.; WANG, Q. Application of Wavelet Theory for Crack Identification in Structures. **Journal of Engineering Mechanics**. V. 124, n. 2, p. 152-157. 1998.

MASCIOTTA, M.-G.; RAMOS, L. F. LOURENÇO, P. B.; VASTA, M.; DE ROECK, G. A spectrum-driven damage identification technique: Application and validation through the numerical simulation of the Z24 Bridge. **Mechanical Systems and Signal Processing**. V. 70-71, p. 578-600. 2016.

MAECK, J.; DE ROCK, G. Description of Z24 Benchmark. **Mechanical Systems and Signal Processing**. V. 17, p. 127-131. 2003.

MEHRJOO, M.; KHAJI, N.; MOHARRAMI, H.; BAHREININEJAD, A. Damage detection of truss bridge joints using Artificial Neural Networks. **Expert Systems with Applications**. V. 35, n. 3, p. 1122-1131. 2008.

MIRJALILI, S. **The Whale Optimization Algorithm**. 2016. MATLAB Central File Exchange, disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/55667-the-whale-optimization-algorithm>>, acesso em 14/06/2022.

MIRJALILI, S.; LEWIS, A. The Whale Optimization Algorithm. **Advances in Engineering Software**. V. 95, p. 51-67. 2016.

MONTEIRO, D. K. **Finite Element Method (FEM): bar elements (Version 1)**. Zenodo, 2022. Disponível em: <<https://doi.org/10.5281/zenodo.7434774>>, acesso em 02/02/2023.

MONTEIRO, D. K. **Numerical methods for evaluation of dynamic response (Version 1)**. Zenodo, 2022. Disponível em: <<https://doi.org/10.5281/zenodo.7062895>>, acesso em 02/02/2023.

MONTEIRO, D. K. **Numerical implementation of the data-driven stochastic subspace identification (SSI-DATA) (Version 2)**. Zenodo, 2022. Disponível em: <<https://doi.org/10.5281/zenodo.7352986>>, acesso em 02/02/2023.

NEWLAND, D. E. **An Introduction to Random Vibrations, Spectral & Wavelet Analysis**. 3rd ed., Mineola, New York: Dover Publications, 2005. 477 p.

NUNES, D. S. **Identificação de Sistemas e Detecção de Danos de Estruturas Estaiadas**. 2019. 286 f. Tese (Doutorado em Estruturas e Construção Civil) – Departamento de Engenharia Civil e Ambiental, Faculdade de Tecnologia, Universidade de Brasília, Brasília.

PANDEY, A. K.; BISWAS, M.; SAMMAN, M. M. Damage detection from changes in curvature mode shapes. **Journal of Sound and Vibration**. V. 145, n. 2, p. 321-332. 1991.

PEETERS, B. **System identification and damage detection in civil engineering**. 2000. 238 f. Proefschrift (Doctoraat in de toegepaste wetenschappen) – Departement Burgerlijke Bouwkunde, Katholieke Universiteit Leuven, Leuven.

PEETERS, B.; VAN DER AUWERAER, H. PolyMAX: a revolution in operational modal analysis. In: International Operational Modal Analysis Conference, 1st, 2005, Copenhagen. **Proceedings...** Copenhagen: IOMAC, 2005.

REN, W. X.; LIN, Y. Q.; FANG, S. E. Structural damage detection based on stochastic subspace identification and statistical pattern recognition: I. Theory. **Smart Materials and Structures**. V. 20, n. 11. 2011.

REN, W. X.; ZONG, Z. H. Output-only modal parameter identification of civil engineering structures. **Structural Engineering and Mechanics**. Taejon (Korea), v. 17, n. 3-4. 2004.

REYNDERS, E. System Identification Methods for (Operational) Modal Analysis: Review and Comparison. **Archives of Computational Methods in Engineering**. V.19, p. 51-124. 2012.

REYNDERS, E.; TEUGHEL, A.; DE ROECK, G. Finite element model updating and structural damage identification using OMAX data. **Mechanical Systems and Signal Processing**. V. 24, p. 1306-1323. 2010.

RODRIGUES, J. **Identificação Modal Estocástica: Métodos de análise e aplicações em estruturas de engenharia civil**. 2004. 526 f. Tese (Doutorado em Engenharia Civil) – Faculdade de Engenharia, Universidade do Porto, Porto.

RYTTER, A. **Vibrational Based Inspection of Civil Engineering Structures**. 1993. 206 f. Ph.D. Dissertation – Department of Building Technology and Structural Engineering, Aalborg University, Denmark, 1993.

SALAWU, O. S. Detection of structural damage through changes in frequency a review. **Engineering Structures**. V. 19, n. 9, p. 718-723. 1997.

SHI, Z. Y.; LAW, S. S. Structural Damage Localization from Modal Strain Energy Change. **Journal of Sound and Vibration**. V. 218, n. 5, p. 825-844. 1998.

SHIH, H. W.; THAMBIRATNAM, D. P.; CHAN, T. H. T. Damage detection in truss bridges using vibration based multi-criteria approach. **Structural Engineering and Mechanics**. V. 39, n. 2, p. 187-206. 2011.

SOHN, H.; LAW, K. H. A Bayesian Probabilistic Approach for Structure Damage Detection. **Earthquake Engineering and Structural Dynamics**. V. 26, p. 1259-1281. 1997.

SRINIVAS, V.; RAMANJANEYULU, K.; ANTONY JEYASEHAR, C. Multi-stage approach for structural damage identification using modal strain energy and evolutionary optimization techniques. **Structural Health Monitoring**. V. 10, n. 2, p. 219-230. 2010.

TEUGHEL, A.; DE ROECK, G. Structural damage identification of the highway bridge Z24 by FE model updating. **Journal of Sound and Vibration**. V. 278, p.589-610. 2004.

TRAN-NGOC, T.; KHATIR, S.; DE ROECK, G.; BUI-TIEN, T.; ABDEL WAHAB, M. An efficient artificial neural network for damage detection in bridges and beam-like structures by improving training parameters using cuckoo search algorithm. **Engineering Structures**. V. 199, 109637. 2019.

VAN OVERSCHEE, P.; DE MOOR, B. **Subspace identification for linear systems: Theory - Implementation - Applications**. Leuven: Kluwer Academic Publishers, 1996. 254 p.

VILLALBA, J. D.; LAIER, J. E. Detecção De Dano Estrutural Utilizando Redes Neurais Artificiais: Um estado do Arte. **Cadernos de Engenharia de Estruturas**. São Carlos, v. 17, n. 67, p. 1-19. 2017.

VOLD, H.; KUNDRAT, J.; ROCKLIN, G. T.; RUSSEL, R. A Multi-Input Modal Estimation Algorithm for Mini-Computers. **SAE Technical Paper Series**. Detroit, v. 91, n. 1, p. 815- 821, 1982.

WU, X.; GHABOUSSI, J.; GARRETT JR., J. H. Use of Neural Networks in Detection of Structural Damage. **Computers & Structures**. V.42, n. 4, p. 649-659. 1992.

ZENI, G. **Detecção de Dano em Estruturas Utilizando Identificação Modal Estocástica e um Algoritmo de Otimização**. 2018. 87 f. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre.

ZHAO, Y.; GONG, M.; ZUO, Z.; GAO, Y. Bayesian estimation approach based on modified SCAM algorithm and its application in structural damage identification. **Structural Control and Health Monitoring**. V.28, n. 1, p. 1-20. 2020.

ZHENG, W.; SHEN, J.; WANG, J. Improved Computational Framework for Efficient Bayesian Probabilistic Inference of Damage in Truss Structures Based on Vibration Measurements. **Transportation Research Record**. N. 2460, p. 117-127. Washington, D.C., 2014.

ANEXO A




Figura A.1 – Resultados de Zeni (2018) para a viga com 3% de ruído e excitação ambiental:
(a) cenário 1, (b) cenário 2, (c) cenário 3




Figura A.2 – Resultados de Zeni (2018) para a viga com 5% de ruído e excitação ambiental:
(a) cenário 1, (b) cenário 2, (c) cenário 3




Figura A.3 – Resultados de Fadel Miguel *et al.* (2012) para a viga com 3% de ruído e excitação ambiental: (a) cenário 1, (b) cenário 2




Figura A.4 – Resultados de Fadel Miguel *et al.* (2013) para a viga com 3% de ruído e excitação ambiental: (a) cenário 1, (b) cenário 2