



Vítor Abrahão Gonçalves

**Identificação modal de danos em passarelas
metálicas com uso de Redes Neurais Artificiais**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Civil do Departamento de Engenharia Civil e Ambiental da PUC-Rio.

Orientadora: Prof^a. Elisa Dominguez Sotelino

Coorientador: Cássio Marques Rodrigues Gaspar

Rio de Janeiro
Setembro de 2021

Vítor Abrahão Gonçalves

**Identificação modal de danos em passarelas
metálicas com uso de Redes Neurais Artificiais**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Engenharia Civil do Departamento de Engenharia Civil e Ambiental da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Prof^a. Dra. Elisa Dominguez Sotelino

Orientador

Departamento de Engenharia Civil e Ambiental – PUC-Rio

Dr. Cássio Marques Rodrigues Gaspar

Coorientador

Departamento de Engenharia Civil e Ambiental – PUC-Rio

Prof. Dr. Paulo Batista Gonçalves

Departamento de Engenharia Civil e Ambiental – PUC-Rio

Prof. Dr. Diogo Rodrigo Ribeiro

Instituto de Engenharia do Porto - ISEP-IPP

Rio de Janeiro, 20 de setembro de 2021

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Vítor Abrahão Gonçalves

O autor é graduado em Engenharia Civil pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) em 2018. Ingressou no programa de Mestrado Acadêmico na PUC-Rio em fevereiro de 2019, tendo interesse nas áreas de pesquisa relacionadas à dinâmica das estruturas, detecção de danos e ao aprendizado de máquina.

Ficha Catalográfica

Gonçalves, Vítor Abrahão

Identificação modal de danos em passarelas metálicas com uso de redes neurais artificiais / Vítor Abrahão Gonçalves ; orientadora: Elisa Dominguez Sotelino ; coorientador: Cássio Marques Rodrigues Gaspar. – 2021.

90 f. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil e Ambiental, 2021.

Inclui bibliografia

1. Engenharia Civil e Ambiental - Teses. 2. Detecção de danos. 3. Dinâmica. 4. Passarela metálica. 5. Redes neurais artificiais. I. Sotelino, Elisa Dominguez. II. Gaspar, Cássio Marques Rodrigues. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Civil e Ambiental. IV.

CDD: 624

Agradecimentos

Agradeço primeiramente aos meus orientadores Elisa D. Sotelino e Cássio Marques Rodrigues Gaspar por toda orientação, paciência e conselhos oferecidos durante a elaboração deste trabalho. Todos os conhecimentos passados foram de extrema importância para o meu crescimento pessoal e profissional.

Ao CNPq, por investir na produção científica nacional e possibilitar o desenvolvimento desta pesquisa.

Agradeço aos colegas e professores da pós-graduação de engenharia civil da PUC-Rio que cruzaram o meu caminho e que tiveram uma parcela de contribuição para o desenvolvimento final deste trabalho. Principalmente ao Caio e ao Gabriel, que tanto me auxiliaram na execução deste trabalho.

Agradeço também aos professores Paulo Batista Gonçalves e Diogo Rodrigo Ribeiro, membros da banca examinadora, por terem aceitado contribuir com este trabalho.

Aos meus amigos Christovam, Felipe, Lucian, Ronald e Vitor, que estiveram comigo durante esta caminhada.

À minha família, por todo o suporte e incentivo durante o mestrado. Principalmente aos meus pais Rogério e Fabiana, e minha madrasta e padrasto, Juliana e Vilmar, pelo carinho, paciência e dedicação para a formação do ser humano que sou hoje.

À minha namorada, Giovanna, pelo companheirismo, apoio e paciência durante esta fase, estando do meu lado em todas as situações, compartilhando grandes trocas e aprendizados.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Resumo

Gonçalves, Vítor Abrahão; Sotelino, Elisa Dominguez (Orientadora); Gaspar, Cássio Marques Rodrigues (Coorientador). **Identificação modal de danos em passarelas metálicas com uso de Redes Neurais Artificiais**. Rio de Janeiro, 2021. 90p. Dissertação de Mestrado - Departamento de Engenharia Civil e Ambiental, Pontifícia Universidade Católica do Rio de Janeiro.

As estruturas civis durante toda a sua vida útil estão sujeitas a diversas ações de deterioração, desgastes ou corrosão de seus membros, que podem gerar variações em suas características físicas. Estas ações podem causar danos ao seu funcionamento, podendo chegar até ao colapso, em casos mais extremos. Além disso, o avanço tecnológico que permite a concepção de estruturas cada vez mais esbeltas, e que geram assim possíveis vibrações excessivas, elevam o monitoramento estrutural a um patamar de extrema importância e atenção na ótica dos gestores desses sistemas. Particularmente, no caso de obras de infraestrutura como pontes e passarelas, as grandes dimensões são características significativas que tornam as práticas de monitoramento e inspeção mais difíceis. Dessa forma, com o objetivo auxiliar no monitoramento estrutural e direcionar inspeções visuais, diversos métodos de identificação de danos são estudados com base nas características dinâmicas das estruturas, como as frequências naturais e os modos de vibração. A revisão de literatura, porém, demonstra que há uma dificuldade na aplicação desta identificação em estruturas mais complexas de grande porte. Assim, este trabalho visa estudar esta dificuldade e propor uma solução baseada na construção de um índice, composto pelos modos de vibração. Além disso, através da aplicação de algoritmos de aprendizado de máquina e de reconhecimento de padrões, como as Redes Neurais Artificiais (RNAs), propõe-se aumentar a eficiência do processo de localização espacial e quantificação dos danos. Em seguida, a metodologia proposta é, então, aplicada em um modelo de passarela metálica inspirado em uma estrutura real presente na região do Terminal Centro Olímpico da cidade do Rio de Janeiro – RJ. A identificação de danos é estudada através da aplicação do índice proposto, incorporando as redes neurais e avaliando o impacto da variação dos parâmetros da RNA na eficiência global da detecção.

Palavras-chave

Detecção de danos; dinâmica de estruturas; passarela; redes neurais artificiais; estruturas 3D; variação dos modos de vibração.

Abstract

Gonçalves, Vítor Abrahão; Sotelino, Elisa Dominguez (Orientadora); Gaspar, Cassio Marques Rodrigues (Coorientador). **Modal identification of damage in steel footbridges using Artificial Neural Network**. Rio de Janeiro, 2021. 90p. Dissertação de Mestrado - Departamento de Engenharia Civil e Ambiental, Pontifícia Universidade Católica do Rio de Janeiro.

Civil structures are subjected to different deterioration and corrosion actions throughout their entire service life, which can generate variations in their physical characteristics. These actions can cause damage to its functioning, and possibly leading to collapse in more severe cases. In addition, technology development which allows the design of increasingly slender structures, can produce excessive vibrations, which elevates the importance of structural monitoring to a higher level from the perspective of infrastructure managers. Particularly, in the case of bridges and walkaways, due to their large dimensions make monitoring and inspection even more difficult. Thus, with the aim of providing methods to assist in structural monitoring and facilitate visual inspections, several damage identification methods are investigated, which are based on structures dynamic characteristics, such as natural frequencies and mode shapes. The conducted literature review revealed that there is a difficulty in applying these identification methods in large-scale and complex structures. Thus, this research aims to study these barriers and propose a solution based on the development of a new damage index based on the structure's mode shapes. Furthermore, through the application of machine learning algorithms and pattern recognition, such as Artificial Neural Networks (ANN), it is proposed to increase the efficiency of the damage identification and quantification process. Then, the proposed methodology is tested numerically on a steel footbridge model inspired by a real structure located in the region of the Olympic Center Terminal, in the city of Rio de Janeiro – RJ. The damage identification method is studied through the application of the proposed damage index, incorporating the neural network and assessing the impact of ANNs parameters variation in the global efficiency of the damage detection method.

Keywords

Damage detection; structural dynamics; footbridge; artificial neural network; 3D structures; mode shape shifts.

Sumário

1 Introdução	16
1.1. Motivação.....	16
1.2. Objetivo	17
1.3. Metodologia	18
1.4. Estrutura do trabalho	18
2 Revisão da Literatura	20
2.1. Metodologia de pesquisa.....	20
2.1.1. Formulação das perguntas	21
2.1.2. Localização dos estudos.....	21
2.1.3. Análise e seleção quantitativa	24
2.1.4. Análise qualitativa	25
2.2. Resultados	26
2.3. Revisão dos trabalhos	27
2.3.1. Índices dinâmicos de dano	27
2.3.2. Redes Neurais Artificiais.....	36
2.4. Conclusões da revisão sistemática da literatura	40
3 Método de pesquisa	41
3.1. Índices de dano	41
3.1.1. Frequências naturais	41
3.1.2. Curvatura modal	44
3.1.3. Flexibilidade modal	46
3.1.4. Energia de deformação modal.....	46
3.2. Vetor resultante	48
3.3. Redes neurais artificiais	50
4 Aplicação.....	53
4.1. Apresentação da estrutura	53

4.2. Modelagem numérica.....	55
4.3. Comportamento dinâmico.....	57
4.4. Simulação de danos artificiais.....	58
4.5. Vetor Resultante.....	60
4.6. Redes Neurais Artificiais.....	62
4.6.1. Banco de dados.....	63
4.6.2. Pré-processamento dos dados.....	64
4.6.3. Rede Neural 1: Localização do dano.....	64
4.6.4. Rede Neural 2: Quantificação do dano.....	69
4.7. Resultados.....	73
5 Conclusões e investigações futuras.....	78
5.1. Conclusões.....	78
5.2. Sugestões para investigações futuras.....	79
6 Referências bibliográficas.....	81
Apêndice.....	87
Apêndice A – Resultado conjunto das Redes 1 e 2 para um conjunto de teste de 131 dados.	87

Lista de figuras

Figura 2.1 – Etapas de uma revisão sistemática da literatura.....	20
Figura 2.2 – Árvore de palavras-chave.	22
Figura 2.3 – Análise de relação entre palavras-chave: a) Rede de relevância e conexões; b) Rede para um exemplo do termo “Damage Index”.	23
Figura 2.4 – Processo de análise quantitativa.....	25
Figura 2.5 – Número de trabalhos entre 2000 e 2020.....	26
Figura 2.6 – MSE nas direções vertical (Stubbs), transversal e axial (Adaptado de Li et al., 2006)	34
Figura 2.7– Exemplo de configuração de uma rede de múltiplas camadas.	37
Figura 3.1 – Resposta da variação das frequências naturais em um pórtico 2D submetido a danos simétricos. a) Estrutura do pórtico; b) Variação das frequências naturais.	42
Figura 3.2 - Variação das frequências naturais do pórtico para danos de 30%, 60% e 90% de intensidade.....	43
Figura 3.3 – Resposta da variação da curvatura modal para um dano simulado próximo ao pilar. a) estrutura 3D, o dano introduzido e o indicado pela curvatura; b) Resposta gráfica para a variação da curvatura modal.	45
Figura 3.4 – Oito primeiros modos de vibração.....	45
Figura 3.5 – Variação da flexibilidade modal para um dano próximo ao pilar interno.....	46
Figura 3.6 - Variação da energia de deformação modal nas na direção a) vertical (Z) e b) longitudinal (X)	48
Figura 3.7 – Representação gráfica do Vetor Resultante.	49
Figura 3.8 - Variação do Vetor Resultante para um dano próximo ao pilar.	50
Figura 3.9 - Processos de localização e quantificação de danos.....	51
Figura 4.1 – Localização da estrutura (Google Maps, 2020).....	53
Figura 4.2 – Estrutura da passarela setorizada.....	54
Figura 4.3 – Seção transversal do modelo computacional da passarela .	54

Figura 4.4 – Modelo adaptado da passarela real. a) Modelo estrutural no <i>software</i> Revit, da Autodesk; b) Modelo de cálculo (numérico).....	55
Figura 4.5 - Componentes da estrutura do modelo.....	56
Figura 4.6 – Condições de contorno do modelo.....	56
Figura 4.7 – Oito primeiros modos de vibração da passarela e suas respectivas frequências naturais	58
Figura 4.8 - Setor da estrutura com seção transversal de espessura diferente	59
Figura 4.9 – a) Setor do dano simulado; b) Detalhe do dano aproximado.	60
Figura 4.10 – a) Setorização da passarela e o dano inserido no setor C; b) Variação do índice de dano VR para um dano no setor C; c) Média da variação do índice VR por setor.	61
Figura 4.11 – a) Setorização da passarela e danos inseridos; b) Variação do VR para dano de 60% no setor F; c) Variação do VR para dano de 30% no setor K.....	62
Figura 4.12 - Exemplo de dados para um único cenário de dano.	64
Figura 4.13 - Velocidade de convergência entre as funções a) Tanh e b) Sigmoidal avaliando o decaimento da função erro de acordo com o número de épocas.....	66
Figura 4.14 – a) Configuração final da rede neural de localização; b) funções de ativação entre as camadas da rede 1.	67
Figura 4.15 – Variação das funções de a) Acurácia e b) Erro para as fases de treinamento e validação da rede	69
Figura 4.16 – Decaimento do erro nas fases de validação e treinamento para as funções de ativação a) Tanh e b) Sigmoidal.	71
Figura 4.17 – a) Configuração final da rede neural de quantificação; b) funções de ativação entre as camadas da rede 2.	73
Figura 4.18 – Modelos de avaliação de eficiência das redes 1 e 2 para as fases de treinamento, validação e teste.	74
Figura 4.19 – Matriz de confusão na avaliação do conjunto de teste para a Rede 1.....	75
Figura 4.20 – Gráfico de avaliação da eficiência da Rede 2, com os valores de dano reais e os previstos pela rede.	75

Lista de tabelas

Tabela 2.1 – Formação de sentenças e resultado de busca das pesquisas	24
Tabela 2.2 – Resultado do número de trabalhos selecionados após os filtros quantitativo e qualitativo.	25
Tabela 2.3 – Resumo das principais vantagens, desvantagens e aplicações dos métodos estudados (Gonçalves et al., 2021).	35
Tabela 4.1 – Característica dos modos de vibração e frequências naturais do modelo da passarela	57
Tabela 4.2 - Danos simulados através de reduções específicas de seção transversal.....	59
Tabela 4.3 - Proporção dos dados para as fases de treinamento, validação e teste da rede neural	63
Tabela 4.4 – Avaliação da variação do número de camadas ocultas na eficiência da rede	67
Tabela 4.5 – Avaliação da variação da função de ativação na eficiência da rede	68
Tabela 4.6 – Avaliação da variação do método de inicialização dos pesos na eficiência da rede.....	68
Tabela 4.7 – Avaliação da variação do número de neurônios da camada oculta na eficiência da rede.....	68
Tabela 4.8 – Valores finais de erro e validação para a Rede 1.....	69
Tabela 4.9 – Avaliação do número de camadas ocultas para o menor erro na Rede 2	71
Tabela 4.10 – Avaliação da função de ativação nas camadas ocultas para o menor erro na Rede 2	71
Tabela 4.11 – Avaliação do método de inicialização dos pesos para o menor erro na Rede 2	72
Tabela 4.12 – Avaliação do número de neurônios nas camadas ocultas para o menor erro na Rede 2.	72

Tabela 4.13 – Erro absoluto médio para as fases de treinamento e validação da Rede 2.....	73
Tabela 4.14 – a) Exemplo dos dez primeiros resultados da Rede Neural 2 (quantificação); b) Resumo do erro do total de resultados para a Rede Neural 2.....	76
Tabela 4.15 – Exemplo das dez primeiras respostas dos dados de teste das redes 1 e 2 para localização e quantificação dos danos.	76
Tabela 4.16 – Eficiência global das redes de localização e quantificação.	77

Lista de abreviaturas

<i>ASTM</i>	<i>American Society for Testing Materials</i>
<i>BRT</i>	<i>Bus Rapid Train</i>
<i>FRF</i>	Função de resposta em frequência
<i>MSCS</i> <i>M</i>	<i>Mode Shape Curvature Square Magnitude</i>
<i>MSE</i>	<i>Modal Strain Energy</i>
<i>NBR</i>	Normas Técnicas Brasileiras
<i>RNA</i>	Redes Neurais Artificiais
<i>RSL</i>	Revisão Sistemática da Literatura
<i>SVM</i>	<i>Support Vector Machine</i>
<i>TANH</i>	Tangente Hiperbólica

Lista de símbolos

φ''	Curvatura modal
h	Distância entre dois nós de elementos finitos
φ	Modos de vibração
ω	Frequência natural circular
F	Flexibilidade modal
A	Variação da flexibilidade modal
b	Máximo valor de variação de flexibilidade modal
β	Energia de deformação modal
Z	Energia de deformação modal normalizada

f	Frequência natural
VR'	Vetor resultante
Δ	Variação
VR	Índice de dano do vetor resultante
μ	Média
σ	Desvio padrão

“O sucesso nasce do querer, da determinação e persistência em se chegar a um objetivo. Mesmo não atingindo o alvo, quem busca e vence obstáculos, no mínimo fará coisas admiráveis.”

José de Alencar

1

Introdução

1.1. Motivação

As atividades de manutenção e controle da integridade estrutural são objetos de ampla atenção por parte dos gestores responsáveis por grandes obras de infraestrutura. A ênfase em processos de manutenção possui uma significativa relevância quando se trata de estruturas de obras de arte especiais. Pontes, por exemplo, são consideradas estruturas de extrema importância, de alto valor e importante para as comunidades. Portanto, suas atividades de inspeção e monitoramento podem se apresentar como trabalhosas e de alto custo, devido às grandes dimensões (Webb et al., 2015).

O monitoramento estrutural, de acordo com Friedmann e Kraemer (2016), envolve o uso de sensores para aquisição e processamento de dados e é motivado pela necessidade de se preservar a condição do objeto monitorado ou obter informações sobre possíveis alterações que este objeto pode sofrer. Existem diversas maneiras de realizar monitoramento em estruturas, desde inspeções visuais como descritas pela NBR (Normas técnicas brasileiras), até uso de técnicas de detecção de danos com base em métodos de ensaios não-destrutivos.

As inspeções visuais, apesar de se tratarem – a priori – de um método simples, apresentam uma série de dificuldades quando a estrutura em questão apresenta grandes dimensões. O trabalho de inspeção para detectar alguma anomalia nos componentes estruturais pode necessitar de muito tempo e ser, muitas vezes, de extrema dificuldade dependendo da acessibilidade e das condições em que a estrutura está inserida (Gordan et al., 2020).

Por outro lado, com o auxílio de avanços tecnológicos e sensores cada vez mais precisos, o uso de dados de monitoramento para avaliar a condição estrutural é constantemente estudado (Cha et al., 2018).

Considerando a análise dinâmica das estruturas, as metodologias de identificação de danos, que incluem os dados monitorados, partem do princípio de que suas características, como as frequências naturais, modos de vibração e o amortecimento, são alteradas em função da presença de variações na condição estrutural, podendo ser referente às mudanças nas condições de contorno, alteração de rigidez ou massa de elementos ou qualquer outro fator que possa causar alguma modificação posterior na estrutura. E assim, identificando possíveis danos, é possível prevenir impactos negativos nos âmbitos sociais, econômicos, ecológicos e estéticos (Zonta and Adriaenssens, 2011). Além disso, apesar da temática de detecção de danos ser extremamente estudada no contexto mundial, destaca-se a carência do tema aplicada ao cenário brasileiro, despertando assim, o interesse pelo campo de estudo

1.2. Objetivo

O objetivo deste trabalho consiste em estabelecer uma metodologia eficiente de detecção de danos visando uma aplicação em modelos mais próximos às estruturas reais e seus comportamentos específicos. São discutidos os principais índices dinâmicos de danos e a capacidade de cada um deles para casos envolvendo estruturas de grande porte. O estudo busca chegar a um índice mais eficiente para aplicação em uma estrutura de passarela metálica inspirada em uma estrutura real, composta por diferentes curvaturas e elevações, o que gera comportamentos dinâmicos caracterizados por flexões verticais, horizontais, modos torcionais e modos combinados.

1.3. Metodologia

A base para a construção da metodologia proposta é composta por uma revisão sistemática da literatura, identificando as áreas de pesquisa existente em termos de detecção dinâmica de danos em estruturas e suas aplicações. A lacuna identificada na revisão remete às aplicações em estruturas mais complexas, com modelos em três dimensões que se aproximam às condições de estruturas reais. Nesse sentido, são avaliados os índices modais encontrados na literatura para identificação de danos, como as frequências naturais, os modos de vibração, a curvatura modal e a energia de deformação modal. São apresentadas as respectivas formulações e avaliadas as respostas de cada índice para aplicações em modelos reduzidos de estruturas em três dimensões, comentando os aspectos positivos e negativos. Devido às limitações existentes, um novo índice de dano é sugerido para melhor aplicação em uma estrutura de passarela mista.

Finalmente, é incorporado o uso de Redes Neurais Artificiais unido ao índice de dano proposto para tornar o processo mais eficiente, sendo então o método proposto capaz de prever a presença de um dano a partir de um conjunto de dados oriundos de um hipotético monitoramento.

1.4. Estrutura do trabalho

Este trabalho é organizado em cinco seções. O Capítulo 1 apresenta as motivações e a contextualização da área de identificação de danos, os objetivos e a metodologia que conduz esse estudo.

No Capítulo 2 é apresentado o processo de uma Revisão Sistemática da Literatura e suas fases. Esta revisão tem por finalidade identificar as principais pesquisas envolvendo o tema, avaliar a contribuição de cada autor, detectando áreas em que há um menor aprofundamento de conhecimento, e assim contribuir para o seu desenvolvimento.

O Capítulo 3 apresenta a metodologia proposta, com a análise dos índices de dano em diferentes aplicações e quais suas vantagens e

desvantagens. Através das conclusões apresentadas, busca-se a construção de um índice que possa melhorar a eficiência da identificação de danos em estruturas de grande porte, que são objeto de estudo desta pesquisa. A metodologia inclui ainda o uso de inteligência computacional para auxiliar na previsão de danos através das redes neurais artificiais.

Um exemplo de aplicação para a metodologia proposta é realizado no Capítulo 4. É apresentado um modelo numérico inspirado em uma estrutura de passarela metálica real, localizada na região do Terminal Centro Olímpico da cidade do Rio de Janeiro – RJ. O modelo de passarela busca abranger conceitos envolvendo estruturas com diferentes níveis e curvaturas, possuindo modos de vibração com comportamentos dinâmicos tridimensionais.

Por fim, o Capítulo 5 apresenta as principais conclusões sobre o estudo conduzido e sugestões de pesquisas futuras para auxiliar no preenchimento da lacuna de conhecimento encontrada na revisão de literatura.

2 Revisão da Literatura

Este capítulo aborda a metodologia adotada para identificação e avaliação do estado da arte acerca dos assuntos referentes à identificação dinâmica de danos em estruturas de grande porte e o auxílio de técnicas de inteligência computacional, mais especificamente Redes Neurais Artificiais (RNA). Estudos são realizados para identificação de lacunas dentro deste assunto e em como as Redes Neurais podem auxiliar no processo de identificação de danos através de índices dinâmicos.

2.1. Metodologia de pesquisa

Uma boa revisão de literatura é essencial para qualquer trabalho acadêmico, proporcionando bases para o avanço do conhecimento, facilitando o desenvolvimento de teorias, cobrindo áreas onde há diversas pesquisas existentes e realçando áreas onde ainda há necessidade de maior estudo (Webster et al., 2002). Com o objetivo de identificar as lacunas de conhecimento na literatura e atingir de forma mais precisa os temas necessários, é conduzida uma Revisão Sistemática da Literatura (RSL). Segundo Khan et al. (2003), o processo de uma RSL é subdividido em 5 etapas e descrito na Figura 2.1.



Figura 2.1 – Etapas de uma revisão sistemática da literatura.

2.1.1. Formulação das perguntas

Para nortear a pesquisa científica, são elaboradas perguntas que devem ser respondidas pelos trabalhos selecionados na revisão de literatura. Para o tema de índice de danos, as perguntas a serem respondidas são:

- (1) Quais os índices dinâmicos mais eficientes para identificação de danos em estruturas?
- (2) É possível aplicá-los em estruturas de grande porte?

Ao estudar trabalhos onde há o uso de algoritmos de aprendizado de máquina, há o acréscimo das perguntas:

- (3) Qual o impacto da aplicação de técnicas de inteligência artificial, em particular Redes Neurais, na identificação de danos?

2.1.2. Localização dos estudos

Após a formulação das perguntas, a segunda etapa da RSL consiste na localização dos estudos. A escolha das bases de dados e a construção das *strings* de busca são extremamente importantes para se construir uma revisão robusta e confiável.

Neste trabalho foram utilizadas quatro bases de dados: Scopus, Web of Science, ScienceDirect e Google Scholar. Para gerenciamento e organização dos trabalhos estudados, foram utilizados os *softwares* Mendeley e Microsoft Excel.

É construída uma árvore de palavras-chave para auxiliar na formação de frases de busca para o filtro dos trabalhos, mostrada na Figura 2.2. A formação desta árvore e, conseqüentemente, das sentenças de busca, é um processo cíclico que se retroalimenta e se atualiza. A análise de trabalhos filtrados por uma busca com um determinado número de palavras pode levar a identificação de novas palavras-chave e, conseqüentemente, novas sentenças de busca.

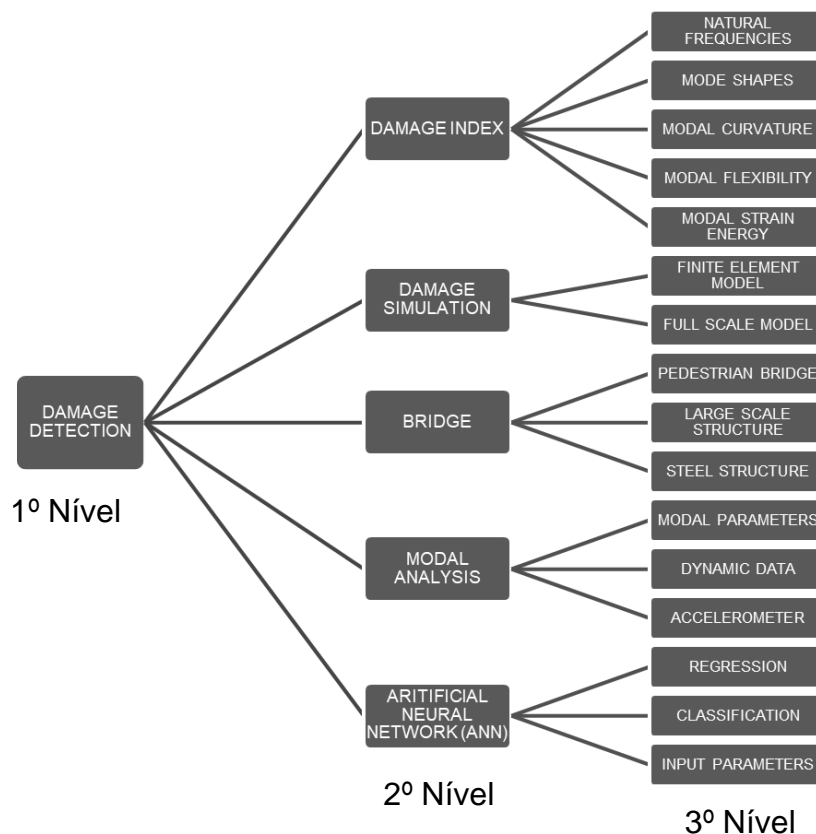


Figura 2.2 – Árvore de palavras-chave.

A formação destas sentenças é dada de forma sequencial de acordo com os níveis da árvore. A primeira busca é feita através das palavras do primeiro nível. Depois, soma-se o termo do segundo nível, construindo uma segunda sentença de busca, e finalmente pelos três níveis juntos para a terceira sentença de busca. Por exemplo, a primeira busca é feita com o termo "Damage Detection", na segunda fase a busca é feita pela sentença ("Damage Detection" E "Damage Index"), e no último estágio, a busca é feita através de ("Damage Detection" E "Damage Index" E "Natural Frequencies"). O conectivo "OU" (em inglês, "OR") é utilizado para aglutinar termos do terceiro nível em uma mesma sentença de busca, como por exemplo em: "Damage Index" E ("Natural Frequencies" OU "Mode Shapes").

Para auxiliar na identificação de palavras-chave e estudar as suas relações, é construída, com auxílio do *software* VOSViewer, uma nuvem de conexões entre das palavras-chave presente nas sentenças de busca. Todos os trabalhos resultados de uma sentença de busca específica são

Figura 2.3 – Análise de relação entre palavras-chave: a) Rede de relevância e conexões; b) Rede para um exemplo do termo “Damage Index”.

O resultado das buscas através das sentenças formadas é apresentado na Tabela 2.1. Nesta tabela estão listados os números de trabalhos encontrados após cada sentença de busca.

Tabela 2.1 – Formação de sentenças e resultado de busca das pesquisas

FORMAÇÃO DAS SENTENÇAS DE BUSCA						NÚMERO DE TRABALHOS ENCONTRADOS		
DAMAGE DETECTION	AND	DAMAGE INDEX	AND	NATURAL FREQUENCIES		70	TOTAL: 481	
				MODE SHAPES		63		
				MODAL CURVATURE		28		
				MODAL FLEXIBILITY		20		
				MODAL STRAIN ENERGY		27		
		DAMAGE SIMULATION		FINITE ELEMENT MODEL		35		
				FULL SCALE MODEL		14		
		BRIDGE		PEDESTRIAN BRIDGE		OR		108
				LARGE SCALE STRUCTURE				
				STEEL STRUCTURE				
		MODAL ANALYSIS		MODAL PARAMETERS		AND		24
				DYNAMIC DATA				
				ACCELEROMETER				
		ARTIFICIAL NEURAL NETWORK		REGRESSION		2		
				CLASSIFICATION		13		
				INPUT PARAMETERS		4		
						73		

2.1.3. Análise e seleção quantitativa

Na etapa de análise e seleção quantitativa são aplicados filtros para redução do número de trabalhos fora do escopo da pesquisa. Os filtros, como apresentado na Figura 2.4, são formados por uma análise de repetição, relevância e título. É inicialmente conduzida a análise de repetição para eliminar trabalhos que apareçam como resultado de diferentes sentenças de busca, evitando duplicidade. Assim, um mesmo trabalho que seja resultado de diferentes buscas, não será considerado mais de uma vez. Posteriormente é avaliada a relevância do trabalho de acordo com o número de citações e verificado o título da publicação para confirmar o pertencimento ao tema estudado. Após a aplicação destes filtros, o número de trabalhos reduz para um total de 174 (Figura. 2.4).



Figura 2.4 – Processo de análise quantitativa

2.1.4. Análise qualitativa

Após a análise quantitativa, é necessário que haja uma análise mais aprofundada dos trabalhos resultantes. Uma análise qualitativa composta pela leitura de cada resumo é conduzida para restringir apenas as publicações relevantes ao tema. Finalmente, o número de publicações após todos os filtros aplicados é 48.

A Tabela 2.2 descreve o número de pesquisas que foram aprovadas após a passagem por todos os filtros.

Tabela 2.2 – Resultado do número de trabalhos selecionados após os filtros quantitativo e qualitativo.

FORMAÇÃO DAS SENTENÇAS DE BUSCA					FILTRO QUANTITATIVO	FILTRO QUALITATIVO	TOTAL		
DAMAGE DETECTION	AND	DAMAGE INDEX	AND	NATURAL FREQUENCIES		11	22	48	
				MODE SHAPES		5			
				MODAL CURVATURE		6			
				MODAL FLEXIBILITY		4			
				MODAL STRAIN ENERGY		5			
		DAMAGE SIMULATION		FINITE ELEMENT MODEL		7	4		
				FULL SCALE MODEL		1			
		BRIDGE		PEDESTRIAN BRIDGE		OR	21		4
				LARGE SCALE STRUCTURE					
				STEEL STRUCTURE					
		MODAL ANALYSIS		MODAL PARAMETERS		AND	16		5
				DYNAMIC DATA					
				ACCELEROMETER					
		ARTIFICIAL NEURAL NETWORK		REGRESSION		2	13		
				CLASSIFICATION		8			
				INPUT PARAMETERS		2			
						20			

2.2. Resultados

Este capítulo apresenta a última etapa da RSL. A análise final dos trabalhos que passaram pelos filtros qualitativos e quantitativos e que então são estudados de forma completa. Um total de 48 artigos que envolvem os temas de detecção de danos, índices e uso de redes neurais artificiais compõem este conjunto.

A temática da identificação dinâmica de danos é um conceito já bastante explorado na literatura, com trabalhos publicados há mais de 30 anos. A evolução dos estudos busca identificar metodologias e índices que melhor representam um dano estrutural no estudo do comportamento dinâmico. A introdução de inteligência computacional no processo também é um tema que vem crescendo ao longo dos anos.

A Figura 2.5 demonstra graficamente a frequência de trabalhos referentes à identificação de danos, dentre aqueles selecionados nas etapas anteriores. Na figura são identificadas três linhas de pesquisa: estudos sobre desenvolvimento de índices de dano, uso de redes neurais artificiais no processo de identificação e a aplicação a estruturas de pontes. Pode-se perceber que a aplicação em estruturas reais de grandes dimensões, como pontes, possui uma tendência de crescimento nos últimos anos.




Figura 2.5 – Número de trabalhos entre 2000 e 2020.

2.3. Revisão dos trabalhos

Neste capítulo é feita a revisão dos artigos selecionados e comentado sobre as contribuições que os mesmos trazem a este trabalho. A revisão consiste em duas esferas: estudo dos índices de danos e utilização das redes neurais no processo de identificação de danos.

2.3.1. Índices dinâmicos de dano

Diversos índices de dano são estudados na área de monitoramento estrutural com base na resposta dinâmica das estruturas. Alguns são originários com base nos parâmetros modais clássicos como frequências naturais, modos de vibração e amortecimento, enquanto outros se utilizam de dados diretos do monitoramento, como por exemplo as acelerações.

De acordo com Zonta (2000), a captação de dados para identificação de danos em uma estrutura através da avaliação dos seus parâmetros modais pode ser classificada em dois tipos:

- Técnicas baseadas na identificação da variação da resposta de parâmetros modais clássicos. Normalmente neste caso é feita a análise comparativa entre o comportamento de dois modelos (intacto e danificado), sendo os dois necessários para a identificação.
- Técnicas baseadas na identificação de anomalias e não linearidades, como a presença de superharmônicos na resposta dinâmica da estrutura e variações no tempo da frequência de oscilação (Carminati et al., 2018). Neste caso a anomalia identificaria a presença do dano, sem a necessidade da comparação entre dois comportamentos da estrutura.

Devido à praticidade e facilidade do processo de captação de dados, este trabalho busca estudar os índices que se enquadram no primeiro tipo, a fim de avaliar a aplicabilidade em estruturas metálicas mais complexas e de dimensões reais.

2.3.1.1. Frequências naturais e modos de vibração

Os parâmetros modais de uma estrutura (modos de vibração, frequências naturais e amortecimento) são frequentemente utilizados como indicadores da presença de danos. A variação de rigidez causada por uma possível alteração da condição estrutural é refletida nesses parâmetros. Os modos de vibração e as frequências naturais são mais sensíveis a essas mudanças do que o amortecimento e este último não apresenta possíveis indicadores de variação devido à presença dos danos (Salawu and Williams, 1995).

No estudo de Kudus et al. (2018), é proposta uma abordagem onde são analisadas as mudanças visuais nos modos de vibração e a variação das frequências naturais. Uma redução de 75% na espessura de uma viga tubular ocasiona uma maior variação do modo de vibração que apresenta uma maior resposta modal na região próxima ao dano. Dessa forma, dependendo de cada posição e intensidade do dano, tem-se um modo mais afetado. Entretanto, a pequena dimensão de um dano em comparação com uma estrutura de grande porte diminui a sensibilidade da análise e inviabiliza a sua aplicação. Os autores Contursi et al. (1998) e Clayton et al. (2005) utilizam as frequências naturais como indicador de dano em estruturas de pórtico 2D e de uma viga engastada-livre, respectivamente. Os estudos atestam que apenas as frequências não são capazes de localizar o dano devido ao alto nível de contaminação de ruído que este dado pode carregar do monitoramento, e dos possíveis erros causados pela simetria do dano em relação à estrutura, que pode gerar a mesma variação de frequência para danos em diferentes locais. O estudo de Contursi et al. (1998) ainda indica que é necessário um alto número de modos de vibração para que o índice seja eficiente (de 10 a 15 modos). Entretanto, Shi et al. (2000) expande o método para contemplar modos de vibração parciais, isto é, em situações em que a aquisição de dados de monitoramento não é suficiente para a construção de modos.

Para superar o problema da simetria, Mekjavić and Damjanović (2016) usaram algumas técnicas de modelagem para criar um modelo de viga não

simétrica, como: geração de malha assimétrica, mudança das condições de contorno e aplicação de massa concentrada. Tais manipulações propostas pelo autor se tornam inviáveis na aplicação de casos de estruturas de larga escala e com maiores complexidades de modelagem, objeto de análise deste trabalho.

Com o objetivo de aproximar a identificação de danos dos dados captados de monitoramento, Chao et al. (2014) propõem uma abordagem direta ao espectro de resposta dos sensores. Entretanto foi avaliado que em estruturas de grande porte, a variação insignificante das frequências naturais era incapaz de identificar a presença do dano, e estando também atado a um posicionamento eficiente dos sensores.

Blachowski et al. (2015) e (Tarozzi et al., 2020) estudam danos em conexões metálicas. Para os primeiros autores, a variação das frequências naturais traz as mesmas limitações dos trabalhos anteriores, e, portanto, é adotado um índice que avalia a rotação no plano dos modos de vibração de uma estrutura 2D. Este índice é eficiente na identificação do dano para a estrutura apresentada, devido ao seu caráter simples, porém a expansão para um modelo em três dimensões aumenta significativamente o número de variáveis, tornando-se extremamente trabalhosa. Já para o segundo estudo, os danos são corretamente identificados através da variação das frequências naturais em uma estrutura 3D retilínea.

2.3.1.2. Curvatura Modal

Na busca por um índice que avalie o dano localmente, o uso da variação da curvatura modal como indicativo de dano foi proposto por Pandey et al. (1991) em estruturas onde o momento fletor é o esforço mais significativo. Este método foi estudado em uma viga simplesmente apoiada e em uma viga em balanço, também estudada por Dawari et al. (2013). O uso da curvatura modal, φ'' , cuja formulação (Equação 1) é feita por aproximações de diferenças finitas centrais utilizando os modos de vibração, v_i , sendo “i-1”, “i” e “i+1” três nós consecutivos de um modelo de elementos finitos e “h” a distância entre os nós, se deu como uma solução

eficiente para solucionar a detecção do dano para estes casos. O índice então é resultado da diferença absoluta entre a curvatura de uma estrutura danificada (“*”) e em condições íntegras (Equação 2), e incorporada a influência dos modos (“n”) de vibração analisados (Equação 3). Desta forma torna-se necessário possuir o valor de três nós consecutivos definidos.

$$\varphi'' = \frac{\varphi_{i+1} - 2\varphi_i + \varphi_{i-1}}{h^2} \quad (1)$$

$$\Delta\varphi'' = \varphi'' - \varphi''^* \quad (2)$$

$$v'' = \sum_{i=1}^n \Delta\varphi'' \quad (3)$$

Shang (2018) e Zahrasadat Momenia e Ardalán Sabamehrb (2018) estudam a aplicação da curvatura modal em uma ponte retilínea, na busca pela adaptação do índice para aplicações em modelos mais sofisticados. Entretanto, apesar de estudar um modelo de estrutura em três dimensões, as análises são todas feitas em um único plano. Tal simplificação pode prejudicar identificação de danos em estruturas que apresentem variações significativas nas três dimensões.

Dawari et al. (2013) concluem que quanto mais alto é o modo de vibração, isto é, maior quantidade de antinós no modo de vibração de uma viga, maior é a magnitude do pico de variação absoluta da curvatura no ponto de dano. Uma vez que quanto maior o número de antinós, mais acentuada são as curvaturas da forma modal e, portanto, melhor é a identificação do dano.

Por outro lado, o método da curvatura possui limitações em regiões de apoio. Rucevskis et al. (2010) modificam o índice e utilizam o quadrado da Curvatura dos Modos de Vibração (*Mode Shape Curvature Square Magnitude* – MSCSM) como índice para localização do dano em uma viga metálica em condição livre-livre e biengastada. O método tem a vantagem de não necessitar dos dados da estrutura intacta para fazer a análise da localidade do dano, porém apresenta-se dependente das condições de

contorno da estrutura, visto que, para a condição livre-livre inicial, o mesmo indicou falsos danos nas extremidades, enquanto que, para a condição biengastada, os autores recomendam o seu uso.

2.3.1.3. Flexibilidade Modal

O uso da matriz de Flexibilidade Modal como índice de dano foi proposto por Pandey and Biswas (1994). A sua formulação incorpora com maior influência os modos de vibração, φ_i , associados a frequências (ω) mais baixas, como atestado pela Equação 4, o que é útil quando estes, por sua vez, são de maior interesse para o estudo do comportamento dinâmico do sistema estrutural investigado. A Equação 5 constrói a matriz de variação de flexibilidade, onde os subscritos “i” e “d” estão relacionados a estrutura intacta e danificada, respectivamente. Finalmente, a Equação 6 identifica, para cada grau de liberdade, o maior valor correspondente de variação.

$$F = \sum_{i=1}^n \frac{1}{\omega^2} \varphi_i \varphi_i^T \quad (4)$$

$$A = Fi - Fd \quad (5)$$

$$b = \max | \ddot{o}_{ij} | \quad (6)$$

Assim, através dos dados de monitoramento obtidos pelos sensores, os autores atestam a validade do método e concluem que há uma maior eficiência da variação flexibilidade em regiões de maior momento fletor.

Jun Zhao (1999) avalia a sensibilidade da variação das frequências naturais, dos modos de vibração e da flexibilidade modal para um modelo reduzido de viga contínua e atesta que o último reflete melhor a presença de um dano estrutural. Apesar da afirmação de Pandey e Biswas (1994) sobre a maior eficiência do índice para danos em regiões de maior momento fletor, como em apoios rígidos, Chiniforush et al. (2017) alertam para a possíveis falsos positivos nestas regiões. Este fato se deve à ocorrência de problemas de singularidades nos cálculos dos modos de

vibração, pois nestas regiões estes são muito próximos de zero. Além de desconsiderar dados próximo aos apoios, os autores também atestam que os maiores valores da variação da flexibilidade modal ocorriam fora das áreas danificadas.

A identificação de danos pode também ser vista pela ótica de um problema de otimização, como estudado por Corrêa et al. (2016), que utilizaram a matriz de flexibilidade em estudo de identificação de danos em placas. O estudo caracteriza a identificação do dano como um problema de otimização, onde o objetivo é minimizar uma função definida pela variação da matriz de flexibilidade da estrutura intacta e de possíveis situações de danos. A metodologia de otimização apresentou um custo computacional alto para a minimização da função, devido à alta quantidade de nós do modelo de elementos finitos. Como solução, foi estabelecido que só seriam analisados danos em estágio inicial (<25%), que atingiam poucos nós da malha. A tendência para grandes estruturas é que esse alto custo cresça ainda mais devido à grande quantidade de nós.

Objetivando a melhorar a identificação de danos em estruturas mais semelhante às condições reais, com modos de vibração tridimensionais, Jayasundara et al. (2019) apresentam uma metodologia de análise bidirecional da variação da flexibilidade modal para uma ponte retilínea em arco. Os autores constroem o índice utilizando as direções vertical e horizontal dos modos de vibração, para assim conseguir captar as variações de forma mais completa e identificar a região danificada.

2.3.1.4.

Energia de deformação modal

Stubbs et al. (1995) incorporaram a curvatura modal no cálculo da energia de deformação de uma viga de acordo com as Equações 7,8 e 9, e utilizam esta formulação como índice de dano. O método MSE (*Modal Strain Energy*) baseia-se na análise da variação da energia de deformação modal causada por reduções na rigidez dos elementos. A aplicabilidade do método em uma estrutura de tamanho real foi comprovada em um modelo numérico de uma ponte retilínea bi apoiada, em duas dimensões.

$$\beta_{ij} = \frac{[(\varphi_{ij}^*)^2 + \Sigma(\varphi_{ij}^*)^2] [\Sigma(\varphi_{ij}^*)]^2}{[(\varphi_{ij}^*)^2 + \Sigma(\varphi_{ij}^*)^2] [\Sigma(\varphi_{ij}^*)]^2} \quad (7)$$

$$\beta_i = \sum_{j=1}^n \frac{NUM_{ij}}{DEN_{ij}} \quad (8)$$

$$Z_i = \frac{(\beta_i - \bar{\beta}_i)}{\sigma_{\beta}} \quad (9)$$

Onde i é o número de modos de vibração, j o número de elementos, φ_{ij}^* a curvatura modal e o sobrescrito $*$ indica o termo referente a estrutura danificada. Na Equação 9, β_i é normalizado, onde $\bar{\beta}_i$ e σ_{β} são, respectivamente, os valores de média e desvio padrão de β_i , formando então, o indicador de dano (Z).

Para trazer o método para uma realidade mais próxima às estruturas reais, Li et al. (2006) aplicaram a o MSE em uma estrutura de torre metálica 3D. Nesse estudo, foi verificada a necessidade de incorporar duas direções na formulação do método, axial e transversal para poder capturar a resposta dos danos nos diferentes modos de vibração. Pode-se perceber a necessidade da decomposição do método em todas as direções para poder obter a resposta de cada dano de forma efetiva. A identificação de um dano em determinada posição na estrutura pode responder de forma diferente dependendo da direção em que o cálculo do índice é feito. Dessa forma, é necessária uma análise conjunta das três direções para chegar a uma conclusão eficiente sobre a presença do dano, contestando a efetividade do método original, que inclui apenas a coordenada vertical dos modos.

Esta variação no índice pode ser visualizada na Figura 2.6, onde é feita uma análise transversal, longitudinal e vertical (índice Stubbs) para o pórtico em questão. Nesta figura, percebe-se que um dano no elemento 18 é identificado apenas nos dois primeiros indicadores, enquanto um dano no elemento 22, apenas no indicador axial. Jayasundara et al. (2019) introduzem uma abordagem em duas direções, utilizando os modos de vibração vertical e lateral, para que sejam detectadas as variações dinâmicas causadas pelo dano inserido.




Figura 2.6 – MSE nas direções vertical (Stubbs), transversal e axial (Adaptado de Li et al., 2006)

O estudo de Farrar and Jauregui (1997) aponta um comparativo entre os métodos já descritos neste capítulo. Os autores concluem que, para um perfil metálico, apenas danos severos – onde a seção transversal é danificada na forma de um corte que abrange praticamente toda a alma do perfil – são identificados pelos índices, atestando pouca sensibilidade para danos mais leves.

2.3.1.5. Tabela Resumo

A revisão dos trabalhos mencionados acima aponta que a temática dos índices de dano é constantemente trabalhada, e sua eficiência é extremamente dependente da aplicação em que está submetida.

No estudo conduzido por Montalvão et al. (2006) acerca de uma série de índices, os autores então concluem que uma série de variáveis devem ser consideradas para a escolha do método mais efetivo. Cada método possui suas particularidades, vantagens e desvantagens, e cada comportamento estrutural irá demandar uma abordagem diferente e particular para chegar em uma maior eficiência. O autor ainda destaca que parâmetros muito sensíveis podem levar a falsos positivos, enquanto parâmetros menos sensíveis podem omitir algum dano presente.

Tabela 2.3 – Resumo das principais vantagens, desvantagens e aplicações dos métodos estudados (Gonçalves et al., 2021).

Método	Vantagens	Desvantagens	Aplicações
Frequências naturais e modos de vibração	Propriedades dinâmicas conhecidas e de relativamente fácil aquisição	A identificação não se dá de forma direta, observando apenas os picos de variação. Deve-se fazer uma análise dos dados na estrutura como um todo.	Adequado para estruturas 3D devido a capacidade de capturar deslocamentos em todas as direções e formas modais.
Curvatura Modal	Grande eficiência na localização direta da posição dos danos. Aplicação com o uso dos modos de vibração em apenas uma direção	Necessidade de uma continuidade dos dados para poder construir o gráfico de curvatura contínua. As condições de contorno livres podem ser responsáveis por erros.	Aplicação mais eficiente em estruturas de vigas pela continuidade da curvatura entre todos os pontos da estrutura. Condições de contorno influentes.
Flexibilidade Modal	Grande eficiência em estruturas mais flexíveis, que tornam o índice mais sensível, principalmente em áreas de maior momento fletor.	Dificuldade em áreas mais rígidas como regiões de apoios rígidos em que a variação do índice é muito pequena em comparação à outras regiões	Aplicação em estruturas de vigas ou placas. Condições de contorno influenciam na eficiência do índice quando aplicada em estruturas de maior porte.
Energia de deformação Modal (MSE)	Boa eficiência para localização e quantificação de danos em estruturas de grande porte. Baixo número de modos de vibração necessários para obter respostas eficientes.	Elementos que não tenham grandes participações na energia de deformação modal da estrutura não possuem respostas significativas.	Aplicação em estruturas 2D e 3D dependendo da quantidade de direções em que o método é aplicado. Melhores respostas em estruturas onde o momento fletor é mais importante.

Dessa maneira, a Tabela 2.3, apresentada por Gonçalves et al. (2021), aglutina as principais vantagens, desvantagens e aplicações que os métodos estudados são submetidos.

2.3.2. Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos, compostos por unidades de processamento simples interligadas, chamadas neurônios artificiais, capazes de armazenar informações, reconhecer e classificar padrões e fazer previsões (Araújo, 2017).

Os neurônios artificiais simulam o comportamento do corpo humano através de técnicas de inteligência artificial e são capazes de aprender, por meio de treinamentos, o comportamento de algum fenômeno. Esta previsão é feita baseada no ajuste de parâmetros (pesos) que possibilitam a interpolação de valores de acordo com os dados que são oferecidos à rede. Dessa forma, o resultado da rede é calculado como função direta dos dados de entrada e de seus pesos associados (Bishop, 1995). O valor de cada neurônio é calculado através da utilização de funções específicas, chamadas de funções de ativação.

Uma rede de uma camada é formada pelos seus neurônios de entrada, que recebem os dados que alimentam o processamento da rede, e os neurônios da camada de saída. Já uma rede de múltiplas camadas (Figura 2.7) apresenta, além das camadas de entrada e saída, uma camada intermediária (camada oculta) e, portanto, desempenhos computacionais mais eficientes que as redes de apenas uma camada (Marcy, 2013).




Figura 2.7– Exemplo de configuração de uma rede de múltiplas camadas.

O treinamento de uma rede neural pode ser classificado como supervisionado ou não-supervisionado. O primeiro consiste em oferecer à rede dados de entrada e a respectiva saída desejada para este conjunto de dados de entrada. Com o conjunto de dados, a rede vai atualizando os seus pesos através de algoritmos específicos com o objetivo de minimizar o erro entre a saída desejada e a resposta processada pela rede. Desta forma, após o ajuste final dos pesos no treinamento, a rede deve ser capaz de prever novos episódios, com novos dados de entrada. Já o treinamento não-supervisionado envolve não mais um mapeamento de entradas e saídas, mas sim uma modelagem da distribuição de probabilidade dos dados de entrada, fazendo com que o aprendizado seja possível através da percepção de padrões nos dados fornecidos (Bishop, 1995).

De acordo com Cutler and Dickenson (2020) há dois grandes tipos de problemas envolvendo técnicas de aprendizado supervisionado, problemas de classificação e problemas de regressão. Na classificação, a rede tem como objetivo prever a classe à qual pertence um evento caracterizado pelo conjunto de dados de entrada, enquanto nos problemas que envolvem técnicas de regressão, o objetivo da rede é regredir os valores de entrada a um valor contínuo.

A alta capacidade das Redes Neurais Artificiais em reconhecer padrões torna o método um grande aliado no processo de identificação de

danos. E juntamente com os índices de danos já apresentados, as RNAs apresentam diversos benefícios para a aumentar a eficiência da metodologia. Quando comparadas a outras técnicas de aprendizado de máquina, Gordan et al. (2020) afirmam que as redes neurais possuem maior flexibilidade, autonomia e precisão e, portanto, com menor erro na previsão dos resultados.

Redes Neurais com algoritmos de retropropagação (*Backpropagation*) são comumente utilizadas nos processos de identificação de danos (Machavaram and Shankar, 2012). Para alimentar as RNAs, diversos tipos de dados são inseridos. Desde os índices de danos apresentados até dados de monitoramento menos processados, como acelerações e FRFs (funções de resposta de frequência).

Os autores Wu et al. (1992) e Pathirage et al. (2018) utilizaram as redes neurais para prever o parâmetro de rigidez de cada elemento do modelo numérico através de dados de frequência natural e modos de vibração. Em modelos simples e com poucos elementos, a metodologia proposta é válida, entretanto, com o aumento das dimensões da estrutura e, conseqüentemente, do número de elementos do modelo, os erros aumentam e o custo computacional inviabiliza a aplicação.

Em estruturas de pórtico, Yun e Bahng (2000) e Yuen e Lam (2006) utilizaram as componentes dos modos de vibração para alimentar a rede, resultando em um bom reconhecimento de padrões de dano para uma estrutura 2D. O segundo trabalho tem como objetivo discutir a construção da rede neural e seus parâmetros, como número de camadas ocultas, número de neurônios nessas camadas e as funções de ativação mais eficientes, concluindo que cada aplicação específica demanda a configuração ideal para a rede neural utilizada.

O uso de índices de dano compostos por frequências naturais e modos de vibração são bastante usados como dados de entrada de RNAs pela praticidade e relativa facilidade de se medir estes dados (Kim et al., 2003). Porém, as frequências naturais, por exemplo, podem não ser uma boa alternativa pela sua pequena variação entre os estados intacto e com dano, principalmente em grandes estruturas, como já visto no Capítulo

2.3.1.1. Hakim and Abdul Razak (2011, 2013) utilizaram as frequências naturais como entrada da rede e chegaram à mesma conclusão.

Buscando encontrar índices eficientes para alimentar um algoritmo de rede neural, Ni et al. (2002) estudaram a construção de dados de entrada e concluíram que um par de índices formados pela variação das frequências naturais e a variação dos modos de vibração de forma conjunta pode aumentar a eficiência tanto da localização do dano quanto da quantificação. A variação das frequências naturais é utilizada na identificação da intensidade do dano devido a sensibilidade em relação à severidade e a insensibilidade em relação à localização. Pillai e Krishnapillai (2010) expandem a utilização deste par de dados para uma rede neural com aprendizado não-supervisionado e concluem que quanto maior o número de membros do modelo numérico, maior é o erro, podendo chegar em 30% a 40%.

O uso da flexibilidade modal como dado de entrada para uma rede também é estudado na literatura como feito por Zheng et al. (2003). Os autores incorporaram a flexibilidade aos dados de variação de modos de vibração e de frequências naturais formando um par de índices para cada nó do modelo de elementos finitos. Em modelos de estruturas de grande porte, a alta quantidade de nós aumenta a dificuldade em aplicar a metodologia proposta.

Assim como a flexibilidade, o índice MSE também é utilizado para alimentar uma rede neural como em Bagchi et al. (2010) e Tan et al. (2020). Assim como a utilização do índice sem o auxílio das RNAs, a eficiência do método está muito atrelada à contribuição que o elemento danificado possui na energia de deformação modal da estrutura. Se não houver contribuição efetiva, nem mesmo um dano de alta intensidade pode ser reconhecido.

Além dos índices de dano já estudados, a técnica de redes neurais também pode ser usada incorporando dados provenientes diretamente de monitoramentos através de sensores. Zang and Imregun (2001), Sun (2009) e Bandara et al. (2014) utilizaram as funções de resposta de frequência (FRFs) como dados de entrada da rede. Enquanto Neves et al. (2018), Finotti et al. (2019) e SILVA et al. (2020) usaram os dados de

aceleração como entrada. A vantagem desses métodos em relação àqueles que utilizam os índices de dano é que menos manipulações e transformações dos dados são necessárias para serem utilizados diretamente nas redes neurais. Entretanto, a quantidade de dados capturados pode ser muito maior, sendo necessária a aplicação de técnicas de redução de dimensionalidade para se alcançar a eficiência necessária.

2.4.

Conclusões da revisão sistemática da literatura

Diante dos trabalhos apresentados no Capítulo 2.3, identifica-se que há uma grande variabilidade de eficiência na aplicação de identificação de danos de acordo com a aplicação na qual a metodologia está submetida. O comportamento dinâmico individual das estruturas caracteriza essa variabilidade e impõe que uma análise seja feita acerca do índice de dano mais preciso.

Além disso, o uso das redes neurais tem sido comumente aliados aos índices de dano em estudos de identificação. Entretanto, assim como nas pesquisas envolvendo somente os índices de dano, o uso de redes neurais está atrelado em sua grande maioria às aplicações envolvendo estruturas simples, em duas dimensões e que não possuem as limitações impostas por modelos de estruturas reais, com comportamentos dinâmicos tridimensionais de flexão e torção.

Desta maneira, o Capítulo 3 deste trabalho propõe uma metodologia capaz de identificar a presença de danos em uma estrutura complexa de grande porte, considerando os modos tridimensionais de flexão vertical, lateral e torcional.

3

Método de pesquisa

Os estudos apresentados no Capítulo 2 indicam um interesse crescente sobre os índices utilizados para identificação de um dano em uma estrutura. Os índices dinâmicos apresentados possuem diferentes características e respostas particulares de acordo com o contexto em que são aplicados. A revisão da literatura demonstra uma falta de conclusões acerca da utilização destes índices em estruturas mais complexas e de grande porte que fogem dos padrões retilíneos e em duas dimensões, como acontece em grande parte dos trabalhos.

3.1.

Índices de dano

Os índices dinâmicos possuem diversas características que podem limitar ou aumentar a eficiência da identificação de danos de acordo com a estrutura em que são aplicados. Como afirmado por Montalvão et al. (2006), deve-se avaliar a sensibilidade de cada índice na situação em que está aplicado, pois cada comportamento estrutural irá demandar uma metodologia diferente para atingir uma boa eficiência. As subseções a seguir analisam a aplicabilidade desses índices através de exemplos numéricos desenvolvidos pelo autor no ambiente do *software* Robot Structural Analysis da Autodesk.

3.1.1.

Frequências naturais

As frequências naturais podem se apresentar como bons indicativos para evidenciar a presença de um possível dano estrutural. A variação das frequências pode indicar que algum membro pode ter sofrido alguma modificação e que é refletida no seu comportamento dinâmico.

A identificação desta variação, entretanto, é feita de forma global, isto é, o local exato do dano não pode ser identificado apenas com a informação das frequências naturais e sim apenas apresentar indicativos de que há alguma mudança no comportamento da estrutura como um todo. Além disso, a eficiência da análise está condicionada às dimensões do dano em relação à estrutura. Dependendo desta proporção de dimensões, é possível que um dano se torne imperceptível na ótica da variação das frequências naturais.

Para analisar este índice, é construído um modelo de pórtico 2D com dimensões indicadas na Figura 3.1a. O modelo possui todos os seus membros com seções transversais tubulares metálicas (aço ASTM A588-50) de 273x15,1mm. As condições de contorno adotadas para o modelo são dois apoios de segundo gênero na base do pórtico.

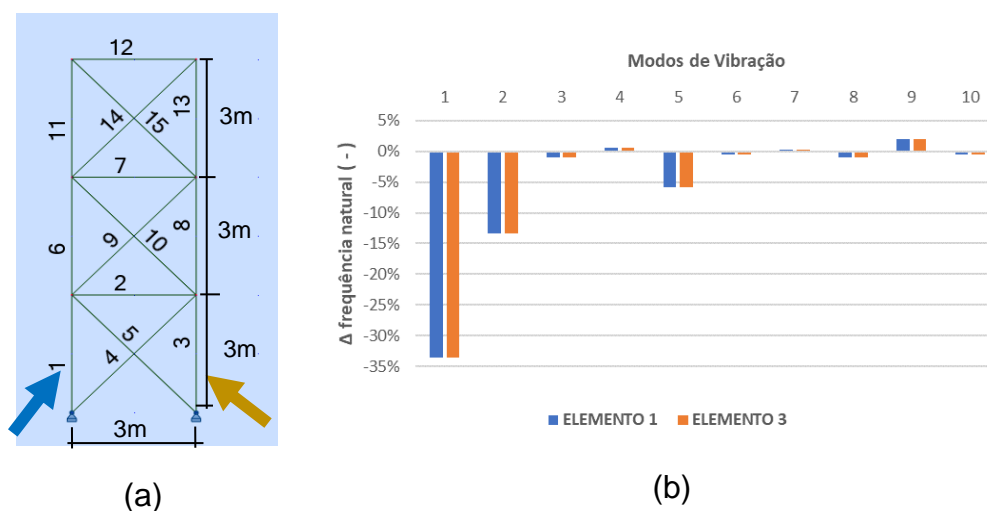


Figura 3.1 – Resposta da variação das frequências naturais em um pórtico 2D submetido a danos simétricos. a) Estrutura do pórtico; b) Variação das frequências naturais.

Como apontado por Contursi et al. (1998) e Clayton et al. (2005) no Capítulo 2.3.1.1, em estruturas simétricas como o pórtico 2D, a variação das frequências naturais é exatamente igual quando um dano é introduzido em elementos simétricos. Por exemplo, um dano introduzido nos elementos 1 e 3, individualmente, gera a mesma variação $[(f_{\text{intacto}} - f_{\text{dano}})/f_{\text{intacto}}]$ para as

dez primeiras frequências naturais. O dano para este caso é gerado em todo o elemento na forma de redução da espessura da seção transversal tubular metálica, como feito por Kudus et al. (2018). O resultado da variação das frequências naturais nos dois casos é apresentado no gráfico da Figura 3.1b.

Por outro lado, há uma sensibilidade da variação das frequências naturais na diferenciação da intensidade do dano presente na estrutura. Introduzindo um dano no elemento 1 do mesmo pórtico 2D da Figura 3.1 e variando a sua intensidade em 30%, 60% e 90%, que representam a porcentagem de redução da espessura da seção transversal, a variação das frequências naturais acompanha este aumento do dano. Como mostrado na Figura 3.2, para a primeira frequência natural, por exemplo, um dano de 30% gera uma redução de 5%, enquanto para danos de 60% e 90%, as reduções são aproximadamente 15% e 33%, respectivamente. Para o segundo modo de vibração, a redução na frequência natural para os danos de 30%, 60% e 90% são, respectivamente, de 2%, 6% e 13%, enquanto para os demais modos, esta variação não se apresenta significativa.




Figura 3.2 - Variação das frequências naturais do pórtico para danos de 30%, 60% e 90% de intensidade.

3.1.2. Curvatura modal

Utilizando os modos de vibração de uma estrutura, o uso da variação da curvatura modal se apresenta como um indicativo de dano eficiente para estruturas sujeitas à flexão. Em uma estrutura 2D simples, como uma viga ou pórtico, este índice apresenta boa eficiência como visto pelos estudos apresentados no Capítulo 2.

Para uma análise envolvendo uma estrutura em três dimensões, é utilizado como modelo de referência o trecho retilíneo (I e II) do modelo da Figura 4.4b, assim como utilizada as seções transversais indicadas na Figura 4.3. Este modelo (Figura 3.3a), possui dois vãos (12m e 26m) e oito modos de vibração – variando de 2,68 Hz a 13,88 Hz – que envolvem torções, flexões laterais e verticais (Figura 3.4), a eficiência decai significativamente. Um dano de grande intensidade (90% de redução de rigidez) gerado na forma de redução de seção transversal em uma região próxima ao pilar de apoio central – uma região mais rígida se comparado com o centro do vão, por exemplo – apresenta uma resposta equivocada para a identificação do dano. A Figura 3.3b apresenta a resposta da variação da curvatura [Equações (1),(2) e (3)] para as vigas do modelo de acordo com a sequência de nós da estrutura. Apesar do dano estar localizado próximo ao pilar, o pico de maior variação acontece em uma região próxima ao centro do vão, isto é, uma região mais flexível, exemplificando uma grande limitação. Como abordado no Capítulo 2, Pandey et al. (1991) utilizam a curvatura pela maior sensibilidade que a mesma possui em danos com intensidade abaixo de 50% de redução na rigidez, entretanto essa conclusão não é válida para a tipologia da estrutura aplicada.

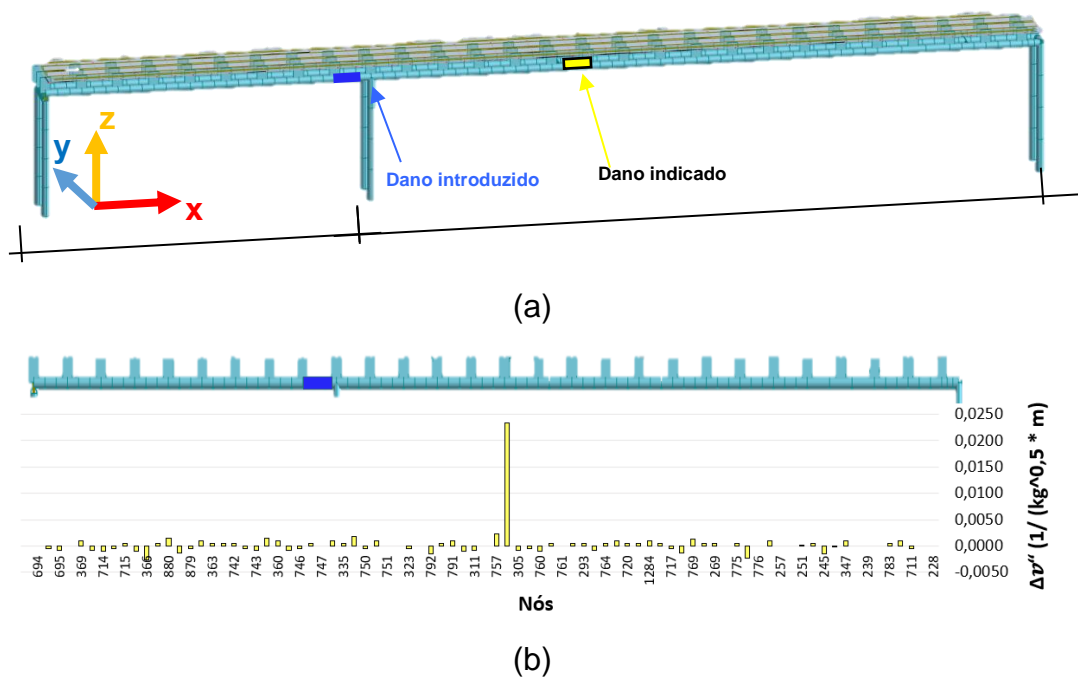


Figura 3.3 – Resposta da variação da curvatura modal para um dano simulado próximo ao pilar. a) estrutura 3D, o dano introduzido e o indicado pela curvatura; b)

Resposta gráfica para a variação da curvatura modal.

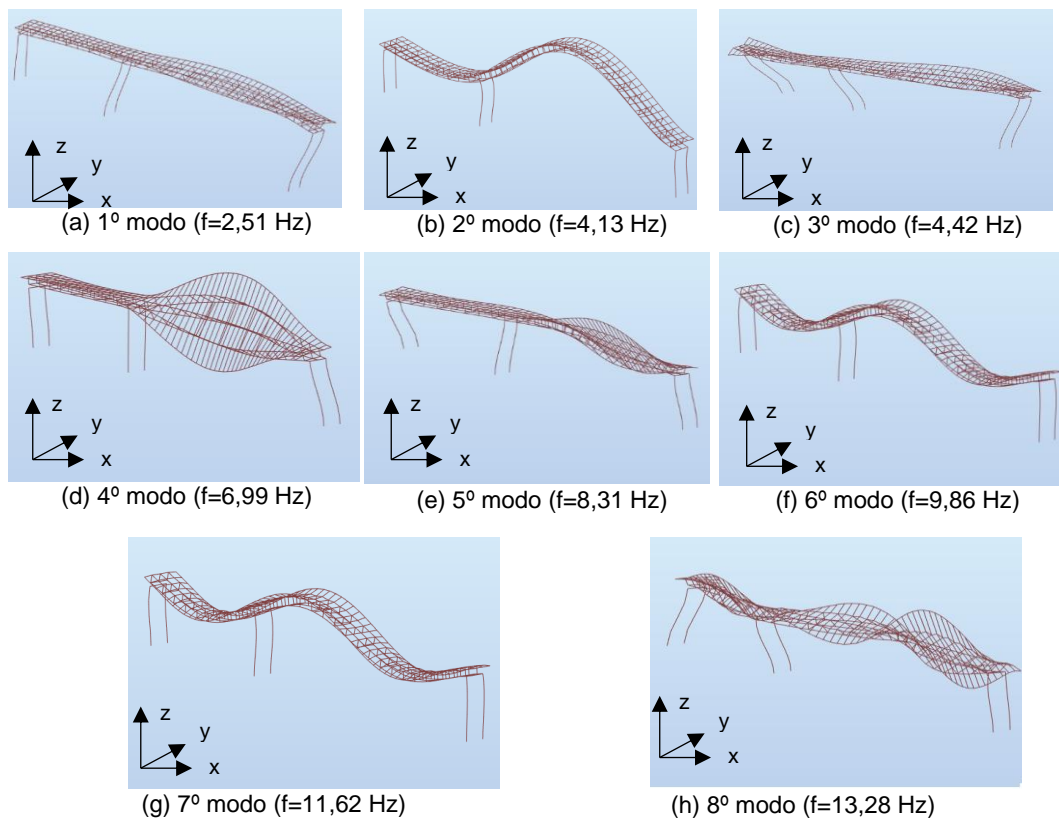


Figura 3.4 – Oito primeiros modos de vibração.

3.1.3. Flexibilidade modal

Assim como o índice de curvatura modal, a variação da flexibilidade modal dos elementos de uma estrutura, calculada através de seus parâmetros modais (frequências naturais e modos de vibração), apresenta respostas eficientes para a localização de um dano em estruturas simples, como vigas e pórticos simples em duas dimensões (Capítulo 2).

Utilizando a mesma estrutura da Figura 3.3a e o mesmo dano artificial inserido, obteve-se como resposta da variação deste índice [Equações (4), (5) e (6)] o gráfico da Figura 3.5. A variação da flexibilidade modal para os nós da estrutura não indica de forma correta a posição do dano. Através do gráfico percebe-se que não há um pico de variação significativo para a identificação correta do elemento danificado e mesmo assim, as maiores variações identificadas no gráfico estão localizadas nas regiões próximas ao centro do maior vão, novamente em área mais flexível. A dificuldade de identificar um dano em regiões próximas a pilares e mais rígidas é congruente com as conclusões de Chiniforush et al. (2017), como visto no Capítulo 2.




Figura 3.5 – Variação da flexibilidade modal para um dano próximo ao pilar interno


3.1.4. Energia de deformação modal

Analogamente às aplicações dos índices anteriores, a identificação do dano a partir da variação da energia de deformação modal, conforme o uso

das Equações (7) e (8) e (9), apresenta resposta similar para o mesmo dano simulado na estrutura da Figura 3.3a. O pico de variação do gráfico (Figura 3.6a) indica de forma errônea o elemento danificado, novamente apontando a maior variação em um elemento central do maior vão.

A formulação do cálculo da energia de deformação modal utiliza a componente vertical dos modos de vibração devido aos esforços de momento fletor predominantes nos elementos da estrutura. Neste caso, como há grande influência de modos de flexão lateral e torcionais no comportamento dinâmico (Figura 3.4a, c, d, e, h), o estudo das outras coordenadas é necessário para que se reflita corretamente a presença de dano na variação do índice, como analisado por Li and Yang (2006).

Com a visualização gráfica dos modos de vibração, percebe-se que a variação da componente vertical na região onde o dano está inserido é pequena se comparada ao restante da estrutura, visto que é uma região mais rígida devido ao apoio do pilar. Diante disso, é necessário que a análise seja expandida para as outras coordenadas como proposto pelos autores Jayasundara et al. (2019) e Li and Yang (2006). Utilizando, então, a coordenada horizontal longitudinal X (Figura 3.6b) no cálculo da variação da energia modal, obtém-se a identificação correta do elemento estrutural danificado. Dessa maneira, conclui-se que para este modelo de estrutura, nessas condições de dano, a coordenada longitudinal é mais eficiente para evidenciar a posição do dano.



(a)




Figura 3.6 - Variação da energia de deformação modal na direção a) vertical (Z) e b) longitudinal (X) .

Considerando os resultados dos índices de dano apresentados, estuda-se a necessidade de se analisar todas as componentes (X, Y e Z) dos modos de vibração em uma estrutura que apresente comportamentos dinâmicos mais complexos, levando em consideração modos tridimensionais relativos à torção e à flexão, verticais e laterais.

3.2. Vetor resultante

A concepção proposta neste trabalho de um índice relacionado à magnitude do Vetor Resultante é baseada nesta demanda de análise tridimensional dos modos de vibração para identificação correta de danos. Neste sentido é interessante que um único índice seja responsável pela variação do comportamento entre uma estrutura intacta e uma estrutura com um dano, para os três eixos (vertical, transversal e longitudinal – Z, Y, X). Assim, é construído um vetor resultante que incorpora as variações tridimensionais entre os modos de vibração. As Equações 10 e 11, e a Figura 3.7 apresentam o cálculo da variação do VR e a forma gráfica do vetor, respectivamente.

$$VR'_{ij} = \sqrt{\varphi_{x,ij}^2 + \varphi_{y,ij}^2 + \varphi_{z,ij}^2} \quad (10)$$

$$\Delta VR'_{ij} = |VR'^*_{ij} - VR'_{ij}| \quad (11)$$

Onde $VR'_{i,j}$ representa o valor do Vetor Resultante referente ao modo de vibração “j” no nó “i” do modelo de elementos finitos da estrutura, $\varphi_{x,i}$ representa o modo de vibração, normalizado por massa, considerando a coordenada modal x e, analogamente, para os modos de vibração considerando as coordenadas y e z. $\Delta VR'_{i,j}$ indica a variação de $VR'_{i,j}$ entre a estrutura danificada (sobrescrito “*”) e intacta.




Figura 3.7 – Representação gráfica do Vetor Resultante.

Ao incorporar as três direções na análise da variação dos modelos intacto e danificado, não há mais necessidade de se analisar cada componente separadamente e nem de se observar o comportamento dinâmico da estrutura previamente, visto que os movimentos de flexão, vertical e lateral, e de torção estão contemplados na análise na forma de um único indicador.

Considerando obter a influência dos oito primeiros modos de vibração da estrutura analisada, o índice final é construído a partir do somatório da variação do Vetor Resultante para os modos analisados, de acordo com a Equação 12, onde “n” é o número de modos incorporados na análise.

$$VR_i = \sum_{j=1}^n \Delta VR'_{i,j} \quad (12)$$

Para exemplificar a eficiência do índice, é repetido o exemplo usando a mesma estrutura com o mesmo dano inserido para os índices anteriores, e calculada a variação do Vetor Resultante. A Figura 3.8 apresenta o

resultado para o dano próximo ao pilar, que como pode-se observar é corretamente identificado.




Figura 3.8 - Variação do Vetor Resultante para um dano próximo ao pilar.

Para estruturas de grande porte, não retilíneas e mais complexas ou que sejam representadas numericamente por um modelo de elementos finitos com alto número de nós e elementos, a identificação de forma gráfica não se torna tão interessante.

Com o objetivo de tornar o processo mais eficiente e acelerar a identificação de danos, é introduzido o uso de inteligência computacional na forma de Redes Neurais Artificiais. As redes neurais são capazes de auxiliar na previsão de um dano a partir do fornecimento de um conjunto de dados de entrada formado pelos valores do índice VR para os nós do modelo.

3.3. Redes neurais artificiais

As redes neurais artificiais auxiliam na previsão do dano a partir de dados de variação do Vetor Resultante utilizando técnicas de inteligência artificial. Fornecendo um número de dados para treinamento, a rede é capaz de prever a presença do dano a partir de novas informações provenientes dos danos simulados. Com os modos de vibração, calculam-se os índices (VR) para cada nó do modelo numérico, introduzindo-os como dados de entrada. Como concluído por Finotti et al. (2019), é mais eficiente aplicar metodologias de redes neurais – quando o objeto de estudo são

estruturas de grande porte – do que outras tecnologias de reconhecimento de padrões como o SVM (*Support Vector Machine*, sigla em inglês para Máquina de Vetores de Suporte).

A rede neural é capaz de “aprender” o comportamento da estrutura danificada através de uma quantidade limitada de informações, e possibilita prever a localização e a intensidade de um dano com interpolações numéricas utilizando os pesos estabelecidos na fase de treinamento. O algoritmo de *Backpropagation* utilizado na construção da rede impõe a construção destes pesos através de minimização do erro no resultado da camada de saída e os reajusta de forma inversa ao processamento da rede.

Duas redes neurais independentes são formadas: a primeira para localização do dano na estrutura, baseada nos dados de variação do Vetor Resultante, e, a segunda, para prever o quanto degradado está o membro estrutural. Esta última incorpora a variação das frequências naturais aos dados de entrada – que possuem boa sensibilidade em relação a intensidade do dano (Figura 3.2). A Figura 3.9 resume o diagrama de fases incluídas na metodologia proposta.

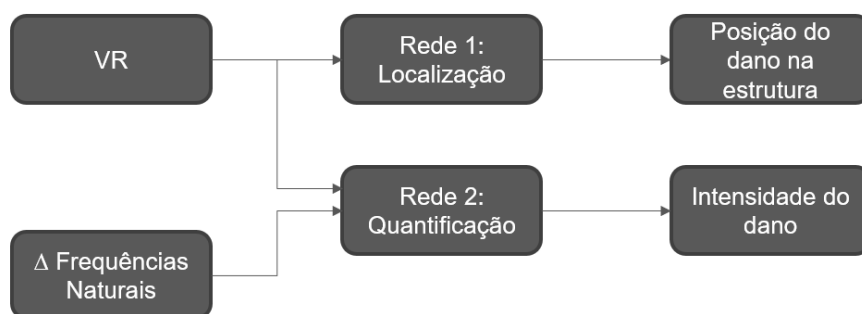


Figura 3.9 - Processos de localização e quantificação de danos

Dessa forma, as duas redes possuem processos distintos de treinamento, validação e teste, e resultados independentes, mas que formam um par de informações (localização e quantificação) para uma situação de dano em que se encontra a estrutura. Cada rede é treinada de forma individual, portanto possui seus pesos individualmente definidos,

número de camadas ocultas e funções de ativação específicas para que atinjam os resultados na camada de saída com a maior acurácia.

No Capítulo 4 é discutida a aplicação desta metodologia utilizando o índice VR, assim como a construção da Rede Neural Artificial e seus parâmetros.

4 Aplicação

Considerando os índices de dano estudados no Capítulo 3 e objetivando realizar a identificação de danos em uma estrutura complexa de grande porte, a aplicação da metodologia com o uso do Vetor Resultante é feita em um modelo numérico inspirado em uma passarela metálica com tabuleiro pavimentado em concreto, com diferentes níveis e curvaturas. A estrutura que serviu de inspiração para a construção do modelo é apresentada no Capítulo 4.1.

4.1. Apresentação da estrutura

A realização dos Jogos Olímpicos de 2016 na cidade do Rio de Janeiro promoveu uma série de alterações na infraestrutura de transporte público na cidade. A construção da passarela em questão é consequência deste processo. A estrutura é responsável por conectar o terminal do sistema de transporte público BRT (*Bus Rapid Transit*) – ônibus de trânsito rápido – ao complexo esportivo do Parque Olímpico, cruzando as principais vias da região do Recreio dos Bandeirantes.



Figura 4.1 – Localização da estrutura (Google Maps, 2020).

A passarela possui 4 trechos (Figura 4.2) onde destacam-se os trechos 2 e 3 como os mais flexíveis e susceptíveis a vibrações excessivas induzidas por pedestres (Ribeiro et al., 2021). Por este motivo, estes dois segmentos foram selecionados para servirem de inspiração para serem modelados numericamente de forma isolada ao restante da estrutura.

Neste trecho, a passarela é executada em tabuleiro pavimentado em concreto apoiado em uma chapa metálica e sustentada por vigas com perfis metálicos tubulares. As seções transversais podem ser verificadas no corte da estrutura apresentado na Figura 4.3.




Figura 4.2 – Estrutura da passarela setorizada




Figura 4.3 – Seção transversal do modelo computacional da passarela

4.2. Modelagem numérica

A modelagem numérica da estrutura foi feita no software *Robot Structural Analysis*, da Autodesk. O modelo busca inspiração nos trechos 2 e 3 da passarela (Figura 4.2), mantendo as dimensões e seções transversais originais da estrutura.

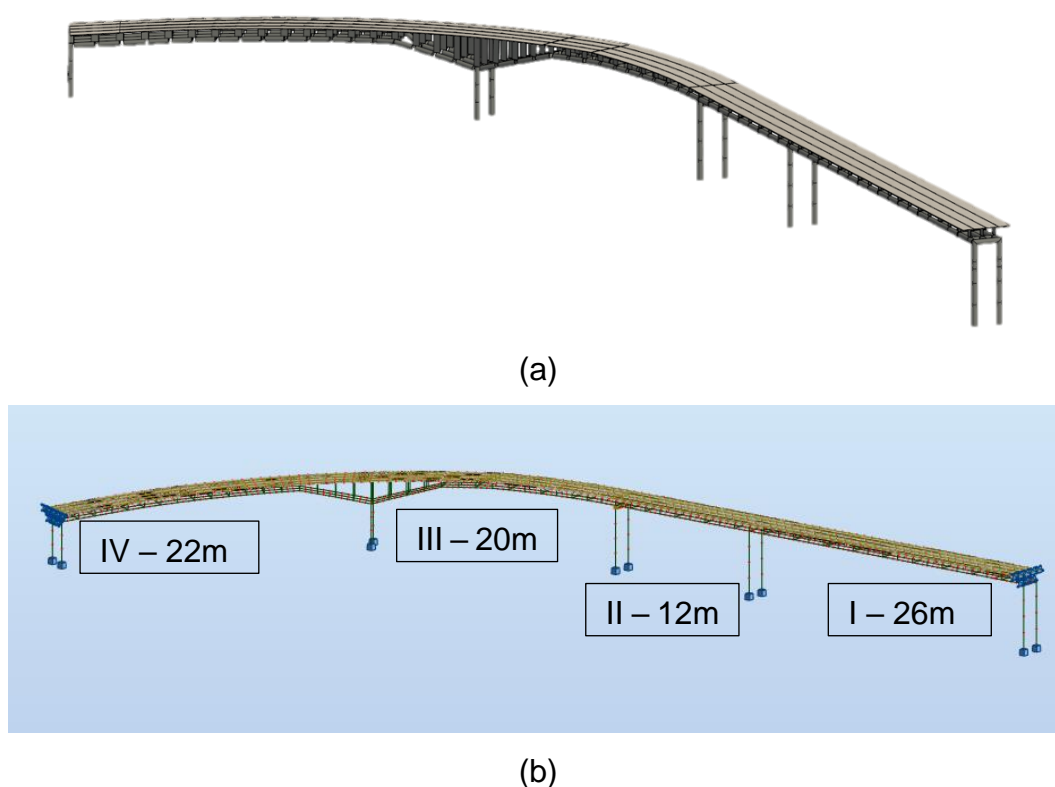


Figura 4.4 – Modelo adaptado da passarela real. a) Modelo estrutural no *software* Revit, da Autodesk; b) Modelo de cálculo (numérico)

O modelo possui 4 vãos com as dimensões indicadas na Figura 4.4b e é composto por 3 eixos de longarinas tubulares com diâmetro de 273mm e espessura de 15,1mm, como mostrado na Figura 4.3; transversinas em seção de chapa metálica e os montantes da mesma forma. Todos os membros foram modelados como elementos de viga e as ligações como perfeitamente rígidas. O tabuleiro por sua vez é composto por uma chapa metálica de 5 mm sob uma laje de concreto de 50 mm de espessura. Para fins de cálculo, a laje composta foi modelada como um elemento de placa

único, utilizando o método das seções equivalentes para aproximar a chapa metálica para uma seção de concreto equivalente.




Figura 4.5 - Componentes da estrutura do modelo

Os apoios do modelo são divididos em duas categorias: apoios dos pilares e apoios de continuidade. Os apoios dos pilares são engastes perfeitos, com rotações e translações nulas. Já os apoios de continuidade são estabelecidos nas extremidades do modelo para simular, de forma simplificada, os efeitos da continuidade da estrutura. Para estes, são limitadas apenas as translações na direção longitudinal, no sentido da continuação da estrutura. A translação nas outras direções e as rotações são livres.





Figura 4.6 – Condições de contorno do modelo

4.3.
Comportamento dinâmico


Para estudar o comportamento dinâmico da estrutura, é realizada a análise modal por meio do software *Robot Structural Analysis*. A análise modal permite identificar as frequências naturais (autovalores) e os modos de vibração (autovetores) da estrutura. Na Tabela 4.1 estão listados os oito primeiros modos de vibração com as respectivas frequências naturais e as características dos modos, e na Figura 4.7 a sua representação visual.

Tabela 4.1 – Característica dos modos de vibração e frequências naturais do modelo da passarela


MODO	FREQUÊNCIA NATURAL (HZ)	CARACTERÍSTICA DO MODO
1	2,56	FLEXÃO LATERAL + TORÇÃO
2	3,81	FLEXÃO LATERAL + FLEXÃO VERTICAL
3	4,14	FLEXÃO VERTICAL
4	4,42	TORÇÃO + FLEXÃO VERTICAL
5	5,68	TORÇÃO
6	6,67	FLEXÃO VERTICAL + TORÇÃO
7	7,01	TORÇÃO
8	8,45	TORÇÃO + FLEXÃO LATERAL



(a) 1º modo (f=2,56 Hz)




(b) 2º modo (f=3,81 Hz)




(c) 3º modo (f=4,14 Hz)



(d) 4º modo (f=4,42 Hz)



(e) 5º modo (f=5,68 Hz)



(f) 6º modo (f=6,67 Hz)




Figura 4.7 – Oito primeiros modos de vibração da passarela e suas respectivas frequências naturais

4.4. Simulação de danos artificiais

A simulação de danos no modelo numérico deu-se como abordado no Capítulo 3, onde a corrosão é artificialmente introduzida na seção tubular metálica como uma redução da seção transversal. Para este estudo, o dano introduzido fica limitado às longarinas de acordo com a redução listada na Tabela 4.2 e com a extensão de aproximadamente 0,5 metros, equivalente a um elemento de viga do modelo. Cinitha et al. (2014) classifica as corrosões em três categorias:

- Corrosão severa: acima de 50% de redução da espessura da seção transversal;
- Corrosão moderada: redução da espessura da seção transversal entre 50% e 25%;
- Corrosão leve: redução da espessura da seção transversal menor que 25%.

Dessa maneira, de acordo com a classificação acima e a Tabela 4.2, são simulados 3 danos leves, 2 danos moderados e 3 danos severos. Para cada combinação de localidade e intensidade de dano, ocorre uma resposta distinta da estrutura.

Tabela 4.2 - Danos simulados através de reduções específicas de seção transversal.

Casos	Espessura da seção tubular (cm)	Redução de espessura
Intacto	1,500	0%
Dano 5	1,425	5%
Dano 10	1,350	10%
Dano 15	1,275	15%
Dano 30	1,050	30%
Dano 45	0,825	45%
Dano 60	0,600	60%
Dano 75	0,375	75%
Dano 90	0,150	90%

A região destacada na Figura 4.8 possui uma mudança na espessura da seção transversal. Enquanto no restante das longarinas a espessura da seção possui 15,1 mm, na região onde as longarinas são inclinadas a espessura é de 21,4 mm. A geração de danos artificiais é feita analogamente nesta região, com as mesmas reduções que foram aplicadas nas demais longarinas.



Figura 4.8 - Setor da estrutura com seção transversal de espessura diferente

4.5. Vetor Resultante

A formulação do Vetor Resultante, como visto no Capítulo 3.2, apresenta resultados positivos e eficientes para a identificação de danos em estruturas complexas. A aplicação deste índice para a estrutura em questão é discutida abaixo.

Para exemplificar a resposta deste índice aos danos, é inserido um dano 90 no trecho retilíneo do modelo da passarela como mostrado na Figura 4.9.




Figura 4.9 – a) Setor do dano simulado; b) Detalhe do dano aproximado.

Para simplificar a visualização da resposta em relação aos nós, o modelo foi subdividido em 13 setores (de “A” a “M” – Figura 4.10a) com aproximadamente 5 metros de comprimento por setor, com exceção do setor “J”, que compreende toda a região das longarinas inclinadas, que possui aproximadamente 11 metros. Após a análise modal e construção dos índices para cada nó da estrutura, a resposta gráfica possibilita identificar corretamente o setor onde ocorre o dano, como pode ser visto na Figura 4.10b, onde os nós estão ordenados seguindo a ordem dos setores da estrutura para melhor entendimento. Para facilitar a visualização, é calculada a média de variação do índice para cada setor do modelo e mostrada no gráfico da Figura 4.10c.

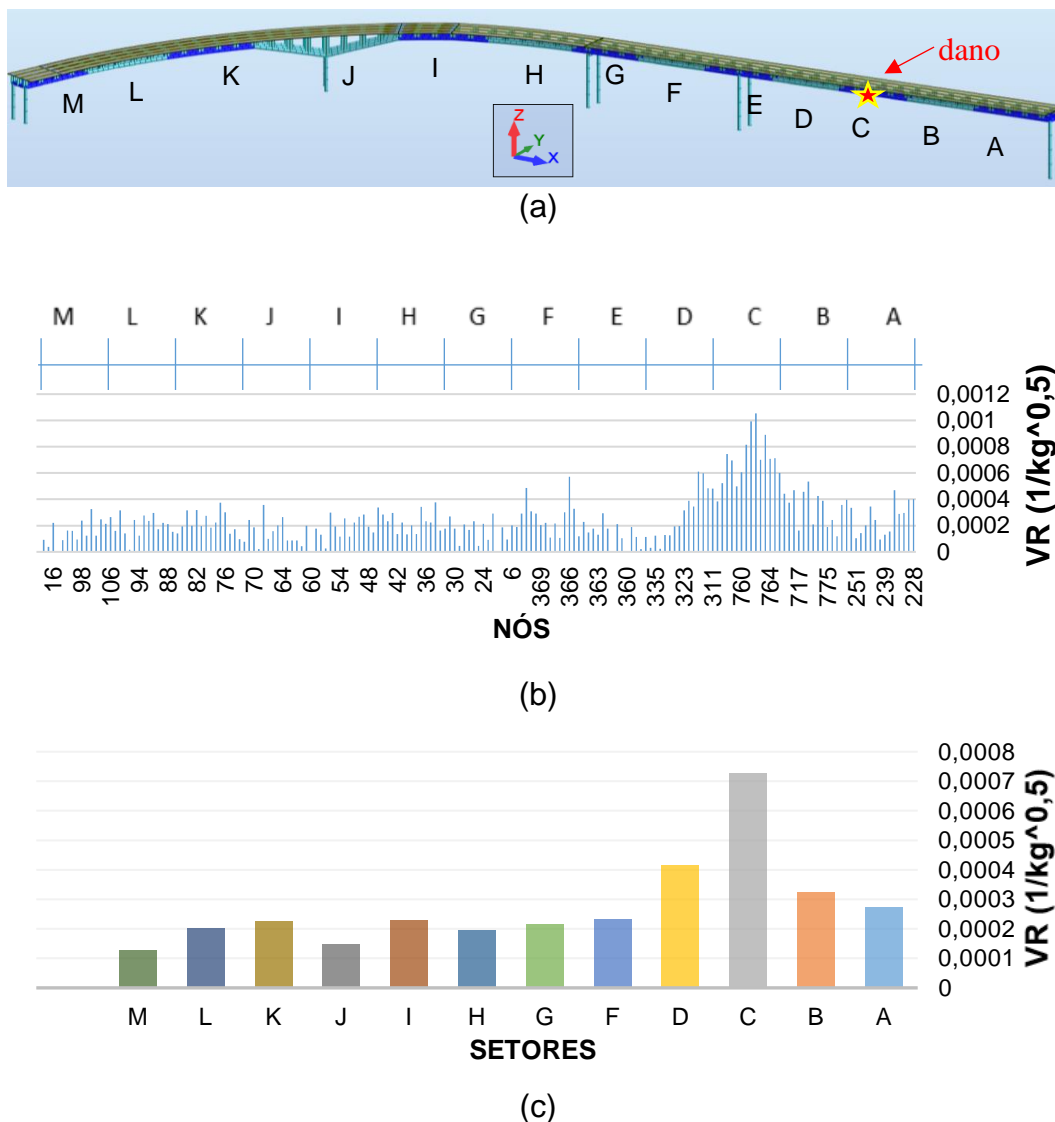



Figura 4.10 – a) Setorização da passarela e o dano inserido no setor C; b)


Variação do índice de dano VR para um dano no setor C; c) Média da variação do índice

VR por setor.


Para mais exemplos do uso do índice na identificação de danos nesta estrutura, são simulados dois danos: um dano 60 no setor F e outro dano 30 no setor K, de acordo com a Figura 4.11a. A resposta da variação do Vetor Resultante em cada setor para os danos 60 e 30 é mostrada nas figuras Figura 4.11b e Figura 4.11c, respectivamente. Percebe-se a eficiente identificação dos danos e constata-se que a magnitude da variação é proporcional à intensidade do dano (maior magnitude para o dano 60 e menor para o dano 30).



(a)



(b)



(c)

Figura 4.11 – a) Setorização da passarela e danos inseridos; b) Variação do VR para dano de 60% no setor F; c) Variação do VR para dano de 30% no setor K.

4.6. Redes Neurais Artificiais

Ainda seguindo a metodologia proposta no Capítulo 3, a aplicação de uma Rede Neural Artificial auxilia na automatização e facilitação do processo de identificação de danos.

A rede neural neste trabalho é realizada dentro da plataforma *Jupyter Notebook*, em código *Python*.

4.6.1.

Banco de dados

Para construir um banco de dados para alimentar esta Rede Neural foi elaborado um código em *Python* dentro do ambiente do software Dynamo, da Autodesk. A escolha de softwares de mesmo fabricante possibilita que a troca de informações seja feita através de um *plugin*, sendo assim mais precisa. O código é responsável pela seleção e modificação da seção transversal de um elemento de viga (longarina) do modelo. Após a substituição do elemento de viga por uma seção danificada (de menor espessura) é feita a análise modal da estrutura e extraída as coordenadas modais dos oito primeiros modos de vibração e as respectivas frequências naturais. Com os dados dinâmicos é possível calcular a variação do Vetor Resultante como apresentado na Equação 12.

Portanto, este banco de dados, considerando cada cenário de dano, é formado pelo valor da variação do Vetor Resultante para cada nó e a variação das 8 primeiras frequências naturais entre a estrutura danificada e a intacta. Além disso, para fins de treinamento supervisionado da Rede Neural, ainda é incluído o setor danificado para cada caso, assim como a intensidade do dano inserido. A Figura 4.12 exemplifica a formação deste banco. Um total de 1304 cenários são simulados aleatoriamente, onde cada um representa a resposta da estrutura para um caso de dano que envolve a combinação entre localização (um dos 13 setores) e intensidade (uma entre as 8 intensidades pré-determinadas na Tabela 4.2).

Estes dados são divididos em conjuntos de treinamento, validação e teste na proporção encontrada na Tabela 4.3.

Tabela 4.3 - Proporção dos dados para as fases de treinamento, validação e teste da rede neural

Fase	Porcentagem dos dados	Número de dados
Treinamento	81%	1055
Validação	9%	118
Teste	10%	131



Figura 4.12 - Exemplo de dados para um único cenário de dano.

4.6.2.

Pré-processamento dos dados

O pré-processamento dos dados de treinamento de uma rede neural é extremamente importante para a sua eficiência (Vincent et al., 2019). A sensibilidade dos modelos de redes neurais artificiais aos dados de entrada tornam comum a prática de ajustar esses dados para melhor adequação aos algoritmos de previsão (Cutler et al., 2020).

A padronização dos dados de entrada evita que aqueles que possuem um valor de maior magnitude não tenham influência desproporcional sobre os de menor magnitude, o que tornaria estes dados mais significativos no resultado da rede. A normalização dos valores de entrada é feita de acordo com a Equação 13, resultando em um conjunto de dados onde a média é igual a zero e o desvio padrão igual a 1, deixando todos os dados na mesma magnitude para que a rede faça o seu processamento de forma eficiente.

$$z = \frac{x - \mu}{\sigma} \quad (13)$$

Onde z é o valor padronizado da variável x , que possui média μ e desvio padrão σ .

4.6.3.

Rede Neural 1: Localização do dano

Para localizar o dano de forma precisa, a variação do vetor resultante (VR) em cada nó do modelo é utilizada como dado de entrada para a Rede Neural 1. É construído um modelo de classificação com o intuito de atestar a presença de um dano em um dos 13 possíveis setores em que a passarela foi subdividida.

Como a classificação dos setores é feita a partir de categorias usando caracteres (A:M) e o algoritmo de aprendizado de máquina não consegue tratar variáveis deste tipo, é necessário realizar uma conversão para dados numéricos. Cada setor é transformado em um vetor binário com 13 entradas para sua representação. Na posição do vetor correspondente ao setor do dano é inserido o número 1 e nas demais posições o número zero, como no exemplo abaixo:

Setor A = (1,0,0,0,0,0,0,0,0,0,0,0,0);

Setor F = (0,0,0,0,0,1,0,0,0,0,0,0,0);

Setor K = (0,0,0,0,0,0,0,0,0,0,1,0,0).

A rede neural de localização do dano possui uma camada de entrada com a variação do Vetor Resultante para cada nó do modelo, uma camada oculta e uma camada de saída referente aos setores da passarela. A configuração final da rede é da seguinte forma:

- Camada de entrada: 1219 neurônios;
- Camada oculta 1: 700 neurônios;
- Camada de saída: 13 neurônios.

A função *Softmax* é definida como a função de ativação da camada de saída. Esta função leva a saída da rede a representar a probabilidade de os dados de entrada pertencerem a uma das classes pré-definidas, neste caso, os 13 setores da passarela. Portanto o valor de saída está entre 0 (0%) – os dados de entrada não correspondem à classe – e 1 (100%) – os dados correspondem perfeitamente à classe.

Para a escolha das funções de ativação entre as camadas, Bishop, (1995) afirma que a função sigmoide logística é a mais indicada para se atingir resultados probabilísticos e mais utilizada quando se trata de um modelo de múltiplas camadas. Entretanto, o autor também atesta a vantagem da função tangente hiperbólica (Tanh) em relação à sigmoide logística por apresentar convergência mais rápida no treinamento do algoritmo. Os gráficos da Figura 4.13 atestam, apesar de sutil, uma maior

velocidade de convergência para a rede com a função Tanh para a fase de treinamento. Outro fator importante é referente aos picos mais acentuados na rede formada pela função sigmoide, indicando maior variação (e valor absoluto) do erro.


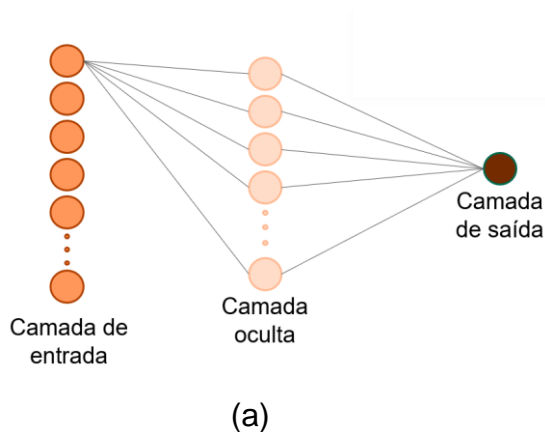


Figura 4.13 - Velocidade de convergência entre as funções a) Tanh e b) Sigmoide avaliando o decaimento da função erro de acordo com o número de épocas.

Por se tratar de um modelo de classificação de múltiplas classes, o erro é calculado de acordo com a função de entropia cruzada categórica (*categorical cross-entropy*). Esta função é utilizada para quantificar a diferença entre duas probabilidades, neste caso a probabilidade de o dano estar em determinado setor (valor previsto pela rede neural) e a presença real (100%) ou não (0%) do dano no mesmo setor.

A configuração final da rede (Figura 4.14) é resultado de diversos testes que buscaram chegar a resultados com menor erro e maior acurácia.






Figura 4.14 – a) Configuração final da rede neural de localização; b) funções de ativação entre as camadas da rede 1.

Foram testadas diferentes redes com uma ou mais camadas ocultas, diferentes funções de ativação, métodos de inicialização dos pesos e diferentes quantidades de neurônios na camada oculta (Tabela 4.4, Tabela 4.5, Tabela 4.6 e Tabela 4.7, respectivamente). Para cada variação de determinado parâmetro, os demais são fixados a fim de se obter o resultado mais eficiente para o parâmetro estudado. Iniciou-se fixando todos os parâmetros e variando apenas o número de camadas ocultas. Identificando a melhor resposta, fixa-se este número e varia-se o segundo parâmetro (funções de ativação), e assim segue para todos os parâmetros estudados. As opções escolhidas para cada estudo de variação estão nas tabelas com destaque em amarelo para a opção adotada para a rede.

Esta configuração final apresentou maior velocidade de convergência, maior acurácia e o menor erro nas fases de treinamento e validação. A Figura 4.15 apresenta os gráficos referentes a essas métricas de acordo com o número de épocas e a Tabela 4.8 apresenta o resultado final para o erro e a acurácia após a fase de treinamento e validação.

Tabela 4.4 – Avaliação da variação do número de camadas ocultas na eficiência da rede

Número de camadas ocultas	Erro <i>Cross-Entropy</i> (validação)	Acurácia (validação)
1	0,13	98%
2	0,40	92%
3	0,26	94%

Tabela 4.5 – Avaliação da variação da função de ativação na eficiência da rede

Função de ativação das camadas ocultas	Erro <i>Cross-Entropy</i> (validação)	Acurácia (validação)
Tanh	0,13	98%
Sigmoide	0,32	94%

Tabela 4.6 – Avaliação da variação do método de inicialização dos pesos na eficiência da rede

Método de inicialização dos pesos	Erro <i>Cross-Entropy</i> (validação)	Acurácia (validação)
Randômico uniforme	0,44	90%
Randômico normal	0,13	98%
Zeros	0,37	92%
Unidade	2,47	22%

Tabela 4.7 – Avaliação da variação do número de neurônios da camada oculta na eficiência da rede

Número de neurônios na camada oculta	Erro <i>Cross-Entropy</i> (validação)	Acurácia (validação)
600	0,24	94%
700	0,13	98%
500	0,25	90%
800	0,27	92%




Figura 4.15 – Variação das funções de a) Acurácia e b) Erro para as fases de treinamento e validação da rede

Tabela 4.8 – Valores finais de erro e validação para a Rede 1.

Fase	Erro	Acurácia
Treinamento	$2,966 \times 10^{-4}$	99,9%
Validação	0,132	97,6%

4.6.4. Rede Neural 2: Quantificação do dano

Para quantificar o dano já localizado, uma nova estrutura de Rede Neural é configurada. Esta segunda rede utiliza a regressão para prever o valor da intensidade do dano, diferentemente da classificação utilizada na primeira rede de localização.

Como apontado no Capítulo 2, as frequências naturais se apresentam como um bom indicativo da presença do dano, porém de forma global, sem ser capaz de localizá-lo. Entretanto, a variação das frequências reflete de forma eficiente as diferentes magnitudes deste dano. Dessa maneira, esta rede neural de quantificação do dano incorpora em sua camada de entrada, além dos dados de variação do vetor resultante, as variações das oito primeiras frequências naturais, normalizadas de acordo com a estrutura intacta, totalizando assim 1227 neurônios. O número de neurônios nas camadas ocultas é determinado de forma empírica, visto que não há na literatura muitos estudos sobre o número ideal (Yuen et al., 2006). Para

iniciar o estudo, foi determinado que a primeira camada oculta teria um número de neurônios próximo à média entre o número de neurônios da camada de entrada e de saída. As demais camadas teriam metade de neurônios da camada anterior.

O objetivo desta rede é realizar uma regressão para o valor correto do dano. Para isto, a função de ativação linear é utilizada na camada de saída. Esta função repassa de forma linear o valor final, após ser multiplicado pelos pesos, para o neurônio de saída. Assim como na rede neural 1, a função de ativação das camadas ocultas é a tangente hiperbólica. Desta forma, a rede de quantificação do dano é configurada da seguinte forma:

- Camada de entrada: 1227 neurônios;
- Camada oculta 1: 700 neurônios;
- Camada oculta 2: 350 neurônios;
- Camada oculta 3: 170 neurônios;
- Camada de saída: 1 neurônio.

Para as camadas ocultas, apesar da função tangente hiperbólica convergir mais rapidamente para um resultado, a função sigmoide apresenta menores erros (ver Figura 4.16 e Tabela 4.10). Os gráficos da Figura 4.16 apresentam diferentes escalas para o eixo vertical devido aos diferentes valores iniciais de erro na aplicação de cada função de ativação. A rede que utiliza a função Tanh apresenta erros iniciais seis vezes maiores, e por isso o seu gráfico possui uma escala maior.

Uma série de variações, além da função de ativação das camadas ocultas (Tabela 4.10), são feitas para se chegar na configuração ideal para a rede. Número de camadas ocultas, a própria variação das funções de ativação, o método de inicialização dos pesos número e o número de neurônios em cada camada oculta são estudados e seus erros demonstrados nas Tabelas 4.9, 4.10, 4.11 e 4.12, respectivamente. A variação destes parâmetros segue o mesmo processo descrito para a Rede 1, no Capítulo 4.6.3. Diante disso, optando pela configuração com o menor erro absoluto médio na fase de validação do modelo como destacado em

amarelo nestas Tabelas, chega-se à configuração da rede esquematizada na Figura 4.17.




Figura 4.16 – Decaimento do erro nas fases de validação e treinamento para as funções de ativação a) Tanh e b) Sigmoide.

Tabela 4.9 – Avaliação do número de camadas ocultas para o menor erro na Rede

2

Número de camadas ocultas	Erro Absoluto Médio (validação)
1	0,05
2	0,04
3	0,01

Tabela 4.10 – Avaliação da função de ativação nas camadas ocultas para o menor erro na Rede 2


Função de ativação das camadas ocultas	Erro Absoluto Médio (validação)
Tanh	0,025
Sigmoide	0,014

Tabela 4.11 – Avaliação do método de inicialização dos pesos para o menor erro na Rede 2

Método de inicialização dos pesos	Erro Absoluto Médio (validação)
Randômico uniforme	0,01115
Randômico normal	0,01219
Zeros	0,00974
Unidade	0,1550

Tabela 4.12 – Avaliação do número de neurônios nas camadas ocultas para o menor erro na Rede 2.

Número de neurônios nas camadas ocultas (1ª – 2ª – 3ª)	Erro Absoluto Médio (validação)
600 – 300 – 150	0,0234
600 – 200 – 50	0,0159
500 – 250 – 100	0,0162
700 – 350 – 170	0,0148
700 – 300 – 100	0,0201
700 – 500 – 250	0,0156
700 – 500 – 100	0,0160



(a)




Figura 4.17 – a) Configuração final da rede neural de quantificação; b) funções de ativação entre as camadas da rede 2.

Sendo assim, a configuração final da rede neural 2 apresenta os resultados de erro para as fases de treinamento e validação de acordo com a Tabela 4.13.

Tabela 4.13 – Erro absoluto médio para as fases de treinamento e validação da Rede 2

Fase	Erro Absoluto Médio
Treinamento	0,0064
Validação	0,0148

4.7. Resultados

Após a configuração das duas redes neurais determinadas a partir das fases de treinamento e validação, a fase de teste busca inserir novos dados para atestar sua eficiência. O conjunto que é submetido ao teste de ambas as redes contém 131 dados escolhidos de forma aleatória através da uma função específica em *Python* (“*train_test_split*”) do pacote “*Scikit Learn*”.

A avaliação da eficiência das redes para o conjunto de teste é feita de forma distinta para as redes de localização e quantificação. A primeira é avaliada através de uma matriz de confusão (*Confusion Matrix*), que apresenta em forma de matriz os dados reais (linhas) e os dados previstos pela rede (colunas). Já para a segunda rede, é apresentada graficamente a relação entre os dados previstos e os valores reais de intensidade do

dano e calculado o seu erro absoluto. A Figura 4.18 apresenta graficamente os modelos de avaliação de cada rede.




Figura 4.18 – Modelos de avaliação de eficiência das redes 1 e 2 para as fases de treinamento, validação e teste.

Para exemplificar o produto de ambas as redes neurais, a resposta para um conjunto de testes é apresentada. Para Rede Neural 1 (localização), a matriz de confusão (Figura 4.19) apresenta em sua diagonal principal todos os setores danificados corretamente identificados e fora da diagonal, os erros associados. O elemento (3,4) da matriz, por exemplo, representa um erro associado a um dano no setor C (3º setor) que está sendo previsto no setor D (4º setor) da estrutura. Assim como o elemento (2,2) representa um dano no setor B (2º setor), corretamente previsto no mesmo setor. O valor dos elementos na matriz representa o número de ocorrências para cada caso. Como pode-se perceber, para este conjunto de testes a rede neural apresentou uma eficiência de 100% na localização do dano, visto que não há ocorrências fora da diagonal principal.

A Figura 4.20 apresenta o gráfico de resultado da Rede Neural 2 (quantificação), onde o eixo horizontal representa o valor real de intensidade do dano (círculos azuis) e o eixo vertical o valor previsto pela rede (triângulos vermelhos). Percebe-se que a grande maioria dos dados foi previsto com uma acurácia maior que 99%. A maior discrepância de resultados é identificada com um círculo tracejado, onde o valor real é referente a um dano de 90% de intensidade, enquanto a rede prevê uma intensidade de 76%.

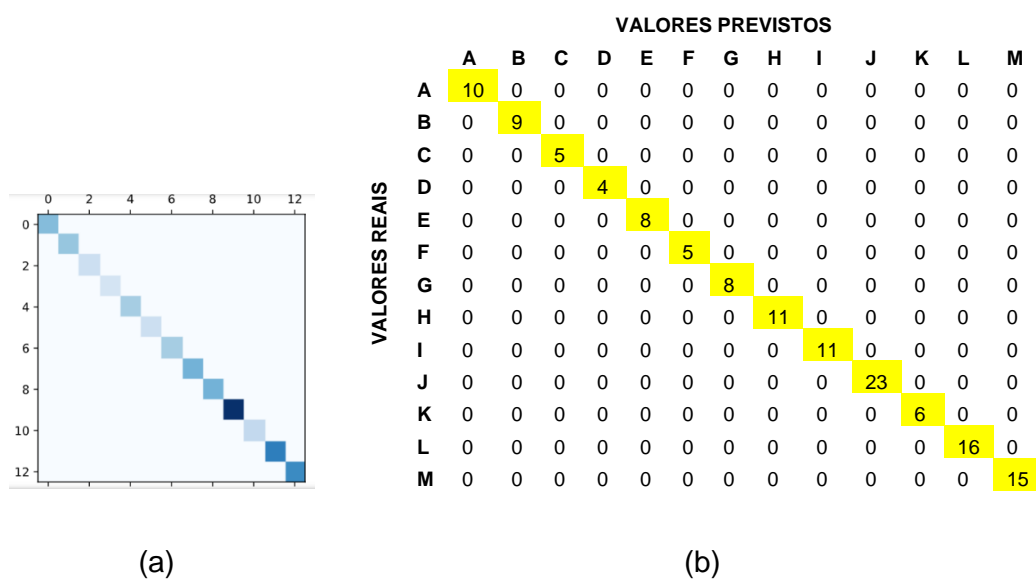


Figura 4.19 – Matriz de confusão na avaliação do conjunto de teste para a Rede 1.




Figura 4.20 – Gráfico de avaliação da eficiência da Rede 2, com os valores de dano reais e os previstos pela rede.

A Tabela 4.14 – a e Tabela 4.14 – b apresentam, respectivamente, os dez primeiros resultados do conjunto de teste com seus erros absolutos e um resumo dos 131 dados de teste.

Tabela 4.14 – a) Exemplo dos dez primeiros resultados da Rede Neural 2 (quantificação); b) Resumo do erro do total de resultados para a Rede Neural 2.

Nº	Previsto (%)	Real (%)	Diferença absoluta (%previsto - %real)
1	91%	90%	0,77%
2	91%	90%	0,77%
3	4%	5%	0,83%
4	4%	5%	0,72%
5	45%	45%	0,01%
6	90%	90%	0,07%
7	15%	15%	0,43%
8	9%	10%	0,67%
9	45%	45%	0,02%
10	45%	45%	0,04%

(a)

Resumo Erro Absoluto	
113	e<1%
17	1%<e <5%
1	5%<e<15%
0	e>25%

(b)

A Tabela 4.15 une as respostas de ambas as Redes Neurais 1 e 2 e seus respectivos erros, para os dez primeiros dados. Além disso, os demais testes podem ser consultados no Apêndice A.

Tabela 4.15 – Exemplo das dez primeiras respostas dos dados de teste das redes 1 e 2 para localização e quantificação dos danos.

Nº	Localização do dano real	Localização do dano prevista	Acurácia	Intensidade do dano real	Intensidade do dano prevista	Erro Absoluto
1	H	H	100%	90%	90,8%	0,77%
2	M	M	100%	90%	90,8%	0,77%
3	G	G	100%	5%	4,2%	0,83%
4	G	G	100%	5%	4,3%	0,72%
5	F	F	100%	45%	45,0%	0,01%
6	I	I	100%	90%	90,1%	0,07%
7	E	E	100%	15%	14,6%	0,43%
8	I	I	100%	10%	9,3%	0,67%
9	K	K	100%	45%	45,0%	0,02%
10	I	I	100%	45%	45,0%	0,04%

Como o conjunto de teste é escolhido aleatoriamente, dez conjuntos (aleatórios) são formados e atribuídos às redes neurais com o objetivo de aumentar a confiança em sua efetividade. Ressalta-se que cada conjunto contém 131 danos. A Tabela 4.16 apresenta a eficiência global das redes neurais 1 e 2 para os 10 conjuntos de teste aleatórios. A capacidade da metodologia apresentada no Capítulo 3 é atestada ao verificar uma média de 99,7% de eficiência na localização do dano, com desvio padrão médio de 0,4%, e 86% dos danos previstos com menos de 1% de erro absoluto e desvio padrão médio de 2,4%. Vale destacar também que para erros abaixo de 5%, tem-se uma eficiência de 99%.

Tabela 4.16 – Eficiência global das redes de localização e quantificação.

	Localização		Quantificação					
	Acurácia	Número de erros	Erro Absoluto					
			<1%	%	<5%	%	<15%	%
TESTE 1	100%	0	113	86%	16	12%	2	2%
TESTE 2	99%	1	123	94%	10	8%	1	1%
TESTE 3	100%	0	112	85%	18	14%	1	1%
TESTE 4	99%	1	108	82%	22	17%	1	1%
TESTE 5	99%	1	107	82%	23	18%	1	1%
TESTE 6	100%	0	113	86%	17	13%	1	1%
TESTE 7	100%	0	109	83%	20	15%	2	2%
TESTE 8	100%	0	113	86%	15	11%	3	2%
TESTE 9	100%	0	111	85%	18	14%	2	2%
TESTE 10	100%	0	116	89%	14	11%	1	1%
MÉDIA	99,7%			86%		13%		1%
DESVP	0,4%			2,4%		2,3%		0,5%

5

Conclusões e investigações futuras

5.1. Conclusões

Este trabalho estuda a capacidade dos principais índices de dano dinâmicos presente na literatura, tais como a variação das frequências naturais, da curvatura modal, da flexibilidade modal e da energia de deformação modal, apontando suas vantagens e limitações. A questão primordial em relação a estes índices passa pela aplicabilidade em sistemas estruturais mais complexos. Estruturas como pontes e passarelas podem apresentar arrojadas concepções estruturais, o que se reflete em comportamentos dinâmicos particulares, dificultando a identificação de danos.

Dessa maneira, utilizando os índices já estudados, a pesquisa aponta as limitações existentes e sugere a adoção de uma metodologia envolvendo a construção de um índice denominado Vetor Resultante (VR) para identificar a presença dos danos e localizá-los de forma eficiente. O modelo de estrutura escolhido busca visar uma aplicação mais ampla do processo de identificação de danos, onde possam ser contempladas de forma eficiente, estruturas complexas de grande porte. São incorporadas as variações das frequências naturais para aumentar a sensibilidade na quantificação dos danos e construído um par de informações para o cenário de dano: localização e intensidade. As Redes Neurais Artificiais são aplicadas pela sua eficiência no reconhecimento de padrões e assim aceleram o processo de identificação. Através dos resultados apresentados, pode-se concluir que:

- O índice VR é capaz de incorporar as alterações dos modos de vibração tridimensionais em um modelo danificado e assim identificar o local do dano em uma faixa de 5 metros;

- As frequências naturais, por possuírem uma maior sensibilidade à intensidade do dano, são incorporadas na metodologia para quantificar o dano localizado, que juntamente com os valores do índice VR, apresentam um alto índice de acertos (maior que 99% para erros de até 5% na intensidade do dano);
- As Redes Neurais Artificiais se mostram uma eficiente técnica de aprendizado de máquina para reconhecimento de padrões de danos nas estruturas, auxiliando no processo de identificação e quantificação.
- Portanto, a metodologia desenvolvida permite identificar e quantificar o dano de forma eficiente para a aplicação em questão e, conseqüentemente, auxiliando no direcionamento de possíveis processos de inspeções necessários por parte da gestão de monitoramento.

5.2.

Sugestões para investigações futuras

Como continuação para investigações futuras e pesquisas relacionadas ao tema de identificação de danos, sugere-se:

- Considerar ruídos dos dados de entrada da rede (índice de dano) para verificar a capacidade do método em lidar com variações no monitoramento dos dados através de sensores;
- Avaliar técnicas de redução de dimensionalidade de dados para reduzir a quantidade de entradas para a rede, diminuindo a necessidade de ter o valor de cada nó do modelo de elementos finitos e mesmo assim obter uma boa eficiência;
- Aplicação em dados reais de monitoramento de uma estrutura complexa;
- Avaliar a capacidade do método para identificação de danos múltiplos.
- Avaliar o uso da metodologia do Vetor Resultante utilizando como base para a sua formulação os demais índices de danos abordados neste trabalho, como a flexibilidade modal, MSE e a curvatura modal.

6

Referências bibliográficas

ARAÚJO, M. **Metodologia baseada em redes neurais artificiais para a detecção de danos estruturais**. [s.l.] Universidade de Brasília, 2017.

BAGCHI, A. et al. Model-Based Damage Identification in a Continuous Bridge Using Vibration Data. **Journal of Performance of Constructed Facilities**, v. 24, n. 2, p. 148–158, 2010.

BANDARA, R. P.; CHAN, T. H.; THAMBIRATNAM, D. P. Structural damage detection method using frequency response functions. **Structural Health Monitoring**, v. 13, n. 4, p. 418–429, 2014.

BISHOP, C. M. **Building Neural Network for Pattern Recognition**. Oxford: Clearedon Press, 1995.

BLACHOWSKI, B.; SWIERCZ, A.; PNEVMATIKOS, N. Experimental verification of damage location techniques for frame structures assembled using bolted connections. **COMPDYN 2015 - 5th ECCOMAS Thematic Conference on Computational Methods in Structural Dynamics and Earthquake Engineering**, n. May 2015, p. 2588–2599, 2015.

CARMINATI, M.; RICCI, S. Structural damage detection using nonlinear vibrations. **International Journal of Aerospace Engineering**, v. 2018, 2018.

CHA, Y. J.; KIM, Y.; YOU, T. Advanced Sensing and Structural Health Monitoring. **Journal of Sensors**, v. 2018, p. 3–6, 2018.

CHAO, S. H.; LOH, C. H.; TSENG, M. H. Structural damage assessment using output-only measurement: Localization and quantification. **Journal of Intelligent Material Systems and Structures**, v. 25, n. 9, p. 1097–1106, 2014.

CHINIFORUSH, A. A. et al. Modal-based damage detection of shear connectors in steel-timber composite (STC) beams. **SHMII 2017 - 8th International Conference on Structural Health Monitoring of Intelligent**

Infrastructure, Proceedings, n. January 2018, p. 1212–1221, 2017.

CINITHA, A.; UMESHA, P. K.; IYER, N. R. An overview of corrosion and experimental studies on corroded mild steel compression members. **KSCE Journal of Civil Engineering**, v. 18, n. 6, p. 1735–1744, 2014.

CLAYTON, E. H. et al. Damage detection and correlation-based localization using wireless mote sensors. **Proceedings of the 20th IEEE International Symposium on Intelligent Control, ISIC '05 and the 13th Mediterranean Conference on Control and Automation, MED '05**, v. 2005, p. 304–309, 2005.

CONTURSI, T.; MESSINA, A.; WILLIAMS, E. J. A multiple-damage location assurance criterion based on natural frequency changes. **JVC/Journal of Vibration and Control**, v. 4, n. 5, p. 619–633, 1998.

CORRÊA, R. A. P.; STUTZ, L. T.; TENENBAUM, R. A. Identificação de danos estruturais em placas baseada em um modelo de dano contínuo. **Revista Internacional de Metodos Numericos para Calculo y Diseno en Ingenieria**, v. 32, n. 1, p. 58–64, 2016.

CUTLER, J.; DICKENSON, M. **Introduction to Machine Learning with Python**. First Edit ed. Sebastopol, CA: O'Reilly Media, 2020.

DAWARI, V. et al. Structural Damage Identification Using Modal Curvature Differences. **IOSR Journal of Mechanical and Civil Engineering**, n. February 2013, p. 33–38, 2013.

FARRAR, C.; JAUREGUI, D. **Comparative study of damage identification algorithms applied to a bridge: I. Experiment**. Smart Materials and Structures, Volume 7, Issue 5. **Anais...**1997

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. DE S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, n. 2, p. 1–17, 2019.

FRIEDMANN, H.; KRAEMER, P. Vibration-based condition monitoring, structural health monitoring, population monitoring-Approach to a definition of the different concepts by means of practical examples from the field of wind energy. **8th European Workshop on Structural Health Monitoring, EWSHM 2016**, v. 4, n. July, p. 2409–2419, 2016.

GONÇALVES, V. A.; GASPAR, C. M. R.; SOTELINO, E. D. **Detecção**

dinâmica de danos em passarelas metálicas utilizando variação de modos de vibração. XII CONGRESSO BRASILEIRO DE PONTES E ESTRUTURAS. **Anais...**Rio de Janeiro: 2021

GORDAN, M. et al. Data mining-based damage identification of a slab-on-girder bridge using inverse analysis. **Measurement: Journal of the International Measurement Confederation**, v. 151, p. 107175, 2020.

HAKIM, S. J. S.; ABDUL RAZAK, H. Application of artificial neural network on vibration test data for damage identification in bridge girder. **International Journal of Physical Sciences**, v. 6, n. 35, p. 7991–8001, 2011.

HAKIM, S. J. S.; ABDUL RAZAK, H. Structural damage detection of steel bridge girder using artificial neural networks and finite element models. **Steel and Composite Structures**, v. 14, n. 4, p. 367–377, 2013.

JAYASUNDARA, N. et al. Vibration-based dual-criteria approach for damage detection in arch bridges. **Structural Health Monitoring**, v. 18, n. 5–6, p. 2004–2019, 2019.

JUN ZHAO. SENSITIVITY STUDY FOR VIBRATIONAL PARAMETERS USED IN DAMAGE DETECTION. **JOURNAL OF STRUCTURAL ENGINEERING**, n. April, p. 410–416, 1999.

KHAN, K. S. et al. Five steps to conducting a systematic review. **Journal of the Royal Society of Medicine**, v. 96, n. 3, p. 118–121, 2003.

KIM, J. et al. Damage Identification in Beam-Type Structures: Frequency-Based Method Versus Mode-Shape-Based Method. **Engineering Structures**, 2003.

KUDUS, S. A. et al. Damage assessment based on modal analysis of pipe structure. **Jurnal Teknologi**, v. 80, n. 5, p. 37–44, 2018.

LI, H.; YANG, H. Modal Strain Energy Decomposition Method for Damage Localization in 3D Frame Structures. n. September, p. 941–951, 2006.

MACHAVARAM, R.; SHANKAR, K. Structural damage identification using improved RBF neural networks in frequency domain. **Advances in Structural Engineering**, v. 15, n. 10, p. 1689–1703, 2012.

MARCY, M. Identificação e Quantificação de Danos em Pórticos Espaciais Via Método do Erro Residual e Redes Neurais Artificiais. p. 112,

2013.

MEKJAVIĆ, I.; DAMJANOVIĆ, D. Damage Assessment in Bridges Based on Measured Natural Frequencies. **International Journal of Structural Stability and Dynamics**, v. 17, n. 2, p. 1–20, 2016.

MONTALVÃO, D.; MAIA, N. M. M.; RIBEIRO, A. M. R. A review of vibration-based structural health monitoring with special emphasis on composite materials. **Shock and Vibration Digest**, v. 38, n. 4, p. 295–324, 2006.

NEVES, A. C. et al. A new approach to damage detection in bridges using machine learning. **Lecture Notes in Civil Engineering**, v. 5, n. January, p. 73–84, 2018.

NI, Y. Q.; WANG, B. S.; KO, J. M. Constructing input vectors to neural networks for structural damage identification. **Smart Materials and Structures**, v. 11, n. 6, p. 825–833, 2002.

PANDEY, A.; BISWAS, M.; SAMMAN, M. Damage Detection From Mode Changes in Curvature. **Journal of Sound and Vibration**, v. 145, p. 321–332, 1991.

PANDEY, A. K.; BISWAS, M. **Damage detection in structures using changes in flexibility** *Journal of Sound and Vibration*, 1994.

PATHIRAGE, C. S. N. et al. Structural damage identification based on autoencoder neural networks and deep learning. **Engineering Structures**, v. 172, n. May, p. 13–28, 2018.

PILLAI, P.; KRISHNAPILLAI, S. A hybrid neural network strategy for identification of structural parameters. **Structure and Infrastructure Engineering**, v. 6, n. 3, p. 379–391, 2010.

RIBEIRO, M. C.; GASPAR, C. M. R.; CARDOSO, D. C. T. **Avaliação do Comportamento Dinâmico de Passarelas Submetidas a Atividades Humanas**. XII CONGRESSO BRASILEIRO DE PONTES E ESTRUTURAS. **Anais...** Rio de Janeiro: 2021

RUCEVSKIS, S.; WESOŁOWSKI, M. Identification of damage in a beam structure by using mode shape curvature squares. **Shock and Vibration**, v. 17, n. 4–5, p. 601–610, 2010.

SALAWU, O. S.; WILLIAMS, C. Bridge Assessment Using Forced-Vibration Testing. **Journal of Structural Engineering**, v. 121, n. 2, p. 161–

173, 1995.

SHANG, X. Research on Damage Identification of a Beam Based on Curvature Mode. **IOP Conference Series: Materials Science and Engineering**, v. 382, n. 5, 2018.

SHI, Z.; LAW, S.; ZHANG, L. Damage Localization by directly using incomplete mode shapes. **Journal of Engineering Mechanics**, v. 126, n. 6, n. June, p. 656–660, 2000.

SILVA, R. L. et al. Empirical method for structural damage location using dynamic analysis. **Revista IBRACON de Estruturas e Materiais**, v. 13, n. 1, p. 19–31, 2020.

STUBBS, N.; KIM, J. Field Verification of a Nondestructive Damage Localization and Severity Estimation Algorithm. **Proceedings of SPIE - The International Society for Optical Engineering**, n. December 2013, 1995.

SUN, Y. Combined neural network and PCA for complicated damage detection of bridge. **5th International Conference on Natural Computation, ICNC 2009**, v. 2, p. 524–528, 2009.

TAN, Z. X. et al. Damage detection in steel-concrete composite bridge using vibration characteristics and artificial neural network. **Structure and Infrastructure Engineering**, v. 16, n. 9, p. 1247–1261, 2020.

TAROZZI, M.; PIGNAGNOLI, G.; BENEDETTI, A. Identification of damage-induced frequency decay on a large-scale model bridge. **Engineering Structures**, v. 221, n. June, p. 111039, 2020.

VINCENT, D. R. et al. Sensors driven ai-based agriculture recommendation model for assessing land suitability. **Sensors (Switzerland)**, v. 19, n. 17, 2019.

WEBB, G. T. et al. Categories of SHM Deployments : Technologies and Capabilities. v. 20, n. 1988, 2015.

WEBSTER, J.; WATSON, R. T. Analyzing the Past to Prepare for the Future: Writing a Literature Review. **MIS Quarterly**, v. 26, n. 2, p. xiii–xxiii, 2002.

WU, X.; GHABOUSSI, J.; GARRETT, J. H. Use of neural networks in detection of structural damage. **Computers and Structures**, v. 42, n. 4, p. 649–659, 1992.

YUEN, K.; LAM, H. On the complexity of artificial neural networks for

smart structures monitoring. **Engineering Structures**, v. 28, p. 977–984, 2006.

YUN, C. B.; BAHNG, E. Y. Substructural identification using neural networks. **Computers and Structures**, v. 77, n. 1, p. 41–52, 2000.

ZAHRASADAT MOMENIA, ARDALAN SABAMEHRB, A. B. AND M. N.-B. VIBRATION-BASED DAMAGE DETECTION IN A CABLE STAYED-BRIDGE. **9th European Workshop on Structural Health Monitoring (EWSHM 2018), July 10-13, 2018 in Manchester, UK (EWSHM 2018)**, 2018.

ZANG, C.; IMREGUN, M. Structural damage detection using artificial neural networks and measured FRF data reduced via principal component projection. **Journal of Sound and Vibration**, v. 242, n. 5, p. 813–827, 2001.

ZHENG, H. T. et al. Structural damage identification by neural networks and modal analysis. **Structural Health Monitoring and Intelligent Infrastructure - Proceedings of the 1st International Conference on Structural Health Monitoring and Intelligent Infrastructure**, v. 1, n. May, p. 635–639, 2003.

ZONTA, D. **Structural damage detection and localization by using vibrational measurements**. [s.l.] Università di Bologna, 2000.

ZONTA, D.; ADRIAENSSENS, S. Value of information: impact of monitoring on decision-making. **Structural Control and Health Monitoring**, n. May 2011, p. 1043–1056, 2011.

Apêndice

Apêndice A – Resultado conjunto das Redes 1 e 2 para um conjunto de teste de 131 dados.

Nº	Localização do dano real	Localização do dano prevista	Acurácia	Intensidade do dano real	Intensidade do dano prevista	Erro Absoluto
1	H	H	100%	90%	90,8%	0,77%
2	M	M	100%	90%	90,8%	0,77%
3	G	G	100%	5%	4,2%	0,83%
4	G	G	100%	5%	4,3%	0,72%
5	F	F	100%	45%	45,0%	0,01%
6	I	I	100%	90%	90,1%	0,07%
7	E	E	100%	15%	14,6%	0,43%
8	I	I	100%	10%	9,3%	0,67%
9	K	K	100%	45%	45,0%	0,02%
10	I	I	100%	45%	45,0%	0,04%
11	D	D	100%	30%	30,3%	0,30%
12	L	L	100%	90%	90,8%	0,77%
13	H	H	100%	75%	75,4%	0,45%
14	J	J	100%	10%	9,3%	0,69%
15	A	A	100%	30%	30,0%	0,04%
16	A	A	100%	5%	4,3%	0,66%
17	H	H	100%	15%	15,1%	0,13%
18	I	I	100%	90%	90,8%	0,77%
19	L	L	100%	75%	75,5%	0,45%
20	J	J	100%	5%	4,2%	0,76%
21	C	C	100%	15%	14,1%	0,93%
22	L	L	100%	10%	8,2%	1,77%
23	F	F	100%	75%	75,5%	0,45%
24	J	J	100%	10%	8,9%	1,10%
25	J	J	100%	5%	5,1%	0,08%

26	A	A	100%	5%	4,7%	0,30%
27	M	M	100%	10%	8,8%	1,19%
28	H	H	100%	60%	60,1%	0,15%
29	M	M	100%	45%	45,0%	0,01%
30	L	L	100%	90%	90,8%	0,77%
31	K	K	100%	75%	75,5%	0,45%
32	G	G	100%	30%	30,1%	0,10%
33	J	J	100%	45%	45,0%	0,01%
34	I	I	100%	45%	45,0%	0,02%
35	K	K	100%	75%	75,5%	0,45%
36	E	E	100%	75%	75,4%	0,45%
37	K	K	100%	60%	60,1%	0,14%
38	G	G	100%	60%	60,2%	0,16%
39	G	G	100%	15%	13,9%	1,14%
40	G	G	100%	30%	29,9%	0,07%
41	C	C	100%	15%	14,3%	0,65%
42	J	J	100%	5%	4,9%	0,11%
43	I	I	100%	10%	9,9%	0,12%
44	L	L	100%	90%	86,1%	3,86%
45	J	J	100%	10%	9,6%	0,42%
46	F	F	100%	10%	7,5%	2,47%
47	L	L	100%	10%	11,9%	1,87%
48	A	A	100%	10%	6,6%	3,40%
49	A	A	100%	10%	8,4%	1,64%
50	J	J	100%	30%	30,1%	0,11%
51	B	B	100%	10%	6,6%	3,45%
52	J	J	100%	90%	90,8%	0,77%
53	L	L	100%	10%	7,1%	2,90%
54	B	B	100%	45%	45,0%	0,01%
55	M	M	100%	90%	86,8%	3,25%
56	J	J	100%	75%	75,5%	0,45%
57	L	L	100%	45%	45,0%	0,02%
58	J	J	100%	75%	75,5%	0,45%
59	L	L	100%	5%	4,4%	0,61%
60	F	F	100%	60%	60,2%	0,16%
61	E	E	100%	10%	7,5%	2,51%
62	J	J	100%	30%	29,9%	0,07%
63	I	I	100%	30%	30,0%	0,05%

64	B	B	100%	45%	45,0%	0,02%
65	M	M	100%	60%	60,2%	0,18%
66	E	E	100%	75%	75,5%	0,45%
67	E	E	100%	75%	75,5%	0,45%
68	H	H	100%	10%	9,4%	0,57%
69	E	E	100%	75%	75,5%	0,45%
70	L	L	100%	30%	30,1%	0,06%
71	K	K	100%	15%	14,0%	1,04%
72	J	J	100%	90%	75,6%	14,38%
73	I	I	100%	30%	30,0%	0,03%
74	I	I	100%	60%	60,1%	0,11%
75	B	B	100%	75%	75,3%	0,31%
76	D	D	100%	30%	30,0%	0,03%
77	A	A	100%	90%	90,8%	0,77%
78	H	H	100%	30%	30,0%	0,01%
79	B	B	100%	10%	9,6%	0,35%
80	I	I	100%	90%	90,8%	0,77%
81	C	C	100%	5%	5,7%	0,65%
82	J	J	100%	5%	4,3%	0,66%
83	H	H	100%	45%	45,0%	0,02%
84	M	M	100%	45%	45,0%	0,02%
85	J	J	100%	75%	75,5%	0,45%
86	E	E	100%	30%	30,0%	0,05%
87	J	J	100%	15%	14,2%	0,84%
88	B	B	100%	75%	75,5%	0,45%
89	I	I	100%	15%	13,9%	1,07%
90	J	J	100%	10%	10,5%	0,55%
91	J	J	100%	60%	60,2%	0,15%
92	F	F	100%	15%	14,4%	0,61%
93	D	D	100%	5%	4,3%	0,71%
94	A	A	100%	45%	44,9%	0,06%
95	B	B	100%	60%	60,4%	0,42%
96	M	M	100%	90%	90,8%	0,76%
97	H	H	100%	30%	29,9%	0,07%
98	M	M	100%	60%	60,2%	0,15%
99	B	B	100%	60%	60,2%	0,15%
100	J	J	100%	60%	60,1%	0,14%
101	J	J	100%	90%	90,8%	0,77%

102	L	L	100%	90%	90,7%	0,75%
103	M	M	100%	30%	29,9%	0,06%
104	J	J	100%	60%	60,1%	0,15%
105	L	L	100%	15%	14,0%	0,96%
106	J	J	100%	90%	90,7%	0,68%
107	M	M	100%	45%	45,0%	0,00%
108	B	B	100%	75%	75,5%	0,45%
109	A	A	100%	90%	90,4%	0,44%
110	A	A	100%	75%	75,5%	0,45%
111	L	L	100%	60%	60,2%	0,18%
112	H	H	100%	90%	90,8%	0,77%
113	L	L	100%	15%	14,3%	0,66%
114	K	K	100%	15%	13,1%	1,87%
115	M	M	100%	45%	45,0%	0,01%
116	A	A	100%	45%	45,0%	0,01%
117	L	L	100%	5%	4,4%	0,60%
118	M	M	100%	75%	75,5%	0,45%
119	H	H	100%	90%	90,8%	0,77%
120	G	G	100%	60%	60,2%	0,16%
121	M	M	100%	30%	30,0%	0,03%
122	L	L	100%	75%	75,5%	0,45%
123	C	C	100%	60%	60,3%	0,35%
124	J	J	100%	90%	90,8%	0,77%
125	D	D	100%	45%	45,0%	0,02%
126	M	M	100%	90%	90,7%	0,71%
127	E	E	100%	10%	15,1%	5,10%
128	G	G	100%	5%	4,4%	0,59%
129	H	H	100%	5%	4,2%	0,79%
130	C	C	100%	60%	60,2%	0,18%
131	M	M	100%	10%	10,0%	0,01%