



UNIVERSIDADE
LUSÓFONA

CENTRO UNIVERSITÁRIO DE LISBOA
FACULDADE DE ENGENHARIA
MESTRADO EM ENGENHARIA CIVIL

**MONITORIZAÇÃO DA SAÚDE ESTRUTURAL
BASEADA NUMA ABORDAGEM HÍBRIDA NO
TREINO DE ALGORITMOS DE
APRENDIZAGEM AUTOMÁTICA**

VERSÃO FINAL

Dissertação defendida em provas públicas para a obtenção do grau de Mestre em Engenharia Civil, orientada por Prof. Doutor Ionut D. Moldovan e coorientada por Prof. Doutor Elói J. F. Figueiredo

Dennerson Gomes de Carvalho, 22105598

2024

www.ulusofona.pt



UNIVERSIDADE
LUSÓFONA

CENTRO UNIVERSITÁRIO DE LISBOA
FACULDADE DE ENGENHARIA
MESTRADO EM ENGENHARIA CIVIL

MONITORIZAÇÃO DA SAÚDE ESTRUTURAL BASEADA NUMA ABORDAGEM HÍBRIDA NO TREINO DE ALGORITMOS DE APRENDIZAGEM AUTOMÁTICA

VERSÃO FINAL

Dissertação defendida em provas públicas na
Universidade Lusófona, Centro Universitário de
Lisboa no dia 24 de abril de 2024, perante o júri,
nomeado pelo Despacho de Nomeação n.º: 930/2024
de 29 de julho de 2024, com a seguinte composição:

Presidente: Professor Doutor Vítor Filipe Silva
Antunes

Arguente: Professor Doutor Luís Oliveira Santos;

Orientador: Professor Doutor Dragos Ionut
Moldovan

Co-Orientador: Professor Doutor Elói J. F.
Figueiredo

Dennerson Gomes de Carvalho, n.º. 22105598

2024

Epígrafe

A monitorização constante é o olhar atento que preserva a vitalidade das estruturas, construindo um futuro seguro sobre os alicerces do presente.

Agradecimentos

Quero expressar minha profunda gratidão aos meus pais, Odenir Miguel de Carvalho e Cleuza Gomes Moreira Miguel, cujo apoio incansável e amor incondicional foram a força motriz por trás da realização deste sonho. Agradeço por sempre acreditarem em mim, por compartilharem desse sonho e por serem fonte constante de inspiração e encorajamento ao longo dessa jornada. Este momento é também fruto do amor e dedicação de vocês.

A minha irmã Glenda Gomes de Carvalho e meu cunhado Thalles Verner por todo carinho e apoio ao longo dessa fase.

Aos meus respeitáveis orientadores, o Prof. Doutor Elói Figueiredo e o Prof. Doutor Ionut Moldovan, pelos valiosos insights, orientação perspicaz e generosidade ao compartilhar seus vastos conhecimentos. Sua dedicação e apoio foram fundamentais para o sucesso desta dissertação, sendo referências admiráveis ao longo desta trajetória acadêmica.

Agradeço também aos meus patrões e amigos, os Arquitetos Ricardo Silva Pinto e Margarida Gomes Simões, por sempre me incentivarem e apoiarem em meu crescimento profissional e pessoal ao longo desses anos.

Por último à pessoa que sempre me apoiou incondicionalmente e esteve ao meu lado em todos os momentos, minha esposa Charlene de Lira Rocha Gomes. Seu amor, compreensão e encorajamento foram fundamentais para superar os desafios desta jornada acadêmica. Agradeço por ser minha companheira e por compartilhar este caminho comigo, sua presença fez toda a diferença.

A todos o meu muito obrigado!

Resumo

A monitorização da saúde estrutural (SHM) é uma prioridade de investigação devido ao envelhecimento constante do património construído. Avanços recentes têm demonstrado a aplicabilidade de SHM para deteção de dano de forma atempada e automática. O princípio de funcionamento da SHM baseia-se no reconhecimento de padrões, com base em experiência prévia, para detetar e diagnosticar dano na estrutura monitorizada. Dados adquiridos em estruturas semelhantes, em funcionamento normal e danificadas, são utilizados como base de comparação para classificar novos dados provenientes da estrutura monitorizada. Contudo, em estruturas de Engenharia Civil, este processo é prejudicado pela falta de acesso a dados correspondentes a condições danificadas (ou em condições operacionais excecionais), o que tipicamente limita a SHM à deteção de anomalias. Esta dissertação apresenta uma abordagem híbrida à classificação da condição estrutural de pontes, baseada no treino supervisionado de algoritmos de aprendizagem de máquina, utilizando dados de monitorização da estrutura não danificada e dados numéricos correspondendo a condições operacionais excecionais e danos estruturais. A passagem pedonal de betão armado e pré-esforçado localizada junto ao campus da Universidade Lusófona foi usada como caso de estudo. A ponte foi medida através do levantamento de nuvens de pontos, o que proporcionou a sua representação tridimensional detalhada. Finalmente, o trabalho aqui apresentado valida a aplicação de telemóvel App4SHM para estimar as frequências naturais de vibração da ponte e analisar a sua condição estrutural.

Palavras-chave: Pontes, Monitorização da Saúde Estrutural, Deteção de Dano, Modos de Vibração, Aprendizagem Supervisionada e não Supervisionada, Modelos de Elementos Finitos.

Abstract

Structural health monitoring (SHM) has emerged as a research priority due to the constant aging of built heritage. Recent advances have demonstrated the applicability of SHM for timely and automatic damage detection. The operating principle of SHM is grounded in statistical pattern recognition, based on previous experience, to detect and diagnose damage in the monitored structure. Data acquired on similar structures, under both normal and damaged conditions, are used as a basis of comparison to classify new data coming from the monitored structure. However, in Civil Engineering structures, this process is hampered by the lack of access to data corresponding to damaged conditions (and/or uncommon operational conditions), which typically restricts SHM to outlier detection. This dissertation presents a hybrid approach to the classification of the structural condition of bridges, based on supervised training of machine learning algorithms, using monitoring data from the undamaged structure and numerical data corresponding to uncommon operational conditions and damage. The reinforced and prestressed concrete pedestrian crossing located next to the Lusófona University campus is used as a case study. The bridge was measured using point clouds, which secured its detailed three-dimensional representation. Finally, this study validates the App4SHM smartphone application to estimate natural vibration frequencies and analyze the structural condition of bridges.

Keywords: Bridges, Structural Health Monitoring, Damage Detection, Modes of Vibration, Supervised and Unsupervised Learning, Finite Element Models.

Abreviaturas, siglas e símbolos

¹

ANN	<i>Artificial Neural Network</i>
BMS	Sistema de Gerenciamento de Pontes (<i>Bridge Management System</i>)
DT	<i>Decision Trees</i>
ELS	Estado Limite de Serviço
ENS	<i>Ensemble Classification</i>
KNN	<i>k-Nearest Neighbour</i>
MLA	Algoritmo de Aprendizagem de Máquina
NB	<i>Naive Bayes Classifier</i>
PFA	Probabilidade de Falso Alarme
QD	<i>Quadratic Discriminant</i>
SHM	Monitorização da Saúde Estrutural (<i>Structural Health Monitoring</i>)
SVM	<i>Support Vector Machines</i>

¹ Neste documento, optou-se por não traduzir algumas denominações consagradas da língua inglesa. Em outros casos, notavelmente Monitorização da Saúde Estrutural e Algoritmos de Aprendizagem de Máquina, as denominações foram traduzidas, mas preservaram-se as abreviações consagradas na língua inglesa (SHM e MLA, respetivamente).

Índice Geral

CAPITULO 1 - Introdução	1
1.1 Enquadramento	1
1.2 Justificativa e relevância	5
1.3 Objetivos	9
1.4 Metodologia	10
1.5 Estrutura do Trabalho.....	11
CAPITULO2 - Estado da Arte	13
2.1 Considerações iniciais	13
2.2 Conceitos de saúde estrutural de pontes.....	13
2.3 Monitorização estrutural e avaliação de danos	16
2.4 Princípios e tipos de dano estrutural	17
2.5 Identificação de danos.....	18
2.6 Abordagem híbrida na monitorização	21
2.7 Abordagens de aprendizagem não supervisionado e supervisionado	23
2.8 Utilização de telemóveis na SHM.....	25
2.9 Considerações finais.....	27
CAPITULO 3 - Caso de estudo e sistema de monitorização.....	29
3.1 Considerações iniciais	29
3.2 Passagem pedonal do Campo Grande	29
3.3 Inspeção visual	31
3.4 Levantamento por nuvem de pontos	32
3.5 Aquisição de dados com App4SHM	38
3.6 Modelação numérica	44
3.6.1 Compatibilidade entre programas.....	44
3.6.2 Modelo numérico inicial.....	44
3.6.3 Parâmetros de calibração	48
3.6.4 Procedimento de calibração e modelo numérico final.....	49
3.7 Considerações finais.....	52
CAPITULO 4 - Resultados e discussão.....	55
4.1 Considerações iniciais	55

4.2	Bases de dados híbridos.....	56
4.2.1	Considerações gerais.....	56
4.2.2	Extensão probabilística de observações numéricas	56
4.3	Composição do conjunto de observações	58
4.3.1	Fundamentação inicial	58
4.3.2	Observações experimentais normais	58
4.3.3	Observações numéricas com acréscimo de massa	60
4.3.4	Observações numéricas com simulação de dano	65
4.4	Dados de entrada.....	68
4.5	Classificação não supervisionada	69
4.5.1	Fundamentação inicial	69
4.5.2	Aprendizagem não supervisionada na passagem pedonal	70
4.5.3	Resultados da classificação não supervisionada	73
4.6	Classificação supervisionada	77
4.6.1	Fundamentação inicial	77
4.6.2	Metodologia	77
4.6.3	Resultados	81
4.7	Considerações finais	92
	Conclusão e trabalhos futuros.....	95
5.1	Conclusão	95
5.2	Trabalhos futuros.....	99
	Bibliografia	101

Índice de Quadros

Quadro 1	Frequências naturais de vibração medidas e do modelo inicial	48
Quadro 2	Frequências próprias de vibração medidas e do modelo calibrado	51
Quadro 3	Frequências naturais de vibração com adição de carga.....	60
Quadro 4	Resultados da simulação de dano.....	67
Quadro 5	Composição das observações de entrada com rótulos detalhados	69
Quadro 6	Detalhes da precisão por categoria.....	76
Quadro 7	Detalhes da precisão por subcategoria	76
Quadro 8	Frequências médias na base de treino de um algoritmo supervisionado	77
Quadro 9	Composição total de observações de entrada	78
Quadro 10	Composição das observações de treino e de teste	81
Quadro 11	Taxa de precisão por categoria.....	83
Quadro 12	Taxa de precisão por categorias detalhadas	84
Quadro 13	Taxa de aceitabilidade	85
Quadro 14	Comparação das classificações relativa e absoluta	86
Quadro 15	Matriz confusão configuração 1	90
Quadro 16	Matriz confusão configuração 2	91
Quadro 17	Matriz confusão configuração 3.....	91
Quadro 18	Matriz confusão consolidada.....	92

Índice de Figuras

Figura 1.1 Associação da SHM ao sistema nervoso humano (adaptada de Civil Research Group, 2024).....	2
Figura 1.2 Capa revista Veja São Paulo, destacando o colapso de uma ponte.....	6
Figura 1.3 Notícia do colapso da ponte	7
Figura 1.4 Colapso ponte sobre o rio Douro (Diário de Notícias, 2021)	7
Figura 2.1 Representação simplificada do processo SHM adaptada de (Neves, 2020)	15
Figura 2.2 Níveis para identificação de danos (adaptada de Figueiredo, 2010).....	19
Figura 2.3 Fluxograma da abordagem híbrida adaptado de (Bud et al., 2022)	22
Figura 2.4 Representação esquemática dos tipos de aprendizagem e dos respetivos algoritmos de interpretação	24
Figura 3.1 Localização passagem pedonal (Google, 2005).....	30
Figura 3.2 Passagem pedonal do Campo Grande	30
Figura 3.3 Desenhos extraídos do projeto estrutural	31
Figura 3.4 Levantamento por nuvem de pontos da passagem pedonal do Campo Grande.....	33
Figura 3.5 Visualização da nuvem de pontos	33
Figura 3.6 Vista isométrica da passagem pedonal através da nuvem de pontos	34
Figura 3.7 Análise da nuvem de pontos no programa Revit	35
Figura 3.8 Maquete da passagem pedonal.....	36
Figura 3.9 Captura nuvem de pontos utilizando telemóvel.....	37
Figura 3.10 Arquitetura da App4SHM (Figueiredo et al., 2022)	38
Figura 3.11 Identificação da estrutura	39
Figura 3.12 Medição da série temporal de aceleração	40
Figura 3.13 Extração das frequências naturais de vibração	41
Figura 3.14 Gráficos de identificadores de dano.....	42
Figura 3.15 Plataforma de administração remota da App4SHM	43
Figura 3.16 Gráfico com as 120 observações iniciais	44
Figura 3.17 Vista do modelo numérico	45
Figura 3.18 Corte transversal do tabuleiro central	45
Figura 3.19 Geometria real e simplificada do pilar.....	47
Figura 3.20 Modelação da seção transversal das vigas	47
Figura 3.21 Primeiro modo de vibração: Modo de flexão simples	51

Figura 3.22 Segundo modo de vibração: Modo de torção	52
Figura 3.23 Terceiro modo de vibração: Segundo modo de flexão	52
Figura 4.1 Distribuições e histogramas de frequências naturais observadas experimentalmente	59
Figura 4.2 Visualização tridimensional das observações experimentais compostas por três frequências naturais.....	59
Figura 4.3 Representação dos acréscimos de carga	60
Figura 4.4 Observações experimentais (azul) e expansão probabilística (vermelho) das primeiras três frequências naturais de vibração para quatro cenários estruturais	61
Figura 4.5 Base híbrida de observações da estrutura não danificada	63
Figura 4.6 Identificação das observações atípicas (vermelho) no conjunto das observações	64
Figura 4.7 Terceiro modo de vibração tem um nó no ponto central do vão	65
Figura 4.8 Discretização na zona central com identificação do trecho danificado.....	66
Figura 4.9 Conjuntos de observações da estrutura não danificada (azul) e da estrutura danificada (vermelho)	68
Figura 4.10 Histogramas da base de treino	71
Figura 4.11 Elipses de confiança sobre observações no espaço bidimensional das frequências de vibração	72
Figura 4.12 Classificação das observações assumindo um PFA de 0.01.....	73
Figura 4.13 Observações classificadas como típicas e atípicas (base de treino foi construída utilizando 80% do conjunto de condição normal e 80% e do conjunto provenientes da condição de massa de 25 pessoas)	74
Figura 4.14 Resultados da classificação não supervisionada.....	75
Figura 4.15 Unificação de observações no espaço das duas primeiras frequências naturais de vibração.....	79
Figura 4.16 Observações da condição danificada, discriminadas por três subconjuntos de dano.....	80
Figura 4.17 Observações da condição com adição de massa, discriminadas por quatro subconjuntos de massa	80
Figura 4.18 Observações da base de treino.....	82
Figura 4.19 Observações bem e mal classificadas pelo algoritmo ENS	88
Figura 4.20 Classificações corretas e incorretas utilizando o algoritmo ENS	89

CAPITULO 1 - Introdução

1.1 Enquadramento

A qualidade de vida humana está intrinsecamente ligada à sua própria saúde. Fazendo uma analogia direta, o mesmo se aplica às estruturas, sendo crucial monitorizar sua saúde mesmo a partir da fase de construção. Portanto, a necessidade constante de avaliação e monitorização da saúde estrutural está cada vez mais presente na engenharia. No caso das pontes, a análise da saúde estrutural tem como objetivo avaliar o comportamento operacional, quantificar a capacidade de carga e identificar o estado de deterioração a fim de tomar medidas preventivas ou corretivas. Métodos tradicionais como o Sistema de Gerenciamento de Pontes (*Bridge Management System* - BMS) utilizam inspeções visuais periódicas e testes não destrutivos. No entanto, essas abordagens podem apresentar limitações em termos de precisão, alcance e eficiência na deteção de problemas estruturais sutis ou em estágios iniciais.

É nesse contexto que surge a necessidade de uma abordagem mais abrangente e integrada para a análise da saúde estrutural de pontes, geralmente denominada de Monitorização da Saúde Estrutural (*Structural Health Monitoring* - SHM). SHM traz uma abordagem que busca combinar métodos mais tradicionais de monitorização recorrendo a sensores permanentes e análise de modelos numéricos com tecnologias mais recentes, algoritmos provenientes da inteligência artificial, uso de drones e modelação de informação da construção. A integração de várias técnicas permite obter uma visão mais completa e detalhada do comportamento da ponte ao longo da sua vida útil, identificando anomalias, tendências e variações em condições normais e extremas.

A designação “saúde” é aqui usada em vez da tradicional “integridade”, de forma a melhor associar a monitorização estrutural à necessidade que o ser humano tem de continuamente acompanhar a sua condição de saúde.

A Figura 1.1 apresenta o conceito por detrás da SHM, assemelhando-o ao sistema nervoso humano, em que o cérebro (computador central) processa informações provenientes dos nervos (sensores) e decide ações para mitigar a sensação de dor (dano). Nesse contexto, os algoritmos de aprendizagem de máquina (*Machine Learning Algorithms* - MLA) desempenham um papel crucial, pois são capazes de aprender com experiências anteriores, ou seja, a partir dos dados de monitorização. Os MLA permitem que computadores e algoritmos

reconhecem o comportamento estrutural, mesmo sem possuir conhecimento prévio das leis físicas das estruturas.




Figura 1.1 Associação da SHM ao sistema nervoso humano (adaptada de Civil Research Group, 2024)

A abordagem SHM não apenas melhora a capacidade de deteção precoce de problemas estruturais, mas também contribui para a tomada de decisões informadas em relação à manutenção, reabilitação ou substituição de pontes. Além disso, ao utilizar tecnologias avançadas, é possível aumentar a eficiência dos processos de avaliação (agilidade, manutenção preditiva, entre outros) e estabelecer um histórico de dados valiosos para análises comparativas e estudos de desempenho a longo prazo.

Danos podem afetar negativamente o comportamento e a capacidade de uma estrutura desempenhar de forma segura sua função pretendida. Portanto, o principal objetivo do SHM, é conseguir detetar o dano na estrutura em tempo quase real, podendo assim aplicar ações corretivas, reduzindo custos e o risco de falhas catastróficas (Yuan et al., 2020).

Em estruturas reais existe uma alta complexidade na obtenção de dados, causada pelos seguintes fatores (entre outros):

- Dificuldade de acesso: Algumas estruturas podem estar localizadas em locais de difícil acesso, como pontes sobre rios profundos, tornando a coleta de dados fisicamente desafiadora.
- Instalação de sensores: A instalação de sensores em locais estratégicos pode ser complicada, exigindo muitas vezes equipamentos especializados e profissionais treinados.
- Variações ambientais: As condições ambientais, como vento, temperatura e umidade, podem afetar a qualidade dos dados. Isso requer considerações especiais ao interpretar as leituras.
- Riscos para os operadores: Em alguns casos, a coleta de dados pode envolver riscos para a segurança dos operadores, especialmente em estruturas grandes, complexas ou em áreas geograficamente desafiadoras.
- Equipamentos especializados: A obtenção de dados de alta qualidade muitas vezes exige investimentos em equipamentos especializados, o que pode ser financeiramente desafiador.
- Necessidade de interrupção: Em alguns casos, pode ser necessário interromper as operações normais da estrutura para instalar sensores ou realizar medições, o que pode ter implicações práticas e económicas.
- Falta de dados anteriores: Em estruturas mais antigas, pode haver uma escassez de dados históricos para comparação, o que torna mais desafiador avaliar mudanças ao longo do tempo.
- Diferenças entre estruturas: Cada estrutura tem características únicas, exigindo abordagens personalizadas para a coleta de dados e análise.

Sabendo que as características de vibração estão diretamente relacionadas às alterações físicas da estrutura, que geralmente causam variação da rigidez, é possível detetar dano através da monitorização das mesmas.

Para a identificação das características de vibração de uma ponte será necessário recorrer a aparelhos de monitorização, podendo estes ser permanentes ou móveis. Um dos dispositivos mais utilizados para esse fim são os acelerómetros. Esses dispositivos medem as acelerações de uma estrutura ao longo do tempo. As series temporais resultantes podem ser utilizadas para extrair as frequências próprias de vibração da estrutura e, no caso em que a medição se faz com múltiplos acelerómetros, os modos normais de vibração. É importante

citar que uma estrutura tem características de vibração muito específicas em relação a outras estruturas, sendo elas distintas e únicas. Por isso, as características de vibração são utilizáveis para o reconhecimento do comportamento normal dessa estrutura. Tipicamente, esse reconhecimento faz-se através de um paradigma de reconhecimento de padrões. Este paradigma tem quatro etapas: avaliação operacional, aquisição de dados, extração de características, e modelação estatística para classificação das características (Figueiredo, 2010).

Ainda neste âmbito, um desafio relevante é a limitação de algumas das técnicas de reconhecimento de padrões em apenas identificar valores atípicos. Esta característica restringe a capacidade de distinguir se variações nas observações são resultantes de danos reais, condições ambientais extremas ou irregularidades operacionais. A falta de precisão na determinação da origem das anomalias pode comprometer a eficácia dos diagnósticos, sendo que essas técnicas não permitem especificar o tipo de dano ou rotular adequadamente a condição da estrutura. Consequentemente, embora o reconhecimento de padrões seja útil para a deteção inicial de irregularidades, é imperativo integrá-lo com metodologias analíticas mais avançadas. Esta integração visa aprimorar a interpretação das causas e naturezas das anomalias detetadas, facilitando assim intervenções mais precisas e uma manutenção mais eficiente.

Por outro lado, o uso de telemóveis como sensores para SHM é uma abordagem inovadora na engenharia civil (Figueiredo et al., 2022). A ubiquidade de telemóveis é as suas capacidades avançadas de sensorização, processamento e conectividade tornaram possível explorar esses dispositivos como ferramentas de monitorização em tempo real para diversas aplicações, incluindo pontes e outras infraestruturas. Com o avanço tecnológico, é possível encontrar e desenvolver soluções cada vez mais “leves” em termos de custo efetivo, mobilidade e flexibilidade, facilmente utilizáveis em diferentes partes de uma ponte, permitindo uma abordagem de monitorização flexível e adaptável.

Os telemóveis estão equipados com uma variedade de sensores integrados, como acelerómetros, giroscópios, magnetómetros, GPS e câmeras, que podem ser explorados para coletar dados relacionados à saúde estrutural de uma ponte. Esses sensores podem detetar movimentos, vibrações e mudanças na orientação, que são indicativos de deformações ou mudanças nas condições da estrutura. Neste contexto, App4SHM é uma aplicação desenvolvida na Universidade Lusófona que permite utilizar telemóveis como sensores em pontes e tirantes (Figueiredo et al., 2022). A aplicação não exclui os métodos existentes

utilizados para monitorização, apenas potencializa com eficiência a realização dos mesmos. App4SHM opera de forma fácil, rápida e prática na monitorização da saúde estrutural das pontes, proporcionando uma abordagem inovadora e acessível para a monitorização frequente do estado das estruturas.

A utilização de telemóveis como sensores ilustra a capacidade de aproveitar tecnologias amplamente disponíveis para melhorar a eficácia e a acessibilidade da monitorização estrutural. No entanto, apesar das potenciais vantagens da abordagem utilizando telemóveis como sensores, existem desafios a serem superados, como a integração de diferentes tipos de dados, fidelidade das medições e a interpretação correta das informações coletadas.

1.2 Justificativa e relevância

No cenário deste estudo, é imperativo realçar as valiosas contribuições trazidas pelas obras de arte, que transcendem meramente o estético para influenciar, de forma marcante, diversos aspetos do contexto urbano e da sociedade em geral. As obras de arte desempenham um papel essencial na promoção do desenvolvimento urbano e na melhoria da qualidade de vida, ao mesmo tempo em que acrescentam camadas significativas à experiência estética do espaço público. As obras de arte, sobretudo pontes e viadutos, têm sido agentes fundamentais na criação de uma infraestrutura que permite a fluidez do tráfego e a interconexão eficaz entre diferentes localidades. Além disso, essas estruturas muitas vezes se tornam marcos emblemáticos, enriquecendo a identidade visual da cidade e proporcionando um sentido de pertencimento e referência.

Ao longo da história, as pontes e os viadutos têm superado desafios geográficos, estabelecendo ligações vitais sobre vales, cursos d'água e áreas montanhosas. Essa superação de obstáculos naturais tem contribuído para a expansão das comunidades e a facilitação do acesso a recursos essenciais. Ademais, as obras de arte têm o poder de inspirar o pensamento criativo, promover a coesão social e estimular o diálogo cultural. Elas representam mais do que estruturas físicas; são expressões tangíveis da criatividade humana que enriquecem a experiência quotidiana das comunidades. Deste modo, ao investigar a função das obras de arte, torna-se evidente a sua substancial relevância no contexto económico global. Na Figura 1.2, destaca-se a necessidade premente de vigilância e conservação, uma vez que as interrupções inadequadas do funcionamento dessas estruturas podem ocasionar impactos significativos, a ponto de afetar o funcionamento integral de uma cidade. Nesse sentido,

sublinha-se a essencialidade dos procedimentos adequados de monitorização e manutenção para garantir a operacionalidade e segurança desses elementos urbanos.




Figura 1.2 Capa revista Veja São Paulo, destacando o colapso de uma ponte

Em diferentes partes do mundo, registram-se diversos casos de colapsos em obras de arte, sublinhando a crucial necessidade de uma monitorização abrangente, especialmente no âmbito da segurança estrutural. O incidente marcante da queda da Ponte Hintze Ribeiro sobre o Rio Douro em 2001, ilustrado na Figura 1.3, representa um marco, reconhecido como o momento de despertar em relação à gestão de pontes, em Portugal (Figueiredo et al., 2013). As estacas, em sua maioria compostas de madeira, encontravam-se cravadas em solo arenoso, o qual sofreu intensa erosão devido à ação hidrodinâmica do rio (Mitre, 2005). O mencionado processo erosivo substancial ocasionou uma degradação significativa do confinamento das estacas, culminando em instabilidade nas fundações da ponte e, conseqüentemente, resultando em perdas de vidas humanas (Figura 1.4).



Figura 1.3 Notícia do colapso da ponte



Figura 1.4 Colapso ponte sobre o rio Douro (Diário de Notícias, 2021)

Esses eventos ressaltam a necessidade premente de aprimorar a compreensão e a monitorização das pontes, com o intuito de reduzir significativamente a incidência de

acidentes e problemas estruturais. A exposição direta aos agentes ambientais de deterioração e o regime de solicitação dinâmico aceleram a progressão de problemas patológicos, contribuindo para a perda de desempenho das estruturas. A SHM, ao visar aprimorar a gestão e a manutenção dessas estruturas, apresenta uma série de razões fundamentais que sustentam sua importância:

- **Sustentabilidade:** A monitorização constante e a manutenção adequada das estruturas contribuem para a sustentabilidade, evitando a necessidade prematura de substituição e minimizando o impacto ambiental associado à construção de novas estruturas (Poças, 2009).
- **Segurança pública:** A segurança dos utilizadores é uma das preocupações em estruturas como pontes, citando riscos sociais, ambientais, tecnológicos, e biológicos (Castro et al., 2005). A capacidade de identificar de forma antecipada qualquer deterioração ou anomalia estrutural pode prevenir acidentes catastróficos, reduzindo o risco de colapsos repentinos que colocam em perigo a vida das pessoas.
- **Longevidade das estruturas:** Uma monitorização constante permite identificar o desgaste das estruturas ao longo do tempo. Compreender os padrões de envelhecimento e as taxas de deterioração permite uma intervenção mais precisa e proativa para estender a vida útil das estruturas e maximizar o retorno sobre o investimento em infraestrutura (Mishra et al., 2022).
- **Eficiência de custos:** A manutenção preventiva e baseada em dados é mais económica a longo prazo do que a manutenção corretiva após falhas (Ramos, 2010). A SHM permite uma alocação mais eficaz de recursos, direcionando as ações de manutenção para áreas específicas que realmente necessitam de atenção.
- **Resposta a eventos extremos:** Eventos como sismo, enchentes ou furacões podem afetar drasticamente a saúde das estruturas. A SHM fornece informações em tempo real sobre o desempenho das estruturas durante e após esses eventos, auxiliando na tomada de decisões críticas de evacuação e resposta de emergência (Farrar et al., 2000).
- **Desenvolvimento de novas tecnologias:** O estudo de SHM impulsiona o desenvolvimento de tecnologias avançadas, como sensores inteligentes,

sistemas de aquisição de dados e algoritmos de análise de dados em tempo real. Isso não apenas beneficia o campo da monitorização estrutural, mas também tem implicações em outras áreas da engenharia (Singh et al., 2022).

- Otimização de recursos: Por meio da análise contínua dos dados coletados, é possível otimizar o uso das estruturas (Santos et al., 2016). Isso pode incluir a adaptação de cargas, a implementação de restrições temporárias ou a modificação de fluxos de tráfego para preservar a integridade da estrutura.

Em resumo, o estudo sobre SHM é fundamental para garantir a segurança das estruturas, prolongar sua vida útil, otimizar recursos, responder a eventos extremos e impulsionar o desenvolvimento de tecnologias inovadoras. A aplicação eficaz do SHM resulta em infraestruturas mais seguras, econômicas e resilientes, contribuindo diretamente para a qualidade de vida e o progresso da sociedade como um todo.

1.3 Objetivos

A presente dissertação tem como objetivo e contribuição científica a aplicação da SHM numa passagem pedonal utilizando algoritmos de aprendizagem de máquina com treino não supervisionado e supervisionado, capazes de reconhecer valores atípicos e classificar a condição estrutural.

Esta dissertação tem também os seguintes objetivos específicos:

- Demonstrar a aplicabilidade de telemóveis num contexto de SHM em pontes;
- Demonstrar a aplicabilidade dos modelos numéricos de elementos finitos para gerar dados numéricos semelhantes aos experimentais;
- Investigar a capacidade dos modelos numéricos de gerar dados referentes a cenários estruturais pouco frequentes, simulando condições específicas de danos ou eventos incomuns por meio de modelos numéricos probabilísticos;
- Testar a utilização de conjunto híbrido de observações provenientes de medições experimentais e do modelo numérico;
- Explorar a mudança de uma abordagem não supervisionada para uma supervisionada no contexto de SHM, buscando compreender como essa transição pode impactar a eficácia e a precisão do sistema de deteção de anomalias;

- Testar diferentes algoritmos de aprendizagem máquina (MLA) para avaliar e comparar a eficácia de cada abordagem na deteção de anomalias e na caracterização do comportamento estrutural.

1.4 Metodologia

A metodologia adotada nesta dissertação é composta por três fases. A primeira fase é dedicada à análise de documentos pertinentes ao tema da dissertação, ao levantamento geométrico da estrutura e à coleta de observações experimentais na estrutura em questão. A segunda fase concentra-se na modelação, envolvendo a construção de modelos numéricos e a definição de variáveis/parâmetros de ajuste para o estudo. Finalmente, a terceira fase é dedicada à classificação de novas observações, com base na aplicação dos dados experimentais e numéricos. Esta metodologia inclui as seguintes etapas:

- I. Levantamento de documentos e projetos referentes à passagem pedonal do Campo Grande, Lisboa;
- II. Estimar experimentalmente frequências naturais de vibração usando a App4SHM na passagem superior pedonal, que são utilizados para treinar os algoritmos de aprendizagem de máquina para a identificação de anomalias;
- III. Levantamento da geometria da estrutura por nuvem de pontos;
- IV. Modelação numérica da passagem superior recorrendo ao método de elementos finitos;
- V. Calibração do modelo numérico com o objetivo de aproximar a média das frequências naturais numéricas e experimentais (estrutural real);
- VI. Aplicação de técnicas não destrutivas (aglomeração de pessoas, por exemplo) para simulação de um estado limite de serviço (ELS);
- VII. Utilização do modelo numérico para simular a introdução de diferentes cenários de dano e rotular as observações em função dos estados operacionais nos quais as mesmas foram obtidas;
- VIII. Treino dos algoritmos de aprendizagem de máquina não supervisionada e supervisionada.
- IX. Quantificando a eficácia na deteção de anomalias, a precisão nas classificações, e a robustez diante de diferentes condições estruturais.

1.5 Estrutura do Trabalho

A presente dissertação está organizada em seis capítulos, cujos conteúdos são resumidos de seguida.

1 Introdução: a introdução destaca a importância da monitorização estrutural de pontes, especialmente no contexto de saúde estrutural, onde métodos avançados são essenciais para garantir a segurança e a integridade dessas infraestruturas. A justificativa do trabalho baseia-se na necessidade crescente de sistemas eficientes de monitorização, visando uma abordagem proativa na deteção de danos e preservação a longo prazo. Os objetivos do trabalho incluem o desenvolvimento e aplicação de métodos de monitorização, o enriquecimento das observações de monitorização através de modelos numéricos calibrados (abordagem híbrida), a identificação de danos estruturais e a avaliação do desempenho de algoritmos supervisionados e não supervisionados para a deteção de anomalias e classificação da condição estrutural.

2 Estado da Arte: oferece uma análise abrangente das pesquisas atuais relacionadas à monitorização estrutural e à avaliação de danos em pontes. Começando com considerações introdutórias, exploram-se os conceitos fundamentais de saúde estrutural de pontes, métodos de monitorização e avaliação de danos. Uma abordagem híbrida é discutida para melhorar a eficácia na deteção de danos, junto com a apresentação dos axiomas e tipos de danos estruturais. As técnicas de identificação de danos são detalhadas, seguidas pela análise das abordagens não supervisionada e supervisionada ao treino de algoritmos de aprendizagem de máquina. O texto também destaca a utilização inovadora de telemóveis na monitorização estrutural. Este capítulo proporciona uma visão abrangente do estado atual da pesquisa nesse campo crucial da engenharia civil.

3 Caso de Estudo e Sistema de Monitorização: apresenta uma investigação detalhada sobre o caso de estudo da Ponte Pedonal do Campo Grande, iniciando com uma descrição do caso e considerações iniciais. São discutidos as etapas de inspeção visual e o uso da aplicação App4SHM para a coleta de dados. Além disso, é abordado o levantamento por nuvem de pontos como uma técnica de medição eficaz. A modelação numérica é explorada em detalhes, incluindo a compatibilidade entre os programas utilizados, a criação do modelo numérico inicial e o procedimento de calibração para obter o modelo final. O capítulo encerra com considerações finais, sobre o desenvolvimento e implementação do sistema de monitorização para a Ponte Pedonal do Campo Grande.

4 Apresentação dos Resultados e Sua Discussão: o quarto capítulo está dividido em duas partes principais. A primeira parte foca-se na abordagem não supervisionada, exibindo e discutindo os resultados obtidos, e destacando conclusões relevantes. A segunda parte concentra-se na abordagem supervisionada, apresentando a seleção dos algoritmos, analisando os resultados alcançados e proporcionando uma análise comparativa do desempenho dos algoritmos escolhidos.

5 Conclusão: a conclusão resume o trabalho e discute as implicações e possíveis aplicações práticas dos resultados obtidos. Além disso, destaca as contribuições do trabalho para o campo de monitorização estrutural de pontes. No âmbito desta dissertação, identificamos oportunidades para futuras pesquisas. Este capítulo destaca também caminhos que podem contribuir significativamente para avanços práticos nos métodos de monitorização estrutural propostos.

CAPITULO 2 - Estado da Arte

2.1 Considerações iniciais

Este capítulo apresenta o estado da arte de diversos tópicos relacionados ao presente trabalho. Inicialmente, são explorados os conceitos fundamentais relacionados à saúde estrutural de pontes, abordando tanto o envelhecimento das mesmas quanto a necessidade contínua de avanços na monitorização estrutural e avaliação de danos. Uma visão da abordagem híbrida na monitorização, seus princípios e tipos de danos, é apresentada. A identificação de danos é discutida, abrangendo métodos não supervisionados e supervisionados. Além disso, são examinadas aplicações inovadoras de dispositivos móveis na monitorização estrutural, destacando a relevância crescente desses instrumentos na engenharia civil. Esse arcabouço teórico proporciona uma base sólida para as investigações e aplicações práticas abordadas ao longo deste estudo.

2.2 Conceitos de saúde estrutural de pontes

Os sistemas de monitorização estrutural em infraestruturas desempenham um papel importante na deteção de danos e na avaliação da saúde das pontes. Com a utilização de sensores e tecnologias de monitorização remota, é possível obter dados em tempo real sobre a condição estrutural das pontes, permitindo uma intervenção rápida e eficaz em caso de anomalias. Além disso, os sistemas podem abranger desde sensores tradicionais, como acelerómetros e extensómetros, até tecnologias mais avançadas, como redes de sensores sem fio e sistemas de visão computacional, proporcionando uma ampla gama de informações precisas e detalhadas (Tavares, 2021). Essas ferramentas são extremamente úteis na prevenção de acidentes e na redução dos custos de manutenção das infraestruturas. Elas permitem a deteção antecipada de qualquer sinal de deterioração ou desgaste, possibilitando intervenções preventivas antes que um problema se torne grave. Além disso, a monitorização constante ajuda a prolongar a vida útil das pontes, pois permite identificar áreas que exigem atenção especial e implementar medidas corretivas de forma oportuna. Em resumo, os sistemas de monitorização estrutural desempenham um papel fundamental na manutenção e segurança, com o uso de tecnologias avançadas, como sensores e sistemas remotos, é possível obter dados precisos e em tempo real sobre a integridade estrutural, permitindo uma intervenção rápida e eficaz.

O aumento do interesse na SHM em termos de pesquisa e implementação pode ser rastreado até os primeiros esforços da humanidade para conceituar, construir, considerar a deterioração e, posteriormente, buscar reparar ou prolongar a vida de estruturas (M. Karbhari & Ansari, 2009). Desde as antigas civilizações que utilizavam inspeções visuais rudimentares até o desenvolvimento de técnicas mais avançadas ao longo do tempo, como o uso de instrumentos de medição e testes de carga, a evolução da SHM reflete a constante busca por meios mais precisos de avaliar e manter a saúde das estruturas. Com os avanços tecnológicos das últimas décadas, a SHM incorporou a automação, a coleta de dados em tempo real, a análise computacional e a aplicação de MLA, resultando em abordagens mais completas para monitorizar e garantir a segurança das infraestruturas civis. Esse interesse surge em grande parte como resposta ao fato de que, com o passar do tempo, todas as estruturas inevitavelmente sofrem degradação. Torna-se crucial para os proprietários e operadores terem uma compreensão sólida da extensão dessa deterioração, seu impacto na vida útil e capacidade remanescente, permitindo assim tomadas de decisão informadas sobre a otimização dos reparos. Dessa forma, a SHM se torna uma tentativa de extrair conhecimento sobre a condição real de uma estrutura ou sistema, buscando perceber se o sistema pode ter-se deteriorado, avaliando os níveis de danos e vida útil restante.

Farrar e Worden (2013), destacam que a identificação de danos requer uma abordagem multidisciplinar, que permite uma análise mais abrangente e precisa dos danos em estruturas, permitindo a detecção precoce, a prevenção de falhas e a garantia da integridade estrutural. O termo SHM refere-se à estratégia para detecção de danos em infraestruturas. Essa estratégia envolve a observação contínua de uma estrutura ou sistema ao longo do tempo, com a realização de medições periódicas das respostas dinâmicas. A análise estatística dessas medições identifica características sensíveis a danos, fornecendo informações sobre o estado atual do sistema. Em monitorizações de longo prazo, essa abordagem oferece atualizações regulares sobre a capacidade da estrutura, levando em conta o envelhecimento e a degradação.

A Figura 2.1 apresenta uma visão geral do processo SHM. Inicialmente, é realizada a aquisição de dados, onde sensores, como acelerômetros e outros dispositivos, capturam informações dinâmicas da estrutura ao longo do tempo. Esses dados, após a coleta, são submetidos a uma fase de processamento, onde algoritmos especializados extraem as características sensíveis a danos. Os resultados dessa análise são então interpretados, proporcionando informações sobre a condição estrutural atual. Essas informações sustentam a tomada de decisão, influenciando escolhas críticas relacionadas à manutenção, reabilitação ou

eventual substituição de componentes. A eficácia dessa tomada de decisão direciona ações específicas para garantir a integridade estrutural a longo prazo, afetando diretamente a vida útil restante da estrutura. Esse ciclo contínuo de aquisição, processamento, análise, tomada de decisão e ação desempenha um papel essencial na preservação e segurança contínuas das infraestruturas.




Figura 2.1 Representação simplificada do processo SHM adaptada de (Neves, 2020)

Não obstante a inquestionável relevância do SHM e do significativo volume de pesquisas conduzidas nesse campo desde os anos 1970 (Cawley, 2018), persistem desafios substanciais que demandam resolução para viabilizar sua disseminação como uma ferramenta amplamente empregada no cenário atual.

A disparidade entre a abundante produção acadêmica e o número limitado de implementações práticas é um aspeto que merece atenção e reflexão. Essa discrepância levanta questionamentos sobre as possíveis razões por trás desse fenômeno e sobre os desafios que impediram a transição eficaz das pesquisas teóricas para a prática. À medida que esse campo evolui, é essencial investigar os fatores que contribuem para essa desproporção e identificar estratégias para superar as barreiras que têm dificultado a aplicação efetiva das descobertas científicas no âmbito experimental. A busca por uma melhor compreensão dessa discrepância aprimorará nossa visão sobre a dinâmica entre pesquisa acadêmica e aplicação

prática, fornecendo informações valiosas sobre as áreas que necessitam de uma abordagem mais holística, colaborativa e orientada a resultados.

2.3 Monitorização estrutural e avaliação de danos

Ao longo das últimas décadas, os países da União Europeia têm canalizado considerável esforço para a edificação de novas e modernas infraestruturas, por vezes, relegando a um plano secundário a supervisão constante das estruturas já estabelecidas. No entanto, essa orientação estratégica revelou uma realidade inegável: a premente carência de intervenções de manutenção nas estruturas já existentes. O resultado desse enfoque é a emergência de uma situação onde a importância de preservar e reabilitar as infraestruturas preexistentes se torna inquestionável (Figueiredo et al., 2013). A necessidade de equilibrar o investimento em novas construções com a atenção dedicada à sustentação das infraestruturas já em operação agora requer uma abordagem mais completa e equitativa.

Portugal é um país com aproximadamente 900 anos, portanto a necessidade da avaliação nacional das pontes tem sentido económico. Por outro lado, aplicar todas as manutenções necessárias nas pontes é desafiador pela grande variedade de soluções existentes e custo efetivo. As estruturas se comportam de formas distintas e individualizadas, como também sofrem danos de formas diferentes. O tempo afeta diretamente a qualidade da estrutura, pois a estrutura estará sujeita a mudanças não previstas em projeto, exemplos disto, o aumento constante das cargas aplicadas e a variação climática, entre outros fatores (Figueiredo et al., 2013).

A necessidade de desenvolver sistemas de monitorização da saúde estrutural tem como objetivo fundamental garantir o correto funcionamento da estrutura durante sua vida útil. Todas as solicitações presentes devem ser asseguradas pela estrutura, que por sua vez, está sujeita a danificações dos elementos estruturais. Estes danos ou falhas podem ser traduzidos em redução de rigidez que, por consequência, modifica os parâmetros modais, frequências próprias, modos de vibração e amortecimento (Guerreiro, 2014).

Atualmente, muitas estruturas estão se aproximando ou ultrapassando sua vida útil de projeto, mas ainda permanecem em operação por razões económicas. Nesse contexto, a avaliação da saúde estrutural torna-se crucial. O SHM desempenha um papel fundamental ao atenuar, de maneira mais suave, as perdas económicas associadas a uma estrutura, seja ela afetada por eventos extraordinários, como um terremoto, ou não, podendo essa avaliação

proporcionar uma compreensão mais aprofundada da capacidade física de recuperação da estrutura.

2.4 Princípios e tipos de dano estrutural

Os princípios fundamentais para SHM apresentados por Farrar & Worden (2013) destacam a extrema importância de técnicas avançadas de análise de dados e modelação para a monitorização eficaz e eficiente de estruturas. Esses princípios ressaltam de maneira contundente a necessidade de compreender todo o comportamento dinâmico das estruturas, incluindo a identificação de padrões anômalos ou atípicos que possam vir a surgir no decorrer da monitorização, a fim de garantir a segurança e a integridade das estruturas em questão. Ademais, é enfatizada a utilização de modelos preditivos altamente precisos e confiáveis que possam prever e antecipar possíveis danos e eventos indesejados, evitando assim qualquer tipo de acidente ou incidente que possa ocorrer. Nesse contexto, segundo Guerreiro (2014), nos últimos anos foram desenvolvidas numerosas novas técnicas de ensaios nas estruturas, tanto de carácter destrutivo, quanto não destrutivo. Técnicas não destrutivas são as mais recorrentes, tendo em consideração, a impossibilidade de danificar uma obra de arte existente para efeito didático.

A avaliação de danos demanda uma comparação entre dois estágios distintos do sistema, e cada análise ou campanha de SHM requer um ponto de referência inicial. A definição do conjunto de treino dependerá do nível de deteção de danos desejado, o que resultará na criação do conjunto de dados com base exclusivamente em condições normais ou a partir da combinação de estados normais e danificados da estrutura. As técnicas utilizadas para identificação de danos em estruturas incluem duas abordagens complementares: a abordagem inversa e a abordagem de reconhecimento de padrões. A abordagem inversa consiste em ajustar um modelo numérico inicial da estrutura através de dados medidos na estrutura real (Friswell, 2007), sendo um método que procura entender as relações de causa e efeito em um sistema complexo, retrocedendo do resultado observado para identificar as variáveis ou parâmetros que o determinaram. É frequentemente utilizada em problemas nos quais o objetivo é determinar as condições ou características que levaram a uma determinada observação.

Já a abordagem de reconhecimento de padrões enfatiza a identificação de regularidades ou padrões significativos nos dados já coletados que caracterizam determinadas condições estruturais, utilizáveis para reconhecer essas mesmas condições estruturais em novos

dados (Webb, 2002). Portanto, essa metodologia utiliza MLA e técnicas estatísticas para analisar e classificar novos dados com base em características identificáveis nos dados pré-existent. É amplamente aplicada em campos como inteligência artificial, processamento de imagem, e até mesmo em diagnósticos médicos, onde a capacidade de identificar padrões complexos é essencial.

A abordagem híbrida no MLA está na combinação destas duas abordagens para obter melhores resultados na monitorização da saúde estrutural, onde a abordagem inversa é valiosa quando se busca diagnosticar um dano conhecido, enquanto a abordagem de reconhecimento de padrões destaca-se na identificação de comportamentos irregulares com base em dados estruturais recolhidos na estrutura não danificada. Combinar essas técnicas permite aproveitar as vantagens de ambas, a qual remete uma precisão ainda maior na deteção de dados anormais, e, sobretudo, a caracterização desses dados atípicos. Além disso, a utilização de métodos híbridos também contribui para lidar de maneira eficiente com a complexidade dos dados estruturais, maximizando assim a eficácia dos modelos desenvolvidos. Isso torna os modelos mais robustos e confiáveis para a análise de longo prazo, o que é essencial para uma monitorização precisa e contínua.

É possível definir três principais tipologias de danos estruturais: defeito, dano e falha. Todos os materiais têm microestruturas diferentes, inclusões, vazios e outros defeitos. Defeitos inerentes ao material não são considerados como danos, pois não afetam a eficiência estrutural global. Em caso de cargas de serviço, fenómenos como fadiga, corrosão, eventos extraordinários, entre outros, estes sim são considerados danos, pois evoluíram sobre a microestrutura dos materiais. No âmbito estrutural associa-se os danos às mudanças que ocorrem no material, como fissuras, plasticidade etc. Neste caso, a estrutura sofre mudanças em seu comportamento, mas pode continuar a funcionar de maneira satisfatória, onde é possível definir a falha pela evolução do dano, no qual atinge um estado limite não aceitável para uso Doebeling et al. (1996).

Portanto, é possível concluir que a integridade estrutural é avaliada com base na comparação entre dois estados diferentes do sistema, nomeadamente o estado inicial regular, não danificado, e um estado estrutural desconhecido, que precisa de ser caracterizado.

2.5 Identificação de danos

A avaliação de danos em sistemas estruturais compreende, principalmente, a deteção inicial de potenciais irregularidades, seguida pela determinação precisa de sua posição,

natureza e severidade. Seguindo a perspetiva apresentada por Rytter (1993); Worden & Dulieu-Barton (2004), um sistema de SHM eficiente é caracterizado pela integração dos níveis de identificação de danos ilustrados na Figura 2.2.




Figura 2.2 Níveis para identificação de danos (adaptada de Figueiredo, 2010)

A etapa inaugural da metodologia, como delineado na Figura 2.2, incide sobre estabelecer a presença de danos na estrutura. Nesse estágio inicial, o objetivo primário é responder à questão central: a estrutura em análise apresenta algum tipo de dano? Este nível fornece uma visão inicial e básica, lançando as bases para investigações mais aprofundadas nos estágios subsequentes de identificação estrutural. A deteção eficaz nessa fase é crucial para orientar as análises posteriores, direcionando a atenção para áreas específicas da estrutura que requerem investigação mais detalhada nos níveis subsequentes de localização, tipologia, intensidade e prognóstico de danos. Próximo nível tem como objetivo identificar a localização onde os danos estão possivelmente presentes na estrutura. Essa etapa aprimora significativamente a nossa compreensão, permitindo uma intervenção mais focada e eficiente. Vale ressaltar que essa etapa não busca definir com exatidão a posição do dano, mas sim estabelecê-la de maneira aproximada. Ao atingir o nível de tipologia, avançamos na compreensão dos danos para identificar não apenas a sua presença e localização, mas também a natureza específica ou tipologia desses danos. Essa fase destaca a diversidade nos tipos de danos, como fissuras, deformações, corrosão, entre outros. A capacidade de discernir a

tipologia dos danos é vital para desenvolver estratégias de reparo ou reforço mais precisas e eficazes. Ao compreender a natureza específica dos danos, tornamo-nos mais aptos a selecionar abordagens de intervenção adaptadas, otimizando recursos e garantindo uma resposta mais direcionada e eficiente às necessidades estruturais. Avançando para o nível de intensidade, a análise agora se aprofunda na avaliação da magnitude ou extensão dos danos identificados. Isso implica quantificar o grau de deterioração ou comprometimento da estrutura. A intensidade pode ser expressa em termos de extensão física, como a área afetada, ou em termos de impacto na capacidade estrutural. Compreender a intensidade dos danos é crucial para determinar a urgência e a natureza das intervenções necessárias. No nível de prognóstico, alcançamos o mais alto grau de análise com objetivo de antecipar o comportamento futuro da estrutura. Este nível envolve prever o desenvolvimento dos danos ao longo do tempo, considerando fatores como condições ambientais, carga de serviço contínua e possíveis eventos extremos. O prognóstico oferece uma visão prospetiva, permitindo planejar estratégias de manutenção a longo prazo e otimizar os recursos. Isso transcende a simples deteção e reparo, oferecendo uma abordagem proativa para garantir a durabilidade e segurança contínua da estrutura ao longo de sua vida útil.

A conceção subjacente a essa estrutura hierárquica reside na premissa de que, à medida que a avaliação avança em níveis mais detalhados, o SHM oferecerá um conjunto cada vez mais abrangente de informações referentes à condição estrutural. Entretanto, essa abordagem também acarreta desafios, implicando uma complexidade crescente na obtenção das informações, uma vez que cada nível subsequente de avaliação requer um entendimento fundamentado nos níveis anteriores, (Rytter, 1993). Por isso, os níveis apresentam uma estrutura piramidal, necessitando das informações dos níveis anteriores. Por conseguinte, os distintos estágios de identificação de danos apresentam demandas variadas em relação a fatores como os tipos de sensores empregados, os algoritmos utilizados para deteção e diagnóstico de danos, bem como o número de parâmetros do modelo considerados (Neves, 2020). Sem um modelo físico, a obtenção de informações além do segundo nível na hierarquia de deteção de danos geralmente se mostra impraticável. No entanto, o primeiro nível de identificação de danos frequentemente é útil o bastante, servindo como um sinal para a realização de inspeções subsequentes. Isso significa que as técnicas usadas neste primeiro nível darão indicações de uma probabilidade significativa de danos, mas a confirmação dessa suposição e a identificação precisa da localização e intensidade do dano só podem ser obtidas por meio de uma investigação mais aprofundada. A abordagem híbrida é essencial para o

progresso eficaz nos diferentes níveis, permitindo tirar proveito das forças complementares de cada técnica. Afkham, (2021) validou a eficiência dessa abordagem, utilizando uma rede neural profunda para regularizar parâmetros de problemas inversos, ressaltando que os cálculos foram mais eficientes e as soluções mais precisas comparadas aos métodos tradicionais.

Danos em uma estrutura podem ser identificados através de testes dinâmicos, revelados de eventuais modificações dos modos de vibração ou frequências, causadas pela presença de danos. As alterações dos modos provocadas pelo dano podem não ser iguais para os diferentes modos, isso porque estas alterações dependem de três fatores: a natureza do dano, localização e a gravidade (Salawu, 1997).

Conforme citado por Credo (1987), um dano devia modificar as frequências em, no mínimo, 5% para que possa ser detetado de maneira evidente. É importante mencionar que, mudanças nos modos de vibração por si só não necessariamente significam danos, sendo que fatores externos podem causar variações. No entanto, é importante realizar uma análise detalhada para determinar a causa das alterações e avaliar se há algum potencial de dano. Isso pode incluir a realização de medições precisas, análises estatísticas e inspeções visuais. Se for identificado algum dano, medidas devem ser tomadas para corrigi-lo antes que possa causar problemas maiores. Uma ferramenta importante para a identificação de danos é recorrer à utilização de modelos de elementos finitos, desde que, suficientemente capazes de identificar alterações em estrutura reais (Doebeling et al., 1996).

2.6 Abordagem híbrida na monitorização

As abordagens híbridas no treino de MLA combinam técnicas de aprendizagem supervisionada e não supervisionada para obter melhores resultados na monitorização da saúde estrutural. Essa combinação permite aproveitar as vantagens de ambos os tipos de algoritmos, melhorando a precisão na deteção de anomalias e na previsão de possíveis falhas (Morais, 2020).

Na deteção de danos estruturais, é comum empregar MLA para identificar desvios estatisticamente significativos nos valores originais. Esses desvios são conhecidos como indicadores de danos e desempenham o papel crucial de refletir a probabilidade de ocorrência de danos na estrutura. A análise estatística desses indicadores proporciona informações valiosas sobre potenciais problemas estruturais, permitindo intervenções proativas e estratégias de manutenção eficazes. Entretanto, além dos danos, a variabilidade ambiental e

operacional também pode causar alterações estatisticamente significativas nas características das estruturas, podendo resultar em falsos positivos e, ainda mais sério, falsos negativos, que são danos possivelmente em fases iniciais confundidos com dados normais ou sobrecarga (Bud et al., 2022). Para evitar esses problemas, modelos de elementos finitos são usados para gerar observações correspondentes a eventos ambientais e operacionais extremos, bem como simular a resposta da estrutura com diferentes danos típicos (Figura 2.3).




Figura 2.3 Fluxograma da abordagem híbrida adaptado de (Bud et al., 2022)

A criação da base de dados híbrida inicia-se com a campanha de monitorização da estrutura alvo. Características sensíveis ao dano são extraídas dos dados brutos, geralmente relacionados à resposta dinâmica (frequências e formas modais). Em seguida, um modelo de elemento finito é construído com base nos projetos estruturais. Tipicamente, o modelo de elementos finitos é construído favorecendo a simplicidade e a eficiência computacional, já que um número alto de modelos de elementos finitos terão de ser corridos para lidar com

variações probabilísticas dos parâmetros incertos devido à sua natureza aleatória e variável ao longo do tempo. O modelo inicial deve ser calibrado para recuperar com precisão a resposta da estrutura, garantindo que as características de vibração e outras componentes observadas na estrutura real sejam reproduzidas de forma fiável. Para a calibração pode-se considerar parâmetros incertos como rigidez do solo, os elementos estruturais e suas dimensões, como comprimento, largura e altura, ajustando-os de forma a melhor se adequarem aos dados experimentais e melhorar a precisão do modelo.

O modelo calibrado é chamado de modelo de referência. Posteriormente, esse modelo é usado para gerar modelos descendentes com distribuições estatísticas desenhadas para cada parâmetro incerto e modelando condições estruturais específicas, como por exemplo acréscimo de massa, simulação de danos, entre outras situações possíveis. São gerados assim conjuntos de observações numéricas, para diferentes condições a que a estrutura esteja sujeita, aos quais se acrescentam os respetivos rótulos. De seguida, a base de dados é otimizada para equilibrar o número de leituras em diversas condições estruturais, evitando disparidades de observações entre as mesmas, para servir como fundamento para o treino de MLA, que pode incorporar medições experimentais, observações provenientes dos resultados de simulações numéricas, rotuladas ou não rotuladas.

Ainda não há consenso sobre a quantidade ideal de observações para garantir que a base de dados resultante seja equilibrado. Pesquisas anteriores, como a de Bud (2022), destacam a importância de se atentar para esse aspeto, pois conjuntos de dados desequilibrados podem comprometer a precisão dos modelos estatísticos de “*clustering*”, levando a classificações errôneas. Portanto é fundamental estabelecer uma homogeneidade na quantidade de observações para garantir a confiança dos dados.

Finalmente, as bases de dados provenientes de simulações numéricas e de monitorização experimental são combinadas para treinar MLA nos regimes não supervisionado e supervisionado, conforme detalhado na seção seguinte.

2.7 Abordagens de aprendizagem não supervisionado e supervisionado

Os termos de aprendizagem não supervisionado e supervisionado se referem a duas abordagens fundamentais no treino de algoritmos de aprendizagem de máquina (Figura 2.4). Estas categorias diferem na maneira como os dados são apresentados e utilizados durante o processo de treino.




Figura 2.4 Representação esquemática dos tipos de aprendizagem e dos respetivos algoritmos de interpretação

No regime não supervisionado, apenas os dados das condições não danificadas são fornecidos ao algoritmo, e esses dados não são rotulados. Nessa abordagem, o objetivo principal é que o algoritmo aprenda apenas o comportamento normal da estrutura. Assim o algoritmo estabelece inicialmente uma condição de referência da estrutura com base em características apropriadas extraídas dos dados da estrutura não danificada, em regime normal de funcionamento. Posteriormente, por meio de um processo de reconhecimento estatístico de padrões, as características extraídas de dados novos, não incluídos na base de treino, são comparadas com as observadas na condição de referência. Se houver desvios significativos, indica-se que a estrutura saiu da sua condição de referência, podendo sugerir possível dano. No entanto, não é certo que a observação fora da zona de referência corresponde a dano, podendo ser, também, consequência de condições ambientais ou operacionais menos usadas. Algoritmos comuns nesta categoria incluem *k-means clustering*, modelos de mistura gaussiana, análise de componentes principais, entre outros (Neves, 2020).

Por outro lado, no regime supervisionado, tanto dados das condições não danificadas (referência) quanto dados das condições danificadas (novas) da estrutura são fornecidos ao algoritmo. Esses dados são rotulados de acordo com a condição da estrutura à qual pertencem, permitindo a construção de um modelo preditivo capaz de reconhecer e rotular novos dados. Essa abordagem é útil quando há conhecimento prévio sobre possíveis cenários de danos, possibilitando a realização de classificação da condição estrutural (para tipologia de dano) e análise de regressão (para a intensidade do dano). Algoritmos comuns nesta categoria incluem *Support Vector Machines (SVM)*, *Naive Bayes Classifier (NB)*, *K-Nearest Neighbour (KNN)*,

Quadratic Discriminant (QD), Decision Trees (DT), Ensemble Classification (ENS), Artificial Neural Network (ANN).

Em resumo, a Figura 2.4 representa o caminho de ambas as abordagens. Enquanto o regime não supervisionado apenas agrupa os dados e apresenta o resultado como dentro ou fora do normal, o regime supervisionado baseia-se em dados já classificados, o que permite ao algoritmo desenvolver uma função com alta precisão preditiva. Ainda no âmbito supervisionado, dois conceitos fundamentais são a classificação e a regressão. A classificação é um processo no qual o algoritmo é treinado para categorizar dados em diferentes classes ou categorias. No contexto da monitorização estrutural, isso pode ser aplicado para identificar diferentes estados de uma estrutura, como por exemplo "danificado" ou "intacto" no caso do regime não supervisionado, ou incluindo tipologias de danos, no caso do regime supervisionado, que são alimentados com um conjunto de dados rotulado, onde cada possui uma categoria associada. O objetivo é que, após o treino, o modelo consiga classificar novos dados em uma dessas categorias com base nos padrões aprendidos durante o treino. Por outro lado, a regressão é utilizada quando o objetivo é prever um valor contínuo em vez de categorias discretas. Em monitorização estrutural, isso poderia envolver a estimativa de parâmetros como a extensão do dano ou a degradação da rigidez. Similar à classificação, a regressão requer um conjunto de dados rotulado, mas os rótulos agora representam valores contínuos.

2.8 Utilização de telemóveis na SHM

A tendência da digitalização tem impulsionado o uso de telemóveis para a monitorização estrutural de pontes devido à sua ampla disponibilidade e baixo custo. Os telemóveis possuem sensores integrados, recursos de armazenamento, processadores e conectividade, como rede celular 4G/5G, Wi-Fi e Bluetooth. Os sensores incluem acelerómetros, câmeras, microfones, giroscópios, magnetómetros e GPS (Figueiredo et al., 2022). O uso dessa tecnologia é relevante, pois permite que os telemóveis sejam utilizados como sistemas de monitorização estrutural nas inspeções de pontes. Segundo Malekloo et al. (2022) fornecem uma visão geral da tecnologia de sensores relacionada ao telemóvel e sua aplicação.

A tecnologia de câmara do telemóvel também pode ser utilizada para a medição de ângulos e deslocamentos relativos, através de técnicas de análise de imagem, e algoritmos de reconhecimento de padrões (Kromanis et al., 2019; Senatov et al., 2016). Essas técnicas

permitem a obtenção de informações precisas e confiáveis sobre a estrutura alvo, que podem ser utilizadas para avaliar o seu estado de saúde e garantir a segurança de seus usuários. Além disso, o uso de telemóveis para SHM também permite o diagnóstico do estado estrutural em tempo real, estimando as frequências naturais de vibração, o que é particularmente útil em caso de emergências ou situações críticas.

Zhao et al. (2015) demonstraram a capacidade dos telemóveis em medir as forças internas de cabos tanto em condições laboratoriais quanto na Ponte da Baía de Xinghai na China. Outra pesquisa conduzida por Zhao et al. (2016), investigou a viabilidade do uso de telemóveis para avaliação de danos em pontes. O estudo envolveu uma ponte suspensa a escala laboratorial, focando na análise do comportamento do tabuleiro e dos cabos. Destaca-se que as medições realizadas pelos telemóveis apresentaram consistência notável comparada aos acelerômetros de referência, na qual a frequência natural fundamental do modelo da ponte foi estimada com um erro máximo de 0,44%. Pesquisas iniciais, incluindo Figueiredo et al. (2023), avaliaram a precisão e capacidade de resolução das medições de vibração feitas com telemóvel, concluindo que essas medições são confiáveis na faixa de frequência relevante para pontes, geralmente abaixo de 20 Hz. Isso sugere que os telemóveis podem ser usados como uma ferramenta útil e acessível para monitorizar a segurança de pontes.

Os estudos apontam para a precisão crescente dos acelerômetros embutidos em telemóveis de nova geração em comparação com os das gerações anteriores, indicando uma evolução rápida nesta tecnologia. Outras vantagens observadas incluem facilidade da utilização do telemóvel na ponte, aquisição de dados e transmissão sem fio (Feng et al., 2015).

A aplicação App4SHM, desenvolvida pelo Grupo de Investigação na Engenharia Civil e o Departamento de Informática da Universidade Lusófona em Portugal, destaca-se pela sua aplicabilidade na monitorização periódica de pontes sob diversas condições operacionais e ambientais. Sua versatilidade permite a realização de SHM através de ensaios não destrutivos durante inspeções programadas. A aplicação emprega modelos não supervisionados de MLA, detetando se novas observações são estatisticamente consistentes ou não com as medições efetuadas na fase de treino. No entanto, a aplicação limita-se a detetar medições inconsistentes com o estado normal da estrutura, que podem ou não corresponder a dano, e não tem capacidade de diagnóstico de dano (Figueiredo et al., 2022).

Uma tendência atual são as aplicações de *crowdsourcing*, como por exemplo a aplicação *Citizen Sensors for SHM* (CS4SHM). Esta aplicação foi criada para permitir que os cidadãos utilizem os acelerômetros embutidos em seus iPhones para medir a vibração e enviar

esses dados para um servidor na internet por meio de uma conexão de rede celular ou WiFi (Ozer et al., 2015). Isso pode ser feito através da aplicação específica que permite a coleta e o envio dos dados de vibração, possibilitando a monitorização e avaliação contínua da segurança das estruturas. CS4SHM coleta medições de pontes flexíveis e identifica a frequência fundamental como sendo a primeira grande amplitude espectral comum à maioria das séries temporais de aceleração. Diferentemente da App4SHM, o CS4SHM foi construído especificamente para sistemas IOS e não inclui uma funcionalidade de deteção de danos. Por outro lado, App4SHM foi projetado para não automatizar o processo de extração de frequências da densidade espectral de potência, pois segue uma política de manter a ferramenta como um instrumento profissional e não como uma ferramenta de *crowdsourcing*. Com efeito módulo de deteção de danos integrado na App4SHM, pode gerar inquietação para usuários não familiarizados com o conceito de similaridade estatística, que poderão ter dificuldade em distinguir observações discrepante fortuitos de dano estrutural (Figueiredo et al., 2023).

2.9 Considerações finais

O estado da arte apresentou uma visão sobre SHM, abordando conceitos fundamentais, métodos de identificação de danos e avanços tecnológicos. Destacaram-se os benefícios dos sistemas de monitorização na prevenção de falhas e prolongamento da vida útil das estruturas, com ênfase no uso de abordagens híbridas que combinam observações experimentais e numéricas para maior precisão na deteção de anomalias. A utilização de telemóveis como sensores foi ressaltada como uma solução de baixo custo e alta eficácia, complementando técnicas tradicionais. Apesar de desafios como a variabilidade ambiental e a necessidade de bases de dados equilibradas, o capítulo evidenciou o papel transformador das tecnologias modernas e métodos inovadores na gestão e manutenção de infraestruturas, contribuindo para sua segurança e sustentabilidade.

É importante destacar que, além da monitorização dinâmica empregada neste estudo, reconhecida pela análise de vibrações e pela identificação de danos estruturais, existem outras abordagens complementares que podem enriquecer a avaliação da integridade de pontes. Entre elas, a monitorização estática é um exemplo, amplamente utilizada para medir deslocamentos e deformações.

CAPITULO 3 - Caso de estudo e sistema de monitorização

3.1 Considerações iniciais

A investigação detalhada da passagem pedonal do Campo Grande será apresentada nessa seção, começando com uma descrição técnica do caso de estudo. Será apresentada a metodologia empregada na inspeção visual e no levantamento geométrico utilizando a nuvem de pontos, essencial para obter uma representação tridimensional precisa da estrutura e validar os parâmetros geométricos para a modelação numérica. Além disso, será destacado o uso do telemóvel como uma ferramenta acessível e eficiente na coleta de dados, incluindo a aplicação App4SHM para medições práticas e rápidas em condições normais da ponte pedonal e a realização da captura de nuvens de pontos utilizando a tecnologia LIDAR. A formulação e calibração do modelo numérico da passagem pedonal receberão atenção especial, garantindo que o comportamento da estrutura seja adequadamente representado para as análises subsequentes. Assim, a seção fornecerá a base sólida para uma análise aprofundada e confiável da integridade estrutural e funcionalidade da ponte.

3.2 Passagem pedonal do Campo Grande

Para desenvolvimento deste estudo recorreu-se à passagem pedonal localizada no Campo Grande, Lisboa (ver Figura 3.1). De acordo com Gammaconsult, (2000), a passagem pedonal é caracterizada pela técnica de betão pré-fabricado, constituída por duas vigas em betão armado pré-esforçado com seção I e altura de 1,23 m, vencendo um vão de 25,6 m, apoiada em aparelhos de apoio do tipo neoprene armado, que transmitem as ações aos pilares de seção variável em altura de 1,40 x 0,45 m na base até 0,70 x 0,45 m junto ao cabeçote para receber as vigas. O tabuleiro é composto por lajes em betão armado com 0,13 m de espessura que apoiam no banzo inferior das vigas. A passagem possui escadas que apresentam um vão de 3,41 m em projeção horizontal, com uma inclinação de 30°.



Figura 3.1 Localização passagem pedonal (Google, 2005)

A observação da estrutura (Figura 3.2) foi realizada através de diversas técnicas de análise e de monitorização, incluindo inspeção visual, levantamento de nuvem de pontos, desenvolvimento de modelos numéricos e ensaios dinâmicos utilizando a App4SHM. A combinação dessas técnicas permitiu uma observação mais abrangente, detalhada e precisa da estrutura.



Figura 3.2 Passagem pedonal do Campo Grande

A inspeção visual permite identificar se há a presença danos visíveis na estrutura, bem como constatar a conformidade com o projeto. O levantamento de nuvem de pontos permitiu fazer uma identificação geométrica efetiva de todos os elementos estruturais. A modelação estrutural foi desenvolvida para simular respostas estruturais. Os ensaios dinâmicos foram realizados utilizando um telemóvel com a aplicação App4SHM como aparelho de medição e análise da resposta estrutural. Esta aplicação permite obter uma estimativa das primeiras três frequências naturais de vibração da estrutura, que são utilizadas como características sensíveis a dano no resto do estudo.

3.3 Inspeção visual

Conduzida de maneira meticulosa, a inspeção visual visa avaliar a condição estrutural da passagem pedonal. O processo envolveu diversas etapas para assegurar uma análise mais abrangente. Inicialmente, foram compilados documentos pertinentes, incluindo projetos estruturais e relatórios de inspeções anteriores (Figura 3.3). Além disso, identificaram locais críticos, como os pilares de sustentação, vigas principais e pontos de ligação entre elementos estruturais, devido à sua importância para a integridade e estabilidade da estrutura, para garantir uma cobertura completa durante a inspeção.




Figura 3.3 Desenhos extraídos do projeto estrutural

A inspeção visual concentrou-se em componentes estruturais cruciais, como vigas, pilares e lajes, buscando atentamente por sinais visíveis de danos, como trincas, corrosão ou deformações. Vale destacar que, no término da inspeção, não foram identificados elementos

que pudessem comprometer a eficácia do estudo. Este resultado inicial permitiu concluir que a passagem pedonal se encontra, aparentemente, em condições estruturais intactas. Essa avaliação positiva é essencial para embasar futuras análises.

Adicionalmente, foi também observado que alguns elementos estruturais têm dimensões não condizentes com as previstas em projeto, nomeadamente ao nível da espessura das lajes. No relatório gerado por Gammaconsult (2000), especificou apenas uma espessura de laje como 0,13 m. Entretanto adiante fica comprovado através da nuvem de pontos que existem valores variáveis, tendo as lajes dos tabuleiros centrais com 0,13 m e a laje dos tabuleiros apoiados nos pilares mais a consola com 0,29 m.

3.4 Levantamento por nuvem de pontos

As nuvens de pontos tridimensionais (*3D point cloud*) são conjuntos volumosos de dados que representam, de maneira minuciosa, a superfície tridimensional de objetos ou ambientes físicos. Obtidas através de tecnologias como LiDAR (*Light Detection and Ranging*), essas nuvens consistem numa extensa coleção de coordenadas tridimensionais, cada ponto carregando consigo informações detalhadas sobre sua posição espacial. Essa tecnologia é notável pela sua aplicabilidade diversificada, abrangendo desde a engenharia e arquitetura até a robótica e a visão computacional.

As nuvens de pontos têm impulsionado a inovação e a compreensão detalhada de espaços tridimensionais, podendo assim obter a sua geometria (Ballesteros et al., 2015). Essas nuvens de pontos são cruciais em projetos de mapeamento tridimensional, reconstrução de ambientes, monitorização de estruturas e planeamento urbano. Sua utilidade reside na habilidade de proporcionar uma representação digital fiel do mundo físico, permitindo análises avançadas, como identificação de padrões, deteção de mudanças ao longo do tempo e a criação de modelos tridimensionais precisos.

De maneira a fazer um levantamento preciso das dimensões dos elementos estruturais da ponte pedonal, no dia 20 de março de 2023 foi realizado um levantamento por nuvem de pontos (Figura 3.4), utilizando o equipamento Leica RTC 360 PLUS, promovendo uma abordagem mais inteligente, resultados mais precisos, visualização detalhada e colaboração eficiente. A aplicação da técnica de nuvens de pontos emerge como um diferencial significativo na otimização geométrica de modelos numéricos de elementos finitos. Destacando-se por uma notável taxa de erro de apenas 10^{-2} metros, esta abordagem foi instrumental para aprimorar os modelos numéricos. O emprego da nuvem de pontos

desempenhou um papel crucial ao verificar e corrigir os dados previamente apresentados no memorial descritivo. Vale ressaltar que, anteriormente, a coleta de dados havia dependido de técnicas de medição estrutural direta de forma manual, suscetíveis a variações. Esta transição para uma metodologia mais precisa e automatizada confere maior fiabilidade e acurácia ao modelo numérico, marcando um avanço tecnológico significativo na análise estrutural (Figura 3.5 e Figura 3.6).



a) Imagem captada pelo laser



b) Nuvem de pontos gerada

Figura 3.4 Levantamento por nuvem de pontos da passagem pedonal do Campo Grande




Figura 3.5 Visualização da nuvem de pontos





Figura 3.6 Vista isométrica da passagem pedonal através da nuvem de pontos


Note-se que o uso de equipamentos profissionais garante uma precisão e qualidade elevadas dos dados coletados. No entanto, esses equipamentos dependem de operadores qualificados para o seu manuseamento.

O programa Autodesk Revit assume um papel de destaque na condução da análise dimensional a partir de nuvens de pontos, estabelecendo-se como uma ferramenta catalisadora na modelação geométrica tridimensional para os desafios atuais da engenharia. Ao interagir harmoniosamente com nuvens de pontos, o Revit não se limita a uma mera extração dimensional; ele oferece a capacidade de interpretar e contextualizar essas dimensões podendo inclusive identificar fissuras, proporcionando uma compreensão mais profunda das complexidades estruturais. Por permitir a captura rápida e precisa das dimensões e geometria da estrutura, essa integração eficiente acelera significativamente o processo de medição (ver Figura 3.7).


A extração de dimensões pelo Revit otimiza a precisão dimensional, contribuindo para a fidedignidade da representação do ambiente físico analisado. Essa simbiose entre o software de modelação e as tecnologias avançadas de captação de dados revela-se como um marco significativo, na eficiência operacional. O Revit, ao desempenhar esse papel, simplifica processos, e também redefine a abordagem para a análise dimensional, conferindo à engenharia uma ferramenta formidável para enfrentar os desafios contemporâneos de forma eficaz.




a) Nuvem de pontos



b) Corte para retirar seção do pilar



c) Corte para retirar seção da escada



d) Corte longitudinal

Figura 3.7 Análise da nuvem de pontos no programa Revit

A execução da nuvem de pontos desencadeou um processo de elaboração da maquete 3D da passagem pedonal como apresentado na Figura 3.8. Esta abordagem técnica conferiu a capacidade de análise das dimensões dos elementos estruturais preponderantes, notadamente vigas, pilares e tabuleiros. Consequentemente, tal estratégia revelou-se importante para a

realização de ajuste e simplificação nas dimensões, contribuindo para a precisão do modelo tridimensional resultante.





Figura 3.8 Maquete da passagem pedonal

Desta maneira, a nuvem de pontos se estabeleceu como a principal referência para a conceção do modelo numérico preliminar.

Entretanto, o telemóvel também pode ser utilizado nesse contexto para gerar a nuvem de pontos, tendo em vista que possui tecnologia LiDAR. Esta tecnologia dos telemóveis permite a emissão de pulsos de luz que, ao refletirem nas superfícies, retornam ao sensor, gerando um mapa tridimensional do ambiente (Figura 3.9). Assim, em forma de comparação, foi utilizado o aparelho iPhone 12 Pro Max. Essa capacidade, anteriormente restrita a equipamentos profissionais, agora está ao alcance das mãos de qualquer pessoa, democratizando e possibilitando novas formas de monitorização. A portabilidade e facilidade de uso dos telemóveis, permitem que pesquisadores e profissionais (ex. inspetores de pontes) possam realizar levantamentos de campo de maneira rápida e eficiente, sem a necessidade de transportar e montar equipamentos pesados e complexos. Essa abordagem inovadora simplifica o processo de coleta de dados, trazendo assim a redução de custos e tempo de operação.



a) visualização da captura



b) medição destacada em azul

Figura 3.9 Captura nuvem de pontos utilizando telemóvel

A título de exemplo a Figura 3.9 apresenta o levantamento por nuvem de pontos do pilar da passagem pedonal utilizando a aplicação 3D Scanner App. Para efeitos de comparação, o levantamento realizado com a nuvem de pontos profissional indicou uma

altura de 5,84 metros. Já a nuvem de pontos gerada com o celular, sem qualquer refinamento posterior em computador e utilizando apenas o dispositivo móvel, forneceu uma altura de 5,80 metros.

3.5 Aquisição de dados com App4SHM

A App4SHM é uma aplicação que utiliza o acelerómetro interno do telemóvel para medir acelerações, estimar frequências naturais e compará-las com um conjunto de dados de referência utilizado para treinar MLA na deteção de danos. App4SHM permite a deteção da condição estrutural quase em tempo real, levando poucos minutos para aquisição de dados, processamento e deteção de dano. Além disso, a App4SHM tem acesso a um servidor para executar operações computacionais e armazenar alguns conjuntos de dados.

A arquitetura computacional da App4SHM está representada esquematicamente na Figura 3.10.




Figura 3.10 Arquitetura da App4SHM (Figueiredo et al., 2022)

A aplicação é composta por dois componentes de software: uma aplicação móvel e uma plataforma computacional hospedada por um servidor remoto. A aplicação móvel foi

desenvolvida utilizando a linguagem *Dart* a qual é compatível com dispositivos que possuem o sistema operacional Android 10 ou superior e iOS. Ela possui uma navegação com quatro abas, correspondentes às quatro etapas do processo de monitorização (Figueiredo, et al., 2022), que se apresentam de seguida.

- Etapa 1: Identificação da estrutura - A primeira etapa consiste em identificar a estrutura a ser monitorizada. Isso é feito selecionando a estrutura desejada de uma base de dados pré-existente (Figura 3.11). Além disso, é possível adicionar novas estruturas à base de dados através do servidor.




Figura 3.11 Identificação da estrutura

- Etapa 2: Aquisição de dados - Nesta etapa é realizada a medição da série temporal de aceleração por um período especificado pelo usuário (ver Figura 3.12). A taxa de amostragem dos acelerômetros instalados em telemóveis está fixada em torno de 50 Hz, com pequenas variações em torno deste valor. Para compensar os erros de frequência de amostragem, as séries temporais são interpoladas de modo que o espaçamento entre dois dados consecutivos seja precisamente 0,02 segundos.




Figura 3.12 Medição da série temporal de aceleração

- Etapa 3: Extração de características - Nesta etapa é feita a extração manual de características importantes, a partir de um espectro de potência obtido através do método de Welch sobre os dados coletados anteriormente, nomeadamente as primeiras três primeiras frequências naturais de vibração (Figura 3.13). Essas características são armazenadas em um vetor (observação) para uso posterior.

Mais informações:

- A seleção das frequências requer conhecimento prévio da ordem de grandeza das mesmas por parte do operador, que pode ser adquirido com base em medições anteriores (a interface apresenta as médias das mesmas), ou a partir de um modelo numérico da estrutura;
- A interface apresenta ainda o desvio da medição corrente face à média das medições anteriores;
- A interface permite *zoom/pan*, e pode apresentar os espectros em escala normal ou logarítmica.




Figura 3.13 Extração das frequências naturais de vibração

- Etapa 4: Detecção de dano - Nessa etapa é realizada a detecção de dano na estrutura. Para cada nova observação, um indicador de dano é estimado. Em seguida, é apresentado um gráfico dos indicadores de dano das observações coletadas na base de dados de treino bem como do da nova observação. O indicador de dano calculado para a nova observação é adicionado ao gráfico com uma cor verde se a estrutura for considerada não danificada ou vermelha se a estrutura for considerada danificada, como mostra a Figura 3.14.

A interface apenas se ativa no modo de detecção de dano se houver observações da condição não danificada que permitam o treino do MLA. O indicador de dano é baseado na métrica estatística da distância de Mahalanobis, que avalia a distância entre um ponto (nova observação) e o conjunto de observações consideradas normais.





Figura 3.14 Gráficos de identificadores de dano

A plataforma em análise integra uma interface web acessível através de navegadores convencionais, conforme representado na Figura 3.15. Essa interface, proporciona aos usuários com direitos de administrador a gestão abrangente dos dados armazenados na base, incluindo informações sobre as estruturas, séries temporais, densidades espectrais de potência e frequências naturais. Ademais, a interface web possibilita operações como carregamento de observações, cadastro de novas estruturas e eliminação de conjuntos de dados incorretos. Os benefícios desse modelo arquitetónico são diversos. Primeiramente, destaca-se a eficiência no registo de séries temporais, viabilizando a consolidação eficaz de informações de aceleração provenientes de diferentes dispositivos móveis para uma mesma estrutura. Além disso, a plataforma permite o carregamento direto de conjuntos de treino já existentes, possibilitando a utilização combinada desses dados com as medições obtidas por telemóveis. A abordagem restrita no acesso ao *backoffice*, exclusivo para usuários autorizados, garante a integridade das informações armazenadas. A otimização de cálculos intensivos, como o algoritmo Welch para gerar o espectro de resposta, ao ser transferida para o servidor, melhora a eficácia, superando

possíveis limitações de dispositivos móveis. Adicionalmente, a estrutura facilita o desenvolvimento da aplicação em diversas plataformas, incluindo iOS, uma vez que os algoritmos implementados no servidor não dependem do sistema operativo do telemóvel (Figueiredo, et al., 2022).




The screenshot displays the 'App4SHM Admin' web interface. The top navigation bar includes the title 'App4SHM Admin', a welcome message 'WELCOME, DENNERSONCARVALHO', and links for 'VIEW SITE / CHANGE PASSWORD / LOG OUT'. The main content area is titled 'Home - Core - Natural frequencies'. On the left, there's a sidebar with 'CORE' and 'Natural frequencies' (with an 'Add' button). The central panel shows a search bar and a table of data. The table has columns: 'READING ID', 'DATE', 'STRUCTURE NAME', 'FREQUENCIES', 'OWNER', and 'TRAINING'. It lists 15 entries for various structures like '1966', '1965', '1964', etc., with their respective dates and frequency data. On the right, there's a 'FILTER' sidebar with a 'Clear all filters' button and a list of filters under 'By structure'.

READING ID	DATE	STRUCTURE NAME	FREQUENCIES	OWNER	TRAINING
1966	23-01-2023 18:21 WET	EE-PassagemFestivel	[3.758542141230069, 6.200455580865604, 13.55353075170845]	-	○
1965	23-01-2023 18:20 WET	EE-PassagemFestivel	[3.7844036497247706, 6.027522935779816, 13.302752935779816]	-	○
1964	23-01-2023 18:19 WET	EE-PassagemFestivel	[3.81062356581986, 6.08314087798153, 14.087798915242494]	-	○
1963	23-01-2023 18:18 WET	EE-PassagemFestivel	[3.77358495660377, 6.062533362722207, 13.477088948787063]	-	○
1962	23-01-2023 18:18 WET	EE-PassagemFestivel	[3.830645161290223, 6.064516129022258, 13.508064516129024]	-	○
1961	23-01-2023 18:17 WET	EE-PassagemFestivel	[3.7610619469026543, 6.075221238938052, 13.495573221238938]	-	○
1960	23-01-2023 18:16 WET	EE-PassagemFestivel	[3.747072993531616, 6.19672131147541, 13.817330210772832]	-	○
1959	23-01-2023 18:16 WET	EE-PassagemFestivel	[3.76940133037694, 6.314855875831485, 13.747228381374724]	-	○
1958	23-01-2023 18:15 WET	EE-PassagemFestivel	[3.8126361655773424, 6.169934640522872, 13.396692816407517]	-	○
1957	23-01-2023 18:14 WET	EE-PassagemFestivel	[3.810623555581986, 6.08314087798153, 13.51092565969777]	-	○
1956	23-01-2023 18:13 WET	EE-PassagemFestivel	[3.78657487091222, 6.175539380378656, 13.511187607573146]	-	○
1955	23-01-2023 18:12 WET	EE-PassagemFestivel	[3.78071835483932, 6.128544423440454, 13.52703213610584]	-	○
1954	23-01-2023 18:11 WET	EE-PassagemFestivel	[3.828306264503116, 6.236658932714615, 13.489095127610206]	-	○
1953	23-01-2023 18:11 WET	EE-PassagemFestivel	[3.759384962406016, 6.082706766917292, 13.430849624060116]	-	○
1952	23-01-2023 18:10 WET	EE-PassagemFestivel	[3.886010382694301, 6.117443868739205, 13.557868376511225]	-	○
1951	23-01-2023 18:09 WET	EE-PassagemFestivel	[3.7996545758366494, 6.031088082901555, 13.385146804839235]	-	○
1950	23-01-2023 18:08 WET	EE-PassagemFestivel	[3.846153865153846, 6.069381998793363, 13.57466063484164]	-	○
1949	23-01-2023 18:07 WET	EE-PassagemFestivel	[3.824302605232296, 6.144475920679896, 13.526191218130311]	-	○
1948	23-01-2023 18:06 WET	EE-PassagemFestivel	[3.7610619469026543, 6.185840707964601, 13.495573221238938]	-	○
1947	23-01-2023 18:05 WET	EE-PassagemFestivel	[3.7827393818984544, 6.057295143467858, 13.35540838852097]	-	○

Figura 3.15 Plataforma de administração remota da App4SHM

Nesta etapa, a App4SHM foi utilizada para obter um conjunto de 120 observações ao longo de vários dias, horários e cenários climáticos. Dentre essas, foram identificadas 11 observações atípicas de forma visual, sendo consideradas as quais se distanciaram de forma considerável do centro das medições (Figura 3.16). Essas observações atípicas podem surgir por diversas razões, como erros de medição, condições operacionais excepcionais ou eventos imprevistos que impactam a estrutura. A presença desses pontos discrepantes pode comprometer a precisão das análises subsequentes, resultando em interpretações distorcidas e conclusões equivocadas. Para o prosseguimento desta dissertação, restou um conjunto de 109 observações da estrutura em condição normal.



a) Relação entre a primeira (F1) e a segunda (F2) frequência natural de vibração, mostrando a dispersão dos dados experimentais

b) Relação entre a primeira (F1) e a terceira (F3) frequência natural de vibração, destacando a distribuição dos dados experimentais

Figura 3.16 Gráfico com as 120 observações iniciais

3.6 Modelação numérica

3.6.1 Compatibilidade entre programas

A indispensabilidade do software de análise estrutural na engenharia civil deriva da sua praticidade e eficiência em contraste com os métodos manuais de cálculo e projeto. Neste contexto, optou-se pela integração do software Recap, Revit e *Robot Structural Analysis* para ampliar ainda mais a abrangência das análises. O Revit e o Recap são reconhecidos por sua capacidade de modelação geométrica detalhada e aquisição de dados tridimensionais por meio de nuvens de pontos. Por outro lado, o *Robot Structural Analysis* destaca-se como uma ferramenta avançada para análise estrutural. As capacidades complementares dentre o Recap, Revit e *Robot Structural Analysis* simplificam o processo de modelação e análise, elevando substancialmente a precisão e credibilidade dos resultados obtidos. Nesse contexto, o Recap tem função de transformar os ficheiros E57 em RCP (sendo estes formatos de arquivos), adaptando-os para leituras em software da Autodesk.

3.6.2 Modelo numérico inicial

A modelação estrutural detalhada da passagem pedonal foi implementada no programa *Robot Structural Analysis*. Elementos finitos de barra com seis graus de liberdade por nó são utilizados para modelar os elementos estruturais, tais como as vigas e os pilares. A Figura 3.17 ilustra a vista global do modelo. A geometria, o material e a seção transversal dessas barras são especificadas para refletir as propriedades reais da estrutura, utilizando a informação constante na memória descritiva em paralelo com o levantamento por nuvem de pontos, sendo possível detalhar a seção de todos os elementos da estrutura.




Figura 3.17 Vista do modelo numérico

Elementos de cascas são aplicados para representar superfícies bidimensionais, como lajes e paredes. A espessura, o material e outras propriedades específicas são atribuídas às cascas para criar uma representação fiel da estrutura em questão, medidas retiradas da nuvem de pontos (Figura 3.18). A ligação entre barras e cascas que simulam os tabuleiros e as vigas está configurada de maneira rígida, impedindo a rotação e deslocamento relativo entre esses elementos, na qual as cargas são diretamente transferidas. Já a ligação entre o tabuleiro e o pilar foi modelada como uma ligação móvel articulada com restrição de rotação na direção normal ao tabuleiro, de modo a simular os aparelhos de apoio.




Figura 3.18 Corte transversal do tabuleiro central

Na estrutura foram consideradas apenas as cargas do peso próprio atribuída automaticamente pelo *Robot Structural Analysis*, e a carga permanente que referencia as guardas na estrutura, presentes apenas nas lajes em consola uniformemente distribuída. A análise conduzida no *Robot Structural Analysis* emprega o método dos elementos finitos para calcular as reações, deslocamentos e esforços internos, proporcionando uma compreensão profunda do comportamento estrutural. Isso permite a extração dos modos próprios de vibração do modelo, os quais serão abordados no próximo capítulo, no qual faz-se menção às interações de calibração do modelo virtual, cujo objetivo é alcançar uma correspondência entre os três modos de vibração identificados na estrutura real e aqueles obtidos através da App4SHM.

O modelo inicial referido apresenta as seguintes propriedades:

- Betão para as cascas 30/37;
- Betão para as vigas 40/50;
- A fim de simplificar a representação da estrutura, optou-se por substituir a escada por molas. Essa abordagem foi adotada com o propósito de simular a complexidade estrutural inerente ao elemento em estudo;
- O pilar foi segmentado em troços como estratégia de simplificação, conforme ilustrado na Figura 3.19 e assumindo um betão 30/37;
- Carga das guardas de 5 kN/m consideradas como massa para efeitos de análise modal;
- Lajes em consola junto dos pilares, com espessura de 29 cm e as lajes centrais com 13 cm;
- Viga foi modelada no *AutoCad* (Figura 3.20) e importada para o *Robot*;
- A avaliação da interação solo-estrutura apresenta desafios complexos, exigindo considerações técnicas abrangentes, incluindo alterações normativas, degradação material e intervenções históricas. Portanto foi adotado apoio elástico permitindo apenas deslocamento vertical, cuja rigidez foi assumida como incerta.




Figura 3.19 Geometria real e simplificada do pilar




Figura 3.20 Modelação da seção transversal das vigas

A conversão das cargas permanentes e quase permanentes para massa, nesse contexto, emerge como uma forma de otimizar a compreensão das propriedades dinâmicas do

sistema. A análise espectral, aprimorada por essa transformação, desempenha um papel na revelação de fenômenos vibratórios essenciais, como ressonâncias e modos vibracionais proeminentes. Assim, a aplicação dessa estratégia contribui para a uniformidade da análise, e também aprimora a capacidade de interpretar e compreender as nuances dinâmicas do sistema em estudo, sendo assim viável extrair os modos próprios de vibração do modelo numérico, possibilitando uma comparação com aqueles obtidos a partir da análise da estrutura física.

Como esperado os valores das frequências próprias de vibração obtidas com o modelo inicial são diferentes dos valores de referência definidos como valores médios das 109 frequências medidas (Quadro 1), sendo necessário a calibração do modelo inicial. O modelo numérico inicial é mais flexível do que a estrutural real; por exemplo, a segunda frequência natural de vibração do modelo numérico é 13,62% inferior ao valor de referência.

Quadro 1 Frequências naturais de vibração medidas e do modelo inicial

Modos	Referência (Hz)	Modelo Inicial (Hz)	Desvio (%)
F1	3,797	3,631	-4,37%
F2	8,187	7,072	-13,62%
F3	13,546	12,439	-8,17%

3.6.3 Parâmetros de calibração

Na fase de calibração numérica é importante considerar os parâmetros incertos que podem influenciar os resultados. Estes parâmetros incertos podem incluir rigidez dos materiais, geometria dos elementos estruturais, rigidez do solo, distribuição de carga, propriedades dos elementos, entre outros. A identificação e quantificação desses parâmetros incertos fazem com que seja reduzida a diferença entre os valores medidos e os do modelo numérico.

Dentre os parâmetros incertos da estrutura em estudo foram selecionados valores que interagem de forma mais agressiva aos modos de vibração. Foram assim adotados para este estudo quatro parâmetros de calibração:

- K_e^v - Rigidez da mola que simula a escada (vertical),
- K_e^h - Rigidez da mola que simula a escada (horizontal),
- K_{solo}^v - Rigidez ligação solo estrutura,
- P_g - Carga distribuída referente a guarda.

Cabe destacar que os elementos conhecidos da estrutura, notadamente as dimensões, foram deliberadamente excluídos como parâmetros de calibração, visando a conformidade do modelo com a configuração física da estrutura. Nesse sentido, os parâmetros de calibração foram direcionados exclusivamente a elementos cujos valores não eram previamente conhecidos ou cuja precisão carecia de certificação absoluta. Este escopo, por exemplo, se estendeu à avaliação das cargas exercidas pelas guardas sobre o tabuleiro, onde a aplicação de valores precisos ou mesmo a determinação desses valores é complexa e, em alguns casos, demanda cálculos específicos.

3.6.4 Procedimento de calibração e modelo numérico final

O procedimento de calibração numérico final consiste na etapa de ajuste dos parâmetros do modelo numérico com base nos dados medidos através do sistema de monitorização. Nesta fase, foi utilizado a série de Taylor para encontrar os valores ideais destes parâmetros, de modo a garantir que o modelo seja capaz de simular de forma precisa o comportamento da passagem pedonal. Este processo envolve a comparação entre os dados simulados e os dados reais de monitorização, de forma a garantir a precisão do modelo.

A série de Taylor é um método de expansão de funções em torno de um ponto específico. Desenvolvida por Brook Taylor, esta série permite aproximar funções complexas por meio de polinômios de graus arbitrários. Cada termo na série é obtido a partir das derivadas sucessivas da função no ponto de referência, o que permite uma aproximação cada vez mais precisa da função ao redor desse ponto a medida que novos termos são acrescentados. Inicialmente, contou-se com as frequências médias derivadas da estrutura,

$$\tilde{f} = \begin{pmatrix} f_1 \\ f_2 \\ f_3 \end{pmatrix}, \quad (1)$$

e as frequências obtidas através do modelo,

$$f_0(C_0^1, C_0^2, C_0^3, C_0^4) = \begin{pmatrix} f_0^1 \\ f_0^2 \\ f_0^3 \end{pmatrix}, \quad (2)$$

levando em consideração os valores iniciais dos parâmetros de calibração.

Nas definições (1) e (2),

$\tilde{f}$ - são as frequências medidas;

f_0 - são as frequências iniciais do modelo;

C_0^1 - coeficiente de elasticidade vertical representa a escada (K_e^v);

C_0^2 - coeficiente de elasticidade horizontal que representa a escada (K_e^h);

C_0^3 - coeficiente de elasticidade vertical que da interação solo-estrutura (K_{solo}^v);

C_0^4 - carga atribuída pelo peso próprio das guardas (P_g).

A diferença entre as frequências obtidas através do modelo com os parâmetros iniciais de calibração e as frequências medidas determinam os erros.

$$\tilde{\varepsilon}(\mathbf{C}_0) = \begin{pmatrix} f_1 - f_0^1 \\ f_2 - f_0^2 \\ f_3 - f_0^3 \end{pmatrix} = \tilde{\mathbf{f}} - \mathbf{f}_0(\mathbf{C}_0) \quad (3)$$

Onde o vetor $\mathbf{C}_0$ contém os valores iniciais dos parâmetros de calibração $C_0^1, \dots, C_0^4$.

O objetivo é determinar as variações ($d\mathbf{C}_0$) dos parâmetros de calibração que fazem com que,

$$\varepsilon(\mathbf{C}_0 + d\mathbf{C}_0) = 0, \quad (4)$$

assegurando simultaneamente que os valores dos parâmetros de calibração (dc_i) se mantenham dentro de limites fisicamente aceitáveis. A plausibilidade física é monitorada por meio de restrições quantitativas e qualitativas. No contexto quantitativo, os parâmetros de calibração individuais são submetidos a limites definidos independentemente, estabelecendo uma faixa específica de variação delimitada por um valor mínimo e um valor máximo.

A expansão da função de erro, em séries de Taylor ao redor dos pontos iniciais $\mathbf{C}_0$, envolve representar o erro como uma soma infinita de termos polinomiais de graus cada vez mais altos. Contudo, por simplicidade, apenas termos lineares são considerados neste trabalho. A expansão da função de erro é expressa de forma como:

$$\varepsilon(\mathbf{C}_0 + d\mathbf{C}_0) = \tilde{\varepsilon}(\mathbf{C}_0) + \sum_{i=1}^4 \frac{\partial \varepsilon(\mathbf{C}_0)}{\partial C_i} \times dc_i = 0 \quad (5)$$

Em que, $\frac{\partial \varepsilon}{\partial C_i}$ são as derivadas da função do erro nos parâmetros de calibração.

Essa condição de erro zero garante que o modelo numérico está alinhado de forma precisa com a realidade observada. A calibração bem-sucedida, por vezes demanda de várias iterações até que a função de erro seja minimizada. Nota-se que o erro não vai atingir necessariamente um valor nulo, por causa das restrições de plausibilidade física aplicadas aos parâmetros C_i .

Foram necessárias pelo menos sete iterações para evoluir do modelo inicial para o modelo final devidamente calibrado. O processo foi automatizado através de uma função em MATLAB, que recebe os valores medidos das frequências, os valores do modelo inicial e os

limites dos parâmetros de calibração e resolve o sistema (5) através de um processo de minimização condicional. De seguida, o software sugere valores que resultarão na redução do erro. Além disso, ilustra os potenciais valores dos modos de vibração utilizando os novos parâmetros de calibração, fornecendo uma representação visual clara da eficácia do processo do cálculo.

Após a conclusão das iterações e a obtenção de um modelo que reproduz fielmente (erros nulos ao nível de todas as frequências ver Quadro 2) a estrutura real, os parâmetros resultantes são os seguintes:

- $K_e^v = 450 \text{ kN/m}$;
- $K_e^h = 1535000 \text{ kN/m}$;
- $K_{solo}^v = 370000 \text{ kN/m}$;
- $P_g = 14,51 \text{ kN/m}$.

Quadro 2 Frequências próprias de vibração medidas e do modelo calibrado

Modos	Referência	Modelo Calibrado	Desvio
F1	3,797 Hz	3,797 Hz	0,00%
F2	8,187 Hz	8,187 Hz	0,00%
F3	13,546 Hz	13,546 Hz	0,00%

Os modos próprios de vibração recuperados pelo modelo numérico são apresentados nas Figura 3.21, Figura 3.22 e Figura 3.23. A precisão obtida nas frequências de vibração permite assumir que o modelo represente fielmente o sistema estrutural real.




Figura 3.21 Primeiro modo de vibração: Modo de flexão simples




Figura 3.22 Segundo modo de vibração: Modo de torção




Figura 3.23 Terceiro modo de vibração: Segundo modo de flexão

3.7 Considerações finais

Este capítulo abordou diversos aspetos essenciais para o estudo da ponte pedonal. Iniciou-se com uma descrição detalhada do caso de estudo, destacando os elementos físicos da passagem pedonal do Campo Grande.

Posteriormente, foi conduzida uma inspeção visual minuciosa, visando avaliar a condição estrutural e identificar possíveis danos. A inspeção visual foi acompanhada com a realização do levantamento por nuvem de pontos da geometria da ponte, proporcionando uma representação tridimensional detalhada da estrutura. Esse levantamento validou as dimensões da passagem pedonal para a criação do modelo numérico, sendo que o telemóvel também pode ser utilizado como ferramenta para esse levantamento. Essa etapa foi fundamental para o entendimento preliminar da integridade da estrutura, bem como para identificar a existência de elementos estruturais geometricamente não condizentes com os identificados na memória

descritiva. Por exemplo, foram identificadas diferenças na espessura da laje, relativamente ao preconizado em projeto.

Em termos de monitorização, foi explorada a aplicação da App4SHM para coletar um conjunto de 109 observações em estado normal (referência), empregando telemóveis para medições práticas e rápidas. Esta ferramenta mostrou-se valiosa, oferecendo uma abordagem prática para ser utilizada por inspetores durante as inspeções visuais periódicas, por exemplo.

A etapa seguinte envolveu a formulação e execução do modelo numérico, descrevendo minuciosamente os parâmetros e características iniciais. Destaca-se a importância da calibração precisa do modelo numérico. Esse processo foi conduzido com rigor, ajustando os parâmetros do modelo para refletir o comportamento real da passagem pedonal.

Este capítulo, portanto, estabeleceu uma base sólida para as fases subsequentes do estudo, proporcionando uma compreensão holística da estrutura e garantindo a consistência das análises futuras.

CAPITULO 4 - Resultados e discussão

4.1 Considerações iniciais

Neste capítulo, o objetivo principal é o treino de algoritmos de aprendizagem máquina (MLA) utilizando a base de dados híbrida, a qual inclui observações experimentais realizadas na passagem pedonal, e observações numéricas decorrentes do desenvolvimento do modelo numérico de elementos finitos, nomeadamente através da adição de massa e da inserção de danos controlados. A utilização de um conjunto diversificado de observações visa testar a capacidade dos algoritmos de aprendizagem de reconhecer e diagnosticar danos ou condições estruturais anômalas.

No total são considerados oito cenários distintos, distribuídos em três categorias: normal, acréscimo de massa e simulação de dano. Esses cenários representam diferentes estados da estrutura, permitindo uma análise das diversas condições a que a estrutura pode estar sujeita.

Tanto o regime não supervisionado quanto o regime supervisionado são empregues no treino. O regime não supervisionado permite que os algoritmos identifiquem anomalias apenas com prévio conhecimento dos dados correspondendo à situação normal, enquanto o regime supervisionado envolve o uso de dados rotulados, correspondendo a várias condições estruturais conhecidas para treinar os algoritmos a reconhecer padrões específicos de danos. Os resultados serão apresentados e discutidos com base na precisão dos algoritmos em detetar dados anômalos e danos, possibilitando a comparação de desempenho entre eles.

Este capítulo detalha o processo de preparação dos dados, o treino dos algoritmos e a avaliação de seu desempenho, relacionando-os aos objetivos iniciais da dissertação. Além disso, são abordadas as metodologias de validação dos algoritmos, incluindo a divisão dos dados em conjuntos de treino e teste, e a utilização de métricas de desempenho, para avaliar a eficácia dos algoritmos.

A discussão final incluirá a análise dos resultados obtidos, destacando os pontos fortes e as limitações dos métodos utilizados, que possam aprimorar a deteção de danos e condições estruturais anômalas utilizando MLA. Dessa forma, este capítulo contribuirá significativamente para o entendimento do potencial e das aplicações práticas dessa tecnologia na monitorização de estruturas.

4.2 Bases de dados híbridos

4.2.1 Considerações gerais

Com a construção do modelo numérico, torna-se possível iniciar simulações envolvendo testes destrutivos, ou seja, a introdução controlada de danos na estrutura. Realizar tais testes de maneira física é inviável devido às limitações práticas e aos custos associados. Com a implementação de um modelo, a simulação de danos pode ser conduzida de maneira eficaz, proporcionando uma abordagem mais acessível e relativamente rápida para avaliar a resposta estrutural frente a diferentes cenários de degradação. Esse avanço viabiliza também a análise de condições operacionais extremas, contribuindo significativamente para a compreensão aprofundada do comportamento da estrutura sob diversas condições de serviço.

A distinção entre sobrecarga de utilização e dano estrutural revela-se um ponto essencial na formação de MLA voltados para a monitorização estrutural. A sobrecarga de utilização, associada a cargas excecionais, pode induzir respostas dinâmicas atípicas temporariamente na estrutura, mas sem causar danos permanentes. Por outro lado, o dano estrutural refere-se a alterações físicas e permanentes na integridade da estrutura, resultando em mudanças significativas nas suas características modais e respostas vibratórias. No entanto, a resposta dinâmica de uma estrutura submetida a cargas excecionais pode manifestar-se de maneira semelhante com dano, o que representa um potencial risco para a confiabilidade do sistema de deteção de dano. Ao treinar MLA para distinguir entre essas duas condições, a precisão e a fidedignidade dos sistemas de monitorização estrutural são aprimoradas. Detetar a diferença entre sobrecarga de utilização e danos reais permite a implementação de medidas corretivas e preventivas no momento oportuno, contribuindo para uma gestão eficiente e sustentável das estruturas e, no limite, na salvaguarda de vidas humanas. Adicionalmente, este enfoque possibilita a maximização da vida útil dos ativos, minimizando intervenções desnecessárias e, assim, resulta em decisões mais informadas e económicas na gestão estrutural.

4.2.2 Extensão probabilística de observações numéricas

Possuindo um modelo base (determinístico) para uma condição estrutural, é necessário aplicar às suas observações a mesma distribuição probabilística que foi observada na monitorização da estrutura real. É neste quesito que se encontram as distribuições probabilísticas. A ideia é que essas distribuições reflitam a variabilidade das medições observadas na prática, incorporando no modelo numérico a incerteza e a aleatoriedade

inerentes aos dados experimentais. Isso permite que o conjunto total de observações seja mais representativo das condições reais.

Para gerar novas observações da estrutura, utilizando o modelo numérico com base nessa expansão, é necessário especificar parâmetros, tais como a média e a matriz de covariância. A média representa o centro da distribuição, enquanto a matriz de covariância indica como as variáveis estão correlacionadas entre si. Este procedimento contribui para um conjunto de observações numéricas mais completo, sendo um elemento importante na formulação de estratégias eficazes para o treino de MLA.

Entender o desvio padrão e a covariância é importante para análises estatísticas mais avançadas e para modelar relacionamentos em conjuntos de dados complexos. O desvio padrão é uma medida que indica o grau de dispersão de um conjunto de dados em relação à sua média (Peck & Devore, 2012). Matematicamente, o desvio padrão (σ) é calculado pela raiz quadrada da variância na forma de:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (6)$$

onde:

- x_i é cada valor no conjunto de dados;
- $\bar{x}$ é a média do conjunto de dados;
- N é o número total de observações.

A covariância mede a relação linear entre duas variáveis. Ela é positiva quando as variáveis tendem a aumentar ou diminuir juntas, negativa quando uma variável tende a aumentar enquanto a outra diminuir, e próxima de zero quando não há relação linear (Johnson & Wichern, 2002). A expressão para a covariância entre duas variáveis X e Y é:

$$cov(X, Y) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) \quad (7)$$

onde:

- x_i e y_i são os valores individuais dos dois conjuntos de dados;
- $\bar{x}$ e $\bar{y}$ são as médias de X e Y ;
- N é o número total de observações.

Em conjuntos de dados multivariados, a covariância é representada por uma matriz. A matriz de covariância (Σ) é simétrica e fornece as covariâncias entre todas as combinações possíveis de variáveis. Por exemplo, para três variáveis (x , y e z), ela é expressa como:

$$\Sigma = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad (8)$$

4.3 Composição do conjunto de observações

4.3.1 Fundamentação inicial

Para representar com precisão a realidade das condições estruturais, os modelos numéricos determinísticos apresentam limitações, uma vez que fornecem apenas um conjunto de observações médias para cada condição de carga ou dano estrutural. Contudo, no mundo real, as medições não são pontuais e uniformes; elas formam verdadeiras nuvens de dados devido à variabilidade das condições ambientais que influenciam diretamente as estruturas e à própria precisão das medições.

Para abordar essa complexidade e aproximar os modelos da realidade observada, adota-se a estratégia abordada na seção anterior, isto é, começa pela quantificação dessa variabilidade e depois procede-se à extensão probabilística das observações para cada condição estrutural. Este método ajusta os modelos para refletirem os níveis de variância realmente observados nos experimentos assumindo uma distribuição Gaussiana para essas condições variáveis.

4.3.2 Observações experimentais normais

A Figura 4.1 apresenta uma visualização abrangente das primeiras três frequências naturais de vibração medidas experimentalmente na passagem pedonal utilizando a App4SHM, gerando assim o conjunto de 109 observações da estrutura não danificada (normal). Cada observação é composta pelas três frequências naturais de vibração ($F1$, $F2$ e $F3$). Essa representação combina as observações no espaço das primeiras três frequências com histogramas da distribuição de cada frequência.




Figura 4.1 Distribuições e histogramas de frequências naturais observadas experimentalmente

Ainda é possível a visualização das mesmas observações em três dimensões (F1, F2 e F3) em conjunto, como demonstra a Figura 4.2.




Figura 4.2 Visualização tridimensional das observações experimentais compostas por três frequências naturais

Para as observações experimentais foi calculada a matriz da covariância, de modo a poder replicar nos dados proveniente do modelo a dispersão obtida na estrutura real, a fim de

prosseguir com a extensão probabilística para os demais conjuntos. A matriz de covariância resultante desse conjunto normal é:

$$\Sigma = \begin{pmatrix} 0,0017 & 0,0012 & 0,0005 \\ 0,0012 & 0,0234 & 0,0037 \\ 0,0005 & 0,0037 & 0,0464 \end{pmatrix}$$

4.3.3 Observações numéricas com acréscimo de massa

Com o intuito de modelar condições operacionais mais extremas, foram realizadas leituras considerando acréscimos de carga correspondentes a 25, 50, 75 e 100 pessoas, conforme detalhado nas situações da Figura 4.3. Para os cálculos, adotou-se uma média de massa de 70 kg por pessoa, resultando em incrementos de carga de 0,03 kN/m², 0,06 kN/m², 0,09 kN/m² e 0,12 kN/m², respetivamente. As leituras foram obtidas estritamente pelos modelos numéricos.





Figura 4.3 Representação dos acréscimos de carga

As primeiras três frequências naturais obtidas considerando vários cenários de carga adicional estão resumidas no Quadro 3.


Quadro 3 Frequências naturais de vibração com adição de carga

Modos	Modelo referência	Cenário 1	Cenário 2	Cenário 3	Cenário 4
F1	3,797 Hz	3,791 Hz	3,785 Hz	3,779 Hz	3,773 Hz
F2	8,187 Hz	8,176 Hz	8,166 Hz	8,155 Hz	8,145 Hz
F3	13,546 Hz	13,530 Hz	13,516 Hz	13,501 Hz	13,486 Hz


Os valores listados no Quadro 3 são considerados valores médios das respetivas distribuições probabilísticas. Em torno desses valores de referência, para remeter a mesma quantidade de observações experimentais, foram geradas 109 novas observações numéricas para cada cenário, utilizando expansão probabilística consistente com a covariância observada na estrutura real durante a sua monitorização. Os resultados desse processo são apresentados na Figura 4.4, onde os pontos vermelhos representam as observações geradas pela expansão numérica e os pontos azuis representam as observações experimentais.




a) Cenário 1



b) Cenário 2



c) Cenário 3




d) Cenário 4

Figura 4.4 Observações experimentais (azul) e expansão probabilística (vermelho) das primeiras três frequências naturais de vibração para quatro cenários estruturais


Os valores desses novos conjuntos sofrem um afastamento dos dados experimentais de forma proporcional à carga aplicada. No entanto, esse afastamento ocorre gradualmente, havendo sobreposição significativa entre os dados correspondendo às condições com acréscimo de massa e sem acréscimo, mesmo para a sobrecarga extraordinária de 100 pessoas.

Na etapa subsequente da análise, todas as observações apresentadas na Figura 4.4 são consolidadas na base de dados da estrutura não danificada. Esta abordagem busca a integração das informações oriundas da estrutura em sua condição normal e com adição de massa, promovendo um conjunto híbrido total de 545 observações da estrutura não danificada.

A combinação de todos os dados da estrutura não danificada tem como objetivo alcançar uma perspectiva unificada das características modais e dos padrões predominantes de resposta, para uma compreensão mais precisa do comportamento do sistema em sua condição normal. A ausência dessa estratégia, diante de um aumento substancial na sobrecarga de utilização, poderia conduzir a interpretações incorretas, podendo confundir o efeito da sobrecarga como um dano estrutural. A Figura 4.5 apresenta a unificação da base de dados da estrutura não danificada.



a) Histogramas e observações no espaço bidimensional das frequências



b) Observações no espaço tridimensional das frequências

Figura 4.5 Base híbrida de observações da estrutura não danificada

Ao consolidar as observações experimentais e numéricas da estrutura não danificada, é imprescindível atentar para a possibilidade da ocorrência de valores discrepantes. Valores discrepantes ou atípicos (outliers) são observações que se destacam significativamente do conjunto, podendo distorcer a interpretação e prejudicar os resultados analíticos.

A exclusão de valores atípicos é essencial no processo de análise de dados por diversos motivos:

- I. Preservação da precisão estatística: A presença de observações atípicas pode distorcer significativamente as métricas estatísticas, como média e desvio padrão. A exclusão dessas observações permite uma representação mais precisa da tendência central e da dispersão dos dados;
- II. Influência nos modelos estatísticos: Observações atípicas podem exercer uma influência desproporcional em modelos estatísticos, resultando em estimativas imprecisas. A remoção dessas observações discrepantes contribui para a construção de modelos mais robustos e confiáveis;
- III. Melhoria na visualização gráfica: Gráficos e visualizações são ferramentas fundamentais na análise de dados. A presença de observações atípicas pode comprimir a escala dos gráficos, dificultando a interpretação. Ao excluí-los, é possível obter visualizações mais informativas e compreensíveis;

IV. Alinhamento com pressupostos dos modelos: Muitos modelos estatísticos assumem a normalidade dos dados. Observações atípicas podem violar esse pressuposto, afetando a validade dos resultados. A exclusão adequada dessas observações ajuda a manter a conformidade com os pressupostos dos modelos.

Foram identificadas 14 observações atípicas pelo seguinte método: (i) calcula-se a média das observações, fornecendo um ponto de referência central no conjunto total; (ii) calcula-se a diferença entre o valor de cada observação e a média correspondente na mesma dimensão. Se essa diferença exceder três desvios padrão, a observação é considerada um valor atípico; (iii) finalmente, os valores atípicos identificados são destacados num gráfico de dispersão tridimensional (Figura 4.6), onde as observações consistentes são representadas em azul e os valores atípicos são destacados em vermelho.




Figura 4.6 Identificação das observações atípicas (vermelho) no conjunto das observações

Após a exclusão, o conjunto ficou constituído por 531 observações para caracterizar o funcionamento normal da estrutura não danificada, para posteriormente ser utilizado no treino dos MLA.

4.3.4 Observações numéricas com simulação de dano

Aprofundando a análise no contexto da deteção de dano, foram geradas observações numéricas da estrutura danificada. A abordagem adotada consiste na inserção de uma fenda estrategicamente posicionada nas vigas e tabuleiro da estrutura, resultando na redução local da rigidez da passagem pedonal. Este procedimento permite avaliar como a estrutura reage perante alterações na sua integridade. O objetivo é simular condições realistas de dano, proporcionando uma compreensão mais aprofundada das capacidades dos MLA na deteção de anomalias estruturais. Essa simulação servirá como base para análises subsequentes, que explorarão a capacidade dos MLA de identificar e caracterizar tais danos em regime não supervisionado e supervisionado.

A introdução de uma fenda na ponte pode ter um impacto considerável na rigidez global da estrutura. Uma fenda atua como uma descontinuidade na geometria da estrutura, alterando a distribuição de esforços na sua proximidade. Ao criar uma abertura na estrutura, a fenda reduz a seção transversal efetiva e, conseqüentemente, a área que contribui para a rigidez global. A redução na rigidez vai influenciar diretamente as frequências e os modos naturais de vibração da passagem pedonal.

Em vigas biapoiadas, em particular na região central, há uma maior suscetibilidade a deformações e concentração de esforços. Portanto, a estratégia de introdução das fendas visa direcionar a intervenção de forma assertiva, posicionando-as exatamente na zona central do vão. Esse cenário de dano explora a vulnerabilidade dessa área específica da estrutura.

Neste contexto, vale ressaltar que o terceiro modo de vibração apresenta um nó ao meio vão onde foi inserida a fenda, como demonstra a Figura 4.7. Por isso, é expetável que o mesmo seja menos afetado pela presença da fenda comparado aos outros dois modos focados neste trabalho.




Figura 4.7 Terceiro modo de vibração tem um nó no ponto central do vão

A Figura 4.8 ilustra a zona fendilhada em que foi utilizado o procedimento para simular a inserção da fenda na passagem pedonal. Para isso, utilizou-se o programa AutoCAD para introduzir a redução da seção, simulando a fenda e extraíndo o momento de inércia (I) da seção transversal do elemento estrutural após a fenda. Devido à limitação do software Robot Structural Analysis em modificar diretamente a altura da seção transversal da viga, foi necessário reduzir o módulo de Young (E) para garantir que a rigidez à flexão (EI) do trecho, obtida pela redução do módulo de Young, seja equivalente à rigidez resultante da presença da fenda correspondente à redução de seção. Essa alteração visa aproximar a rigidez dos elementos estruturais ao comportamento que a presença da fenda induziria na estrutura física. Ela foi aplicada aos elementos finitos situados à distância de 52 cm do centro do vão.





Figura 4.8 Discretização na zona central com identificação do trecho danificado

Foram contempladas três profundidades de fendas na zona fendilhada da viga, respetivamente de 10, 20 e 30 cm. Dado que a laje de tabuleiro está apenas apoiada no banzo inferior das vigas, podem existir diversas possibilidades quanto ao impacto da fenda, podendo a mesma estar localizada apenas nas vigas, não afetando a rigidez do tabuleiro. No entanto, considerou-se o tabuleiro sempre afetado por uma zona fendilhada com fendas de 3 cm de profundidade, o qual submete a estrutura a uma condição mais extrema referente ao dano. O Quadro 4 exhibe os valores médios das frequências naturais obtidas após as simulações nos modelos numéricos com dano. Confirma também que a introdução de um dano a meio do vão na estrutura, especificamente relacionado à presença de uma fenda, não influencia significativamente o modo 3. As variações mais significativas registram-se para a primeira frequência no modelo com a fenda mais profunda (4,06%). As variações menos significativas foram observadas na terceira frequência, apresentando uma máxima de apenas 0,03%, no caso da fenda mais profunda.


Quadro 4 Resultados da simulação de dano

Cenário de dano 1 – Profundidade de fenda 10 cm			
Frequências	Modelo s/ dano	Modelo c/ dano	Diferença percentual
F1	3,797	3,744	1,40%
F2	8,187	8,116	0,87%
F3	13,546	13,544	0,01%
Cenário de dano 2 - Profundidade de fenda 20 cm			
F1	3,797	3,717	2,11%
F2	8,187	8,086	1,23%
F3	13,546	13,543	0,02%
Cenário de dano 3 - Profundidade de fenda 30 cm			
F1	3,797	3,643	4,06%
F2	8,187	8,012	2,14%
F3	13,546	13,542	0,03%


Da mesma forma que no conjunto de massa, para cada situação de dano, utilizou-se a extensão probabilística para compor o conjunto de dados com dano. Assim, foram gerados 327 dados com dano, distribuídos igualmente com 109 observações para cada cenário de dano. A Figura 4.9 ilustra, em azul, o conjunto de observações da estrutura não danificada e, em vermelho, os dados que representam a introdução de valores da estrutura danificada.



a) Cenário de dano 1



a) Cenário de dano 2



b) Cenário de dano 3

Figura 4.9 Conjuntos de observações da estrutura não danificada (azul) e da estrutura danificada (vermelho)

4.4 Dados de entrada

Após a composição dos conjuntos de observações detalhada na seção 4.3, esta seção sumariza os dados utilizados posteriormente nos MLA.

As observações foram distribuídas em três categorias principais: o conjunto normal, o conjunto com acréscimo de massa e o conjunto com simulação de dano.

- Conjunto normal: este conjunto inclui observações que representam o estado da estrutura sob condições normais de operação, sem alterações ou intervenções, coletados experimentalmente na estrutura, sendo composto por 105 observações.
- Conjunto com acréscimo de massa: conjunto de dados gerados a partir dos modelos numéricos com massas adicionais distribuídas na estrutura uniformemente. No total são geradas 426 novas observações.
- Conjunto com simulação de dano: engloba as observações simuladas nos três cenários da estrutura danificada, totalizando 327 observações.

O Quadro 5 resume as observações de entrada de forma detalhada, formando a espinha dorsal para o diagnóstico e análise desenvolvidos neste estudo.

Quadro 5 Composição das observações de entrada com rótulos detalhados

Condição	Quantidade	Metodologia	Rótulo
Normal	105	Experimental	Normal
Normal	106	Numérico	Massa 25
Normal	108	Numérico	Massa 50
Normal	105	Numérico	Massa 75
Normal	107	Numérico	Massa 100
Dano	109	Numérico	Dano 10
Dano	109	Numérico	Dano 20
Dano	109	Numérico	Dano 30

4.5 Classificação não supervisionada

4.5.1 Fundamentação inicial

Na engenharia civil, é frequente dispor apenas de observações de estruturas não danificadas para análise. Diante desta realidade, a classificação não supervisionada emerge como uma ferramenta cujo objetivo é o de detetar valores atípicos nas observações, que podem indicar a presença de dano, ainda que também possam ser meras flutuações sem significado de dano estrutural. Este processo é desafiador devido às possíveis situações indesejáveis que podem surgir.

São distintos os níveis de importância na classificação desses três rótulos: dano, massa e normal. O dano, com sua maior importância a uma classificação errada, pode gerar perdas irreversíveis na estrutura. Por outro lado, uma classificação errada de massa como sendo dano pode não gerar grandes efeitos negativos do ponto de vista estrutural, pois acionam alertas que podem ser sanados com inspeções.

Dentro deste escopo, enfrentamos principalmente duas situações problemáticas: a identificação de uma anomalia em uma estrutura que está, de facto, normal, conhecido como “falso positivo” e a falha em reconhecer um dano real, categorizando uma observação danificada como normal, o “falso negativo”. Ambos os erros têm implicações práticas, pois enquanto os falsos positivos podem levar a descredibilizar o sistema de monitorização, intervenções desnecessárias e custos adicionais, os falsos negativos podem resultar em falhas na deteção de problemas críticos, comprometendo a segurança da estrutura e de vidas humanas.

Portanto, a utilização eficaz da classificação não supervisionada exige um equilíbrio das observações de entrada e uma análise das observações de saída para minimizar esses erros, garantindo assim que as medidas de manutenção e reparo sejam implementadas de maneira precisa e económica, baseadas em diagnósticos confiáveis.

4.5.2 Aprendizagem não supervisionada na passagem pedonal

A base de treino foi construída utilizando 80% do conjunto de condição normal e 80% do conjunto proveniente da condição de massa de 25 pessoas. Esta configuração foi escolhida para capturar variações normais e de sobrecarga, utilizando o conjunto de 25 pessoas por fazer fisicamente sentido de acontecer na passagem pedonal.

Uma das técnicas dentro da classificação não supervisionada e utilizada nesse trabalho é o algoritmo baseado na distância de Mahalanobis. Este algoritmo oferece uma medida de distância entre um ponto e um conjunto de pontos num espaço multidimensional, levando em consideração a correlação entre as diferentes variáveis. Essa abordagem permite uma análise mais precisa da similaridade entre os pontos, contribuindo significativamente para a identificação de padrões e agrupamentos nos dados. Figueiredo (2010) destaca que a distância de Mahalanobis tem sido amplamente empregada em SHM para a normalização de dados, embasado no estudo de Manson et al. (2003), que aplicaram a distância de Mahalanobis a dados de vibração obtidos a partir de um modelo simplificado da asa de uma aeronave para deteção de dano.

Para a aplicar o MLA baseado na distância quadrada de Mahalanobis, é essencial que o conjunto de observações apresente uma distribuição normal, formando uma curva Gaussiana no espaço das frequências naturais de vibração. A Figura 4.10 exhibe os histogramas do conjunto de observações de treino, validando a adequação da base de dados para a utilização de Mahalanobis.




Figura 4.10 Histogramas da base de treino

Ao aplicar o MLA baseado na distância quadrada de Mahalanobis para deteção das observações discrepantes, é necessário estabelecer um limite superior que determina quais observações serão consideradas como observações atípicas. O parâmetro denominado

probabilidade de falso alarme (PFA), também conhecido por nível de significância, desempenha um papel importante nesse processo. O PFA representa a probabilidade de classificar erroneamente uma observação normal como observação atípica. Por exemplo, ao definir $PFA = 0,05$, estamos aceitando até 5% de falsos alarmes para garantir uma deteção robusta de observações atípicas.

Portanto, ao estabelecer um valor específico para o PFA, estamos definindo um critério estatístico que equilibra a necessidade de detetar corretamente observações atípicas com a necessidade de minimizar falsos positivos. Para ilustrar este equilíbrio, a Figura 4.11 oferece uma representação visual da dispersão e incerteza das observações em duas dimensões do espaço das frequências. Essa figura consiste em elipses centradas nos valores médios das frequências naturais incluídas na base de treino, onde o tamanho, orientação e forma das elipses são determinados pela matriz de covariância das observações. Cada elipse representa um nível de confiança específico, com PFA a variar entre 0,01 para a elipse exterior e 0,15 para a interior. Basicamente, apenas 1% das observações normais encontram-se fora da elipse exterior, mas essa percentagem sobe para 15% no caso da elipse interior.




Figura 4.11 Elipses de confiança sobre observações no espaço bidimensional das frequências de vibração

A escolha de um PFA equilibrado é justificada pela análise das elipses, pois um valor menor dessa métrica resulta numa área (elipse) de leituras consideradas normais pelo algoritmo mais ampla, o que pode aumentar significativamente a taxa de falsos negativos,

especialmente quando as observações com dano ocupam um espaço na vizinhança das observações normais. A Figura 4.12 apresenta os dados classificados como observações atípicas para um PFA de 0,01, o que resultaria em um número elevado de falsos negativos, por outro lado ao considerar um PFA=0,15, observa-se um incremento no número de falsos positivos. Com base nessa análise, determinou-se que um PFA=0,05 oferece o melhor equilíbrio entre falsos positivos e falsos negativos.




Figura 4.12 Classificação das observações assumindo um PFA de 0.01

4.5.3 Resultados da classificação não supervisionada

Concluída a fase de treino, e adotando o PFA=0,05 pelas razões explicadas acima, a base de teste foi composta pelos demais conjuntos, incluindo observações classificadas como normais, massa e danos detalhados na seção 4.4. Esse conjunto de teste é utilizado para avaliar o desempenho do algoritmo de classificação em um cenário diversificado. Com base na Figura 4.13, é possível observar a classificação das observações em típicas (observações azuis) e atípicas (observações vermelhas) em relação ao índice de danos, com uma linha pontilhada que representa o limite do PFA de 5%. As regiões destacadas mostram diferentes condições experimentais, incluindo massas crescentes e danos simulados. Nos dois primeiros níveis de dano (Dano 10 e Dano 20), as leituras são predominantemente interpretadas como normais, indicando uma menor sensibilidade do índice de danos para detecções em níveis mais baixos de severidade. Por outro lado, no nível mais gravoso (Dano 30), observa-se um

aumento significativo no número de observações classificadas como atípicas, refletindo uma maior eficácia do método em identificar anomalias em condições de dano mais severas. Este comportamento destaca a importância de ajustar adequadamente o valor do PFA para equilibrar a identificação de falsos positivos e falsos negativos.






Figura 4.13 Observações classificadas como típicas e atípicas (base de treino foi construída utilizando 80% do conjunto de condição normal e 80% e do conjunto provenientes da condição de massa de 25 pessoas)

A Figura 4.14 apresenta a visualização do resultado da classificação no espaço das primeiras duas frequências. Na Figura 4.14 (a), as observações são divididas em duas categorias: as que correspondem a observações consideradas típicas (verde) e as que correspondem a observações consideradas atípicas (vermelho). A Figura 4.14 (b) destaca as classificações corretas e incorretas. Aqui, as observações são divididas em duas categorias: as que foram corretamente classificadas (verde) e as que foram erroneamente classificadas (vermelho). As classificações incorretas ocorrem, na sua maioria, em observações com danos cuja magnitude não é suficientemente elevada para diferenciá-las de maneira clara da zona de observações típicas.



a) Leituras normais e observações atípicas



b) Classificações corretas e incorretas

Figura 4.14 Resultados da classificação não supervisionada

Os mesmos resultados estão apresentados no Quadro 6 e Quadro 7, detalhando a precisão da classificação por categoria e por subcategoria. No primeiro quadro, estão exibidos

os resultados referentes à precisão, número de classificações corretas e número de classificações incorretas para cada categoria de observações. Observou-se que a categoria "Normal" obteve uma precisão de 100%, indicando que todos os dados dessa categoria foram corretamente classificados. Por outro lado, a categoria "Dano" apresentou a menor precisão, com apenas 43,73% dos dados corretamente classificados.

No Quadro 7 estão fornecidos os resultados mais específicos para cada subcategoria das observações. Destaca-se que as observações relacionadas à categoria "Massa" obtiveram altas taxas de precisão, com valores variando entre 91,59% e 97,14%. Por outro lado, as observações associadas à categoria "Dano" mostram precisões significativamente mais baixas, variando de 9,17% a 90,83%.

Quadro 6 Detalhes da precisão por categoria

Categoria	Acurácia	Classificações Corretas	Classificações Incorretas
Dano	43,73%	143	184
Massa	94,71%	322	18
Normal	100%	20	0

Quadro 7 Detalhes da precisão por subcategoria

Subcategoria	Acurácia	Classificações Corretas	Classificações Incorretas
Dano10	9,17%	10	99
Dano20	31,19%	34	75
Dano30	90,83%	99	10
Massa100	91,59%	98	9
Massa75	97,14%	102	3
Massa50	95,37%	103	5
Massa25	95,0%	19	1
Normal	100%	20	0

A baixa taxa de acerto na classificação dos danos menos agressivos pode ser atribuída à alta confusão do espaço das frequências naturais ocupadas pelas observações entre a região da estrutura não danificada e a região da estrutura danificada. Em muitos casos, os danos podem apresentar características que se assemelham às observadas em regiões com massa adicionada ou em condições normais da estrutura. Isso torna a distinção entre essas categorias mais desafiadora para o algoritmo de classificação não supervisionado, especialmente quando as diferenças entre os padrões são sutis ou não facilmente discerníveis.

Diante desse desafio, a seção seguinte apresenta uma abordagem supervisionada. Nesta abordagem, os algoritmos podem beneficiar do conhecimento prévio sobre as características distintivas de cada classe, o que pode ajudar na separação mais precisa entre os diferentes tipos de danos e outras condições estruturais.

4.6 Classificação supervisionada

4.6.1 Fundamentação inicial

O processo de classificação supervisionada começa com a coleta de um conjunto de observações rotuladas, onde cada observação é associada a uma categoria ou estado conhecido, por exemplo, "normal" ou "dano". Neste paradigma, fornecemos aos MLA uma base de observações da passagem pedonal em estudo rotulando cada conjunto de observações que compõe essa base com o estado da passagem pedonal ao qual o mesmo corresponde, nomeadamente condição normal “Normal”, condição de sobrecarga “massa” ou condição danificada “Dano”, tal como resumido no Quadro 8, permitindo que o modelo aprenda as relações intrínsecas entre essas variáveis, refinando a análise da classificação não supervisionada através da presença de mais que duas classes.

Quadro 8 Frequências médias na base de treino de um algoritmo supervisionado

F1 (Hz)	F2 (Hz)	F3 (Hz)	Rótulos	Rótulos Específicos
3,753	8,057	13,355	Normal	Normal
3,853	8,179	13,305	Massa	Massa100
3,665	7,965	13,517	Dano	Dano30

Após o treino, o modelo pode ser aplicado a novas observações não rotuladas para prever o estado da estrutura. Por exemplo, ao analisar novas observações coletadas da passagem pedonal, o modelo pode identificar e classificar as condições como pertencentes a categorias previamente definidas. O sucesso do classificador depende da representatividade da base de treino, da escolha apropriada do algoritmo de aprendizagem de máquina e da capacidade de generalização para condições reais da estrutura.

4.6.2 Metodologia

Na etapa inicial, a estratégia de classificação supervisionada será instrumentalizada utilizando os algoritmos de MLA, *Support Vector Machine* (SVM), *Nearest Neighbour* (KNN), *Quadratic Discriminant* (QD), *Decision Trees* (DT), *Ensemble Classification* (ENS), *Naive Bayes* (NB) e *Artificial Neural Network* (ANN), para analisar os dados e construir modelos preditivos. Segundo Cortes e Vapnik, (1995), que introduziram formalmente o conceito de SVM, "a ideia principal do SVM é maximizar a margem entre classes, o que resulta em uma melhor capacidade de generalização, particularmente em espaços de alta dimensionalidade". Essa abordagem robusta à separação de classes faz do SVM um dos

algoritmos de escolha para muitas aplicações práticas, como deteção de falhas, classificação de imagens e reconhecimento de padrões. O KNN é um método não paramétrico baseado na classificação por vizinhos mais próximos, amplamente usado em reconhecimento de padrões e deteção de anomalias (Altman, 1992). O QDA assume distribuições Gaussianas com diferentes covariâncias para cada classe, útil em problemas de classificação com variâncias distintas (Hastie et al., 2009). As DT segmentam os dados com base em condições de atributo, sendo comuns em análise exploratória (Quinlan, 1986). O ENS combina múltiplos MLA para obter previsões e reduzir o sobreajuste (Breiman, 2001). O NB aplica o teorema de Bayes com suposições de independência condicional, eficiente em classificação de texto e filtragem de spam (Maron & Moore, 1993). As ANN, inspiradas no cérebro humano, são treinadas para reconhecer padrões complexos, aplicáveis em reconhecimento de imagem e previsão de series temporais (Lecun et al., 2015).

O Quadro 9 sintetiza a composição do conjunto total de dados, organizados por condição, quantidade, metodologia empregada e rótulo correspondente. O conjunto total inclui 858 observações, que englobam tanto metodologias experimentais quanto numéricas, refletindo na abordagem híbrida.

Quadro 9 Composição total de observações de entrada

Condição	Quantidade	Metodologia	Rótulo
Normal	105	Experimental	Normal
Massa	426	Numérico	Massa
Dano	327	Numérico	Dano
Conjunto total	858	Híbrido	-

A Figura 4.15 representa a unificação dos três conjuntos utilizados como dados de entrada. A distribuição em cada conjunto de dados torna-se evidente, permitindo analisar e compreender o desempenho dos algoritmos durante o teste, identificando sua capacidade de reconhecer corretamente os padrões e informações exatas presentes nos dados, ou, ao contrário, de se confundir nas interseções dos conjuntos.




Figura 4.15 Unificação de observações no espaço das duas primeiras frequências naturais de vibração

A discretização das observações de entrada foi essencial para aprimorar a clareza na compreensão dos conjuntos. Em particular, cada conjunto Massa e Dano é composto por subconjuntos, conforme foi apresentado no Quadro 5. Dessa maneira, temos três subconjuntos para danos e quatro subconjuntos para a massa, como ilustram a Figura 4.16 e a Figura 4.17. Essa abordagem de subdivisão permite uma análise mais granular e específica dos diferentes estados da estrutura, contribuindo para uma interpretação mais refinada dos padrões de resposta dos algoritmos.

Na Figura 4.16 Observações da condição danificada, discriminadas por três subconjuntos de dano observa-se que os dados associados aos danos de menor magnitude (Dano 10 e Dano 20) apresentam maior sobreposição entre si, o que pode gerar dificuldades na distinção precisa entre essas classes. Em contraste, os dados relativos ao Dano 30 apresentam uma dispersão mais ampla e uma separação mais evidente.




Figura 4.16 Observações da condição danificada, discriminadas por três subconjuntos de dano




Figura 4.17 Observações da condição com adição de massa, discriminadas por quatro subconjuntos de massa

Para a categoria condição de sobrecarga através da adição de massa (Figura 4.17), observa-se uma sobreposição significativa entre todos os subconjuntos, indicando uma relevante interseção de observações numa área específica. Isso implica que existe uma considerável similaridade nos padrões de resposta dos algoritmos para diferentes massas adicionadas à estrutura. O entendimento dessas interseções é fundamental para a análise do desempenho dos MLA. Esta zona também demonstra um ponto de conflito para caracterização das observações de teste, tendo por base que o conjunto da estrutura normal está, também, sobreposto por todo o conjunto de massa (Figura 4.15).

4.6.3 Resultados

Para esta etapa, as observações de entrada para treino e teste foram previamente definidas. Foram reservadas 261 observações para o treino, distribuídas de forma igualitária entre o conjunto normal, a massa de 100 pessoas e o dano de 30 cm. O Quadro 10 apresenta as observações de entrada utilizadas nessa fase.

Quadro 10 Composição das observações de treino e de teste

Condição	Quantidade	Metodologia	Rótulo
Base de treino			
Normal	85	Experimental	Normal
Massa 100	87	Numérico	Massa
Dano 30	89	Numérico	Dano
Base de teste			
Normal	20	Experimental	Normal
Massa25	106	Numérico	Massa
Massa 50	108	Numérico	Massa
Massa 75	105	Numérico	Massa
Massa 100	20	Numérico	Massa
Dano 10	109	Numérico	Dano
Dano 20	109	Numérico	Dano
Dano 30	20	Numérico	Dano

A Figura 4.18 apresenta a configuração das observações utilizadas como base de treino, com o objetivo de verificar o quão eficazes os MLA seriam no diagnóstico. Essa escolha se justifica pela necessidade de manter uma densidade de observações mais ou menos constante em todos os *clusters* de treino (Bud et al., 2022).




Figura 4.18 Observações da base de treino

No processo de classificação de uma nova observação, qualquer um dos MLA atribui notas (scores) a cada condição estrutural. Essas notas são maiores se a probabilidade da nova observação pertencer a respetiva condição estrutural, for grande e baixas, caso contrário. No entanto, as notas não refletem diretamente probabilidades matemáticas e podem ser muito diferentes para uma determinada observação, dependendo do MLA utilizado. Para mitigar essas diferenças, as notas atribuídas por cada MLA foram escaladas entre zero e um, sendo que cada observação tem classificação unitária na categoria à qual é mais provável que pertença. Como as notas relativas a categorias diferentes podem estar muito próxima da unidade, sobretudo devido às sobreposições das diversas condições estruturais no espaço das frequências, parece fazer sentido definir um limiar de nota (*threshold*) acima do qual é considerado provável que uma nova observação de teste seja enquadrada em mais do que uma categoria, se a nota correspondente for suficientemente alta.

O limiar de classificação é, portanto, o parâmetro que define o ponto de decisão para atribuir uma observação a uma classe específica com base nas pontuações ou probabilidades preditas. Um limiar mais baixo aumenta a sensibilidade do modelo, reduzindo a probabilidade de falsos negativos, mas pode elevar a ocorrência de falsos positivos. Por outro lado, um limiar mais alto favorece a precisão, garantindo maior confiança nas classificações positivas, mas pode resultar em um aumento de falsos negativos. A escolha do limiar ideal depende do objetivo do problema e do equilíbrio desejado entre sensibilidade e precisão. Neste trabalho, o limiar foi definido em 0.90.

O Quadro 11 apresenta a taxa de precisão dos diferentes MLA apresentados em três categorias distintas: Normal, Massa e Dano. Essa taxa é definida pelo quantitativo de acertos que o algoritmo obteve. Os algoritmos variam significativamente em desempenho em cada uma dessas classes, por exemplo, o SVM se destaca na classificação da classe Massa, com uma precisão de 89,38%, enquanto obtém um desempenho modesto em Normal (20%) e razoável em Dano (44,96%). Já o KNN tem uma performance equilibrada, mas inferior, com 55% em Normal e 53,98% em Massa, sendo menos eficaz para a categoria Dano (31,09%). Por outro lado, o algoritmo ENS mostra-se mais equilibrado para em todas as classes, especialmente em Normal com 80% de precisão e um desempenho decente em Massa (72,57%) e Dano (32,77%).

Quadro 11 Taxa de precisão por categoria

Algoritmo	Normal	Massa	Dano
SVM	20,00 %	89,38 %	44,96 %
KNN	55,00 %	53,98 %	31,09 %
QD	65,00 %	57,23 %	28,99 %
DT	50,00 %	53,39 %	27,31 %
ENS	80,00 %	72,57 %	32,77 %
NB	65,00 %	57,52 %	30,25 %
ANN	45,00 %	69,32 %	32,35 %

Esses resultados indicam que cada MLA tem uma afinidade por determinadas classes, sendo o ENS o mais equilibrado em termos de taxa de precisão geral, enquanto o SVM é o mais eficaz na classe Massa. Essa variação de desempenho entre os algoritmos mostra a importância de escolher o método correto dependendo do contexto e da classe de interesse.

A estrutura está sujeita a uma alta variabilidade de condições, o que reflete a complexidade do seu comportamento em diferentes cenários. A decisão de adotar a configuração de apenas três categorias para representar essas condições, embora proporcione uma abordagem mais simplificada, exige uma análise cuidadosa quanto às implicações dessa decisão na interpretação dos resultados. A visualização conjunta de diversas situações sob um único rótulo pode obscurecer padrões específicos relacionados a cada estado da estrutura. Nesse aspeto, o Quadro 12 apresenta os resultados de cada categoria dentro dos rótulos (normal, massa e dano) detalhadamente.

Quadro 12 Taxa de precisão por categorias detalhadas

Algoritmo	Normal	Massa100	Massa75	Massa50	Massa25	Dano30	Dano20	Dano10
SVM	20,00 %	80,00 %	91,43 %	92,59 %	85,85 %	100,00 %	57,80 %	22,02 %
KNN	55,00 %	45,00 %	56,19 %	53,70 %	53,77 %	85,00 %	36,70 %	15,60 %
QD	65,00 %	50,00 %	66,67 %	58,33 %	48,11 %	100,00 %	36,70 %	8,26 %
DT	50,00 %	55,00 %	59,05 %	53,70 %	47,17 %	100,00 %	32,11 %	9,17 %
ENS	80,00 %	80,00 %	72,38 %	71,30 %	72,64 %	100,00 %	41,28 %	11,93 %
NB	65,00 %	55,00 %	62,86 %	59,26 %	50,94 %	100,00 %	37,61 %	10,09 %
ANN	45,00 %	65,00 %	80,00 %	67,59 %	61,32 %	100,00 %	40,37 %	11,93 %

Nesta configuração, notavelmente, os MLA demonstram que danos reduzidos podem ser facilmente confundidos por outras categorias, o que reflete na baixa taxa de acerto de todos os MLA em observações das tipologias Dano 10 e Dano 20. Em danos com agressividade maior obtêm-se taxas de acerto de 100%.

Uma análise mais pormenorizada poderá distinguir entre classificações com nota máxima (unitária) e classificações com nota superior ao limiar, mas não a mais alta. Assim, é preciso definir classificações corretas, aceitáveis e incorretas: uma classificação é considerada correta quando o modelo atribui à observação o rótulo exato correspondente à classe verdadeira com alta confiança, representada por uma nota unitária. Já uma classificação é dita aceitável quando o rótulo correto não possui a maior nota, mas ainda superior ao limiar de confiança, indicando que o modelo está parcialmente alinhado à classe verdadeira. Por outro lado, uma classificação é considerada incorreta quando o modelo atribui um rótulo que não corresponde à classe verdadeira, nem atende aos critérios estabelecidos para ser considerada aceitável.

O Quadro 13 apresenta o número de classificações corretas, aceitáveis e incorretas para cada MLA nas diferentes categorias detalhadas de observações (Normal, Massa100, etc.). Observa-se que o SVM, por exemplo, apresentou uma baixa quantidade de classificações corretas para os dados Normais (0), mas obteve melhores resultados para Massa100, com 12 classificações corretas e quatro aceitáveis. Em contraste, o algoritmo KNN, apesar de mostrar um bom desempenho em observações normais, teve dificuldades nas observações de Massa100, com nove classificações corretas e 11 incorretas.

Quadro 13 Taxa de aceitabilidade

Algoritmo:	SVM			KNN			QD		
	Correta	Aceitável	Incorreta	Correta	Aceitável	Incorreta	Correta	Aceitável	Incorreta
Normal	0	4	16	11	0	9	11	2	7
Massa100	12	4	4	9	0	11	7	3	10
Massa75	79	17	9	59	0	46	56	14	35
Massa50	82	18	8	58	0	50	51	12	45
Massa25	80	11	15	57	0	49	40	11	55
Dano30	18	2	0	17	0	3	20	0	0
Dano20	46	17	46	40	0	69	39	1	69
Dano10	13	11	85	17	0	92	9	0	100
Algoritmo:	DT			ENS			NB		
	Correta	Aceitável	Incorreta	Correta	Aceitável	Incorreta	Correta	Aceitável	Incorreta
Normal	10	0	10	9	7	4	9	4	7
Massa100	11	0	9	14	2	4	8	3	9
Massa75	62	0	43	53	23	29	58	8	39
Massa50	58	0	50	54	23	31	54	10	44
Massa25	50	0	56	57	20	29	45	9	52
Dano30	20	0	0	19	1	0	19	1	0
Dano20	35	0	74	44	1	64	38	3	68
Dano10	10	0	99	13	0	96	11	0	98
Algoritmo:	ANN								
	Correta	Incorreta	Aceitável						
Normal	8	1	11						
Massa100	10	3	7						
Massa75	75	9	21						
Massa50	63	10	35						
Massa25	49	16	41						
Dano30	20	0	0						
Dano20	43	1	65						
Dano10	12	1	96						

O Quadro 14 apresenta uma comparação das taxas de sucesso das classificações relativas (incluindo as classificações corretas e aceitáveis) e absolutas (incluindo apenas as classificações corretas) para as categorias, destacando as diferenças no desempenho do modelo de classificação. Para efeitos didáticos, o algoritmo ENS foi escolhido para instrumentalizar a discussão que se segue.


Observa-se que, para a categoria "Normal", a taxa de sucesso relativa é de 80.00%, enquanto a taxa absoluta cai para 45.00%, indicando uma significativa diminuição na precisão quando avaliada de forma mais rigorosa. As subcategorias de "Massa" também mostram uma redução substancial nas taxas de sucesso absolutas em comparação com as relativas, com "Massa100" passando de 75.00% para 65.00% e "Massa25" de 76.15% para 55.05%. A categoria "Dano" apresenta uma ligeira consistência, com "Dano30" mantendo uma alta precisão de 95.00% em ambas as avaliações, enquanto "Dano10" permanece com uma baixa taxa de sucesso de 11.93%. Vale ressaltar que as diferenças observadas decorrem, da presença de observações classificadas como aceitáveis, os quais apresentam uma nota elevada, mas não o maior entre as classes preditas. Essas condições, apesar de não serem identificadas como a classificação principal, possuem uma alta relevância prática, pois indicam estados estruturais plausíveis dentro do contexto analisado. Essa classificação intermediária permite que condições limítrofes ou transicionais sejam consideradas, ampliando a compreensão sobre a variabilidade estrutural e auxiliando na identificação de padrões que poderiam ser negligenciados caso fossem tratadas apenas como classificações incorretas.

Quadro 14 Comparação das classificações relativa e absoluta


Categoria	Taxa de Sucesso Relativa (%)	Taxa de Sucesso Absoluta (%)
Normal	80,00	45,00
Massa	72,57	52,51
Dano	32,77	31,93
Categorias discretizada		
Normal	80,00	45,00
Massa100	80,00	70,00
Massa75	72,38	50,48
Massa50	71,30	50,00
Massa25	72,64	53,77
Dano30	100,00	95,00
Dano20	41,28	40,37
Dano10	11,93	11,93

Essas observações sugerem que o modelo de classificação tem um desempenho consideravelmente melhor quando avaliado em termos relativos, e revela suas limitações mais claramente sob a avaliação absoluta, por desconsiderar valores próximos ao limiar escolhido.


A Figura 4.19 apresenta uma visualização gráfica que distingue entre observações bem classificadas e mal classificadas para as categorias relacionadas na classificação relativa. A análise da figura demonstra que as categorias de dano têm uma significativa sobreposição de observações mal classificadas. Especialmente notável é a confusão entre "Dano10" e "Dano20", onde a separação é menos clara, refletindo a dificuldade do modelo em diferenciar entre as diferentes categorias.



a) Observações normais



b) Observações com acréscimos de massa



c) Observações com dano

Figura 4.19 Observações bem e mal classificadas pelo algoritmo ENS

A Figura 4.20 demonstra a classificação das observações nas três categorias principais (normal, massa e dano), utilizando o modelo ENS. Os pontos verdes indicam observações bem classificadas e os pontos vermelhos as mal classificadas. Nota-se uma significativa sobreposição entre as regiões normal e massa, evidenciando a dificuldade do modelo em distinguir essas condições em zonas de transição. Por outro lado, na região associada ao dano, quanto mais agressivo, maior separação, embora alguns erros ainda estejam presentes. Essa sobreposição reflete a variabilidade das condições estruturais e ressalta a necessidade de avaliar cuidadosamente os critérios de classificação e considerar ajustes no modelo para melhorar a precisão nas fronteiras entre categorias. A visualização dos subconjuntos, como representado anteriormente na Figura 4.16 e na Figura 4.17, proporciona uma compreensão mais detalhada sobre as razões por trás dessas classificações equivocadas.




Figura 4.20 Classificações corretas e incorretas utilizando o algoritmo ENS

Na presente análise, é possível observar uma região com muita sobreposição de observações entre as diferentes classes. Essa sobreposição implica que as observações pertencentes a diferentes categorias, compartilham características semelhantes em certas faixas de frequência, dificultando a tarefa de distinção clara entre essas classes. Para abordar

esse problema, as observações foram divididas em combinações específicas para o cálculo das matrizes de confusão, a fim de identificar as áreas onde ocorrem os erros mais frequentes.

As matrizes de confusão fornecem uma visão detalhada sobre como um modelo está classificando as observações em diferentes categorias, permitindo identificar a taxa de acerto e caracterizar os erros cometidos. Foram adotadas quatro configurações distintas que serão descritas a seguir para a análise das observações. Foram escolhidas para representar diferentes condições estruturais e níveis progressivos de severidade de dano e por fim a matriz de confusão consolidada, permitindo a avaliação do desempenho do modelo de classificação.

O Quadro 15 apresenta a matriz de confusão que abrange a seguinte configuração: "Normal", "Massa25" e "Dano10". A matriz evidencia os desafios enfrentados pelo modelo. Para a classe "Normal", 16 observações foram corretamente identificadas, mas quatro foram confundidas com "Massa25", o que sugere sobreposição entre essas condições. A classe "Massa25" apresentou a maior taxa de acertos, com 77 observações corretamente classificadas, embora 27 tenham sido atribuídas incorretamente à classe "Normal" e duas à classe "Dano10", refletindo dificuldades do modelo em distinguir estados intermediários. Por fim, a classe "Dano10" teve apenas 13 observações classificadas corretamente, enquanto 48 foram confundidas com "Normal" e outras 48 com "Massa25", evidenciando a maior dificuldade do modelo em identificar níveis de dano menos severos. Esses resultados destacam a necessidade de ajustes no modelo para reduzir a confusão entre as classes e melhorar a precisão geral do processo de classificação.

Quadro 15 Matriz confusão configuração 1

	Prevista: Normal	Prevista: Massa25	Prevista: Dano10
Real: Normal	16	4	0
Real: Massa25	27	77	2
Real: Dano10	48	48	13

A segunda matriz de confusão aborda as classes "Normal", "Massa50" e "Dano20" e é apresentada no Quadro 16. Os dados mostram que a classe "Massa50" teve 77 acertos, mas apresentou confusões significativas, com 27 amostras classificadas como "Normal" e quatro como "Dano20". Já na categoria "Dano20", houve 45 acertos, porém 28 amostras foram previstas como "Normal" e 36 como "Massa50". Esses resultados destacam que a maior dificuldade do modelo está em diferenciar entre "Massa50" e as outras classes, indicando áreas de possível aprimoramento.

Quadro 16 Matriz confusão configuração 2

	Prevista: Normal	Prevista: Massa50	Prevista: Dano20
Real: Normal	16	4	0
Real: Massa50	27	77	4
Real: Dano20	28	36	45

Por fim o Quadro 17 contempla a terceira matriz de confusão a qual introduz a configuração de "Normal", "Massa75", "Massa100" e "Dano30". A matriz de confusão revela que o modelo apresenta um desempenho sólido na identificação da classe "Dano30", evidenciando uma clara separação desta em relação às demais categorias. No entanto, as dificuldades na distinção entre "Normal" e "Massa75/100" continuam a sugerir uma sobreposição de características que interfere na precisão dessas classes. Esse cenário pode refletir limitações nas fronteiras de decisão do modelo ou na qualidade das amostras utilizadas no treino, principalmente em relação a "Massa75/100", que apresenta maior confusão com outras categorias. Os resultados indicam que, embora o modelo tenha boa capacidade de identificar padrões bem definidos, como os de "Dano30", ajustes são necessários para melhorar a discriminação nas demais classes e equilibrar o desempenho geral.

Quadro 17 Matriz confusão configuração 3

	Prevista: Normal	Prevista: Massa75/100	Prevista: Dano30
Real: Normal	16	4	0
Real: Massa75/100	27	92	6
Real: Dano30	0	0	20

Pode-se concluir que a análise das matrizes de confusão revela que, embora o modelo de classificação tenha alguns sucessos, ele enfrenta desafios significativos, especialmente na distinção entre classes específicas como "Massa25", "Dano10", "Massa50" e "Dano20".

A matriz de confusão consolidada (Quadro 18) reflete o desempenho geral do modelo na classificação sem discriminação de subcategorias. Sintetiza as observações feitas nas análises das matrizes de subcategorias abordadas anteriormente, refletindo de forma abrangente os desafios do modelo na classificação. Confirma-se a elevada confusão entre as categorias massa e normal, evidenciando a dificuldade do modelo em distinguir adequadamente entre essas classes, possivelmente devido a características compartilhadas ou fronteiras de decisão pouco claras. Além disso, reforça-se a baixa taxa de acerto nos casos

relacionados à categoria dano, com um padrão claro de confusão, especialmente em relação a danos menos agressivos, que tendem a ser classificados como massa ou até mesmo como normal.

Quadro 18 Matriz confusão consolidada

	Prevista: Normal	Prevista: Massa	Prevista: Dano
Real: Normal	16	4	0
Real: Massa	190	137	12
Real: Dano	76	92	70

Vale ressaltar que a má classificação não representa um erro intrínseco do algoritmo, mas sim destaca áreas de desafio na distinção entre os conjuntos. É fundamental interpretar essas zonas de interseção como oportunidades para refinamento do modelo, buscando aprimorar a capacidade do algoritmo em lidar com situações complexas e casos limítrofes entre os diferentes conjuntos.

4.7 Considerações finais

Foi conduzida uma análise abrangente dos resultados obtidos nas classificações não supervisionadas e supervisionadas, aplicadas aos dados híbridos que incluíram observações experimentais e numéricas, abordando diferentes estados estruturais: normal, acréscimo de massa, e simulação de dano. As metodologias empregadas e os resultados foram discutidos com profundidade para avaliar a eficácia dos MLA testados.

Os resultados das classificações não supervisionadas evidenciaram uma variabilidade considerável na precisão entre as diferentes categorias. Embora o cenário "Normal" tenha alcançado precisão perfeita, outras categorias, como "Dano10", demonstraram maior dificuldade, atingindo apenas 9,17% de precisão. Esses resultados reforçam os desafios em detetar danos através de uma abordagem não supervisionada, apontando para a necessidade de abordagens mais refinadas, ou a integração de mais observações para melhorar a aprendizagem dos algoritmos e aprimorar a deteção de anomalias.

Em contrapartida, a abordagem supervisionada revelou-se mais completa em lidar com a diversidade de cenários estruturais. As matrizes de confusão permitiram uma análise detalhada dos padrões de erro, indicando áreas onde a classificação pode ser aprimorada. Isso evidencia a importância de um ajuste cuidadoso dos parâmetros e configurações dos modelos,

para maximizar a precisão e minimizar os erros de classificação, particularmente em categorias com características mais próximas, como sobrecargas operacionais e danos iniciais.

Adicionalmente, a classificação supervisionada possibilita a atribuição de novas observações a múltiplas categorias, além de permitir a definição precisa dos limiares de separação entre elas. Essa abordagem tem o potencial de fornecer ao usuário informações mais detalhadas e confiáveis sobre as possíveis condições da estrutura em análise, contribuindo para uma compreensão mais aprofundada e assertiva do cenário avaliado.

Em síntese, os resultados deste estudo destacam os desafios e a complexidade da classificação de dados estruturais, enquanto ressaltam o potencial de soluções promissoras, como o uso do algoritmo Ensemble (ENS) com parâmetros otimizados.

Conclusão e trabalhos futuros

5.1 Conclusão

A SHM oferece uma abordagem proativa para a gestão de infraestruturas, melhorando a segurança, prolongando a vida útil das estruturas e reduzindo custos associados à manutenção. O uso de técnicas modernas torna o SHM uma ferramenta poderosa para a monitorização contínua da saúde estrutural em diversas aplicações. No entanto, as abordagens convencionais à SHM, baseadas em modelos físicos ou em reconhecimento de padrões, apresentam limitações importantes para estruturas de engenharia civil. Neste trabalho, analisa-se uma estratégia híbrida de SHM que tira partido das vantagens de cada uma dessas técnicas evitando, ao mesmo tempo, as suas desvantagens. Essa estratégia propõe a utilização de observações de monitorização para caracterizar o comportamento normal da estrutura, complementadas por observações numéricas para reproduzir o comportamento estrutural em condições atípicas, incluindo condições operacionais pouco frequentes e condições em que a estrutura apresenta dano. O caso de estudo para a aplicação dessa estratégia híbrida foi uma passagem superior pedonal, localizada no Campo Grande (Lisboa).

Inicialmente, a utilização da aplicação de telemóvel App4SHM permitiu estimar experimentalmente as frequências naturais de vibração da passagem pedonal, evidenciando a eficácia da aplicação em cenários reais. App4SHM permite a monitorização das primeiras três frequências estruturais. O seu uso ilustra como a integração de novas tecnologias permite otimizar processos e expandir as possibilidades de análise e monitorização. Do lado numérico, desenvolveram-se modelos de elementos finitos, construídos a partir de geometrias obtidas através de nuvens de pontos, que exploraram com precisão as características tridimensionais das estruturas, melhorando significativamente a fidelidade e a representação das mesmas. Os modelos foram calibrados de modo a recuperar de maneira fidedigna as características de vibração da estrutura real, bem como as respetivas covariâncias. O emprego de modelos devidamente calibrados amplia significativamente o alcance da observação experimental, superando as limitações das metodologias tradicionais. Este processo de calibração que apresentou eficácia máxima, reduzindo o a taxa de erro a zero, possibilitou a incorporação eficaz de dados multidimensionais, assegurando que as simulações reproduziram com fidelidade a complexidade real da estrutura examinada. Essa precisão foi importante para a

validação do modelo como uma representação fidedigna da estrutura real, o que proporcionou uma base bem estruturada de observações.

Um dos grandes desafios colocados à SHM na área da engenharia civil é monitorizar a estrutura física em condições abrangendo desde o seu estado normal de utilização até seu estado limite último. A dificuldade reside no fato de que danificar intencionalmente uma estrutura para possibilitar avaliações é impraticável. Nesse sentido, o uso de modelos numéricos ganha protagonismo ao permitir a simulação eficaz de diversas condições na estrutura, garantindo uma avaliação mais completa sem a necessidade de introdução de danos reais na estrutura e até mesmo de situações de utilização, nomeadamente os acréscimos de carga. No presente estudo, foram modeladas sete situações anómalas, envolvendo quatro níveis de acréscimo de massa (correspondendo a 25, 50, 75 e 100 pessoas) e três níveis de gravidade de dano. Os modelos foram sujeitos a extensão probabilística, utilizando as covariâncias das frequências próprias de vibração observadas nos dados medidos na estrutura real.

A base de dados de frequências (consideradas como características estruturais sensíveis a danos) assim obtida foi utilizada para treinar algoritmos de aprendizagem de máquina, nomeadamente em regime não supervisionado, para o reconhecimento de situações anómalas, e supervisionado, para a classificação das condições estruturais.

Para o treino não supervisionado, a base de dados híbrida foi dividida numa base de treino, constando de observações experimentais e numéricas da estrutura com acréscimo de 25 pessoas, e uma base de teste, constando de todas as observações não incluídas na base de treino, de todas as tipologias. Para o treino não supervisionado, a base de treino constou de observações experimentais, observações numéricas com acréscimo de 100 pessoas e observações numéricas da estrutura com o maior nível de dano.

A comparação entre os métodos supervisionados e não supervisionados revelou diferenças importantes em termos de desempenho na deteção de danos estruturais. Os métodos supervisionados, demonstraram uma maior precisão e confiabilidade ao reconhecer padrões específicos em diferentes condições da estrutura, como sobrecarga e simulações de danos controlados. O algoritmo *Ensemble*, por exemplo, apresentou resultados consistentemente melhores, com alta acurácia em diversas categorias, destacando-se como uma abordagem eficaz e adaptável. Por outro lado, os métodos não supervisionados mostraram limitações na identificação de padrões mais sutis. Embora se tenham mostrado úteis para detetar a falta de anomalias nas condições estruturais normais, com base nas quais

foram treinados, eles enfrentaram dificuldades significativas em distinguir condições estruturais diferentes das normais, mas com grandes sobreposições de frequências às frequências resultantes da condição normal, como por exemplo o menor nível de dano, onde a taxa de precisão foi muito baixa, de apenas 9,17%. Esse tipo de confusão pode levar a falsas deteções de danos ou à falta de identificação de problemas reais, o que compromete a precisão da análise.

Essa diferença de desempenho entre os dois regimes evidencia a vantagem dos métodos supervisionados. Quando os modelos são treinados com informações claras e rotuladas, eles conseguem diferenciar melhor entre estados normais, sobrecargas temporárias e danos estruturais, oferecendo uma análise mais precisa e confiável. Isso é crucial para garantir a segurança e a manutenção preventiva das estruturas monitorizadas, onde a identificação correta de danos pode fazer a diferença entre um reparo simples e a prevenção de falhas graves.

As matrizes de confusão geradas permitiram uma melhor compreensão dos padrões de erro dos modelos, identificando áreas específicas que necessitam de melhorias. As configurações que apresentaram maior precisão confirmam a importância do ajuste fino dos parâmetros para melhorar o desempenho dos modelos, tanto na classificação não supervisionada (por exemplo, a probabilidade de falso alarme), como na classificação supervisionada (método de classificação e os seus hiper-parâmetros).

Esta dissertação impulsiona o avanço teórico no campo de monitorização estrutural, abrindo novas perspetivas práticas para a engenharia civil. O uso de MLA, em colaboração com modelos numéricos e calibração precisa, emerge como uma ferramenta vital para compreender e monitorizar continuamente as estruturas, promovendo um avanço significativo na segurança e eficiência das infraestruturas civis. Vale ressaltar que, embora este estudo tenha utilizado as frequências naturais como uma característica sensível para a deteção de danos, os algoritmos têm a capacidade de empregar outras características para gerar alertas, potencialmente aprimorando seu desempenho.

Por fim, todos os códigos MATLAB utilizados neste trabalho estão disponíveis para download no seguinte link: <https://11nk.dev/TtCaF>. Estes recursos permitem a replicação e a extensão do estudo, incentivando a continuidade da pesquisa e a inovação no campo do SHM.

5.2 Trabalhos futuros

Este capítulo explora possíveis áreas para pesquisas futuras, buscando expandir o conhecimento adquirido nesta dissertação e abordar desafios ainda não completamente explorados. Em relação às perspetivas para investigações futuras, o presente trabalho na dissertação sugere as seguintes direções de desenvolvimento:

- Avaliação da Influência de Diferentes Dispositivos Móveis na Precisão dos Resultados de Monitorização Estrutural de Pontes

Este estudo investigaria como as especificações técnicas de diferentes telemóveis influenciam a precisão dos dados na monitorização estrutural, avaliando sensores, frequência de amostragem e processamento. A análise comparativa em um caso real abordaria deteção de vibrações, identificação de anomalias e compatibilidade com algoritmos, fornecendo subsídios para padronização e otimização do uso de telemóveis na engenharia civil

- Exploração de Características Múltiplas para Aprimoramento do Desempenho de Algoritmos na Deteção de Danos Estruturais

Este projeto de pesquisa propõe investigar o uso de múltiplas características estruturais sensíveis a danos, além das frequências naturais, como as formas próprias de vibração e a amplitude de resposta, para aprimorar a eficácia dos algoritmos de deteção de danos em estruturas.

- Avaliação da Validade e Robustez de Modelos de Aprendizagem de Máquina Supervisionados: Uma Análise Sistemática da Quantidade Ótima de Observações para Modelos Eficazes em Monitorização Estrutural

O tema proposto visa conduzir uma investigação aprofundada sobre a validação de MLA supervisionados no contexto da monitorização estrutural. O foco principal será determinar a quantidade ideal de observações necessárias para assegurar a eficácia desses modelos. A pesquisa pretende realizar uma análise sistemática, considerando diferentes cenários e condições, para identificar a quantidade ótima de observações que garanta a fidelização dos modelos no processo de monitorização estrutural. Ao abordar essa questão crítica, a pesquisa visa contribuir para a otimização do uso desses algoritmos, promovendo assim avanços significativos na eficácia e aplicabilidade dessas ferramentas na engenharia civil.

- Avaliação do Impacto Económico

Realizar estudos mais aprofundados sobre o impacto económico das estratégias de monitorização propostas pode ser crucial para a aceitação generalizada dessas abordagens. Essa avaliação incluiria análises de custo-benefício e considerações sobre a sustentabilidade económica a longo prazo.

- Investigação de Tecnologias Emergentes

Ficar atento às tecnologias emergentes, como inteligência artificial quântica e computação quântica, pode abrir novas possibilidades para a monitorização estrutural. Essas tecnologias podem oferecer capacidades de processamento mais rápidas e avançadas, contribuindo para uma análise mais eficiente de dados complexos.

A concretização dessas perspetivas futuras pode consolidar ainda mais o campo do SHM, proporcionando avanços significativos em direção a estruturas mais seguras e sustentáveis.

Bibliografia

- Afkham, B. M., Chung, J., & Chung, M. (2021). *Learning regularization parameters of inverse problems via deep neural networks*. arXiv. <http://arxiv.org/abs/2104.06594>
- Altman, N. S. (1992). *An introduction to kernel and nearest-neighbor nonparametric regression*. *The American Statistician*, 46(3), 175–185. <https://doi.org/10.1080/00031305.1992.10475879>
- Ballesteros, R., Ortega, J. F., Hernández, D., & Moreno, M. Á. (2015). *Characterization of Vitis vinifera L. Canopy Using Unmanned Aerial Vehicle-Based Remote Sensing and Photogrammetry Techniques*. *American Journal of Enology and Viticulture*, 66(2), 120–129. <https://doi.org/10.5344/ajev.2014.14070>
- Breiman, L. (2001). *Random Forests*. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Bud, M. A., Moldovan, I., Radu, L., Nedelcu, M., & Figueiredo, E. (2022). *Reliability of probabilistic numerical data for training machine learning algorithms to detect damage in bridges*. *Structural Control and Health Monitoring*, 29(7), e2950. <https://doi.org/10.1002/stc.2950>
- Castro, C. M., Peixoto, M. N. O., & Pires do Rio, G. A. (2005). Riscos ambientais e geografia: Conceituações, abordagens e escalas. *Anuário do Instituto de Geociências*, 28(2), 11–30. https://doi.org/10.11137/2005_2_11-30
- Cawley, P. (2018). *Structural health monitoring: Closing the gap between research and industrial deployment*. *Structural Health Monitoring*, 17(5), 1225–1244. <https://doi.org/10.1177/1475921717750047>
- Civil Research Group. (2024). *Civil Research Group*. <https://civilresearchgroup.ulusofona.pt/structural-health-monitoring/>
- Cortes, C., & Vapnik, V. (1995). *Support-vector networks*. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Credo, S. (1987). *Structural Assessment*. Butterworth-Heinemann, Londres, Reino Unido. ISBN: 978-0-419-22490-7
- Diário de Notícias. (2021). Entre-os-Rios/20 anos. Memória de uma ponte que se desfez e ceifou 59 vidas. Disponível em: <https://dn.pt/sociedade/entre-os-rios20-anos-memoria-de-uma-ponte-que-se-desfez-e-ceifou-59-vidas--13407433.html>

- Doebling, S., Farrar, C., Prime, M., & Shevitz, D. (1996). *Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in Their Vibration Characteristics*. Los Alamos National Laboratory Report, LA-13070-MS. <https://doi.org/10.2172/249299>
- Farrar, C., Sohn, H., & Doebling, S. W. (2000). *Structural Health Monitoring at Los Alamos National Laboratory. Proceedings of the US-Korea Conference on Science, Technology, Entrepreneurship, and Leadership, Chicago, IL, 2-5 de September de 2000*. Relatório Técnico LA-UR-00-3202, Los Alamos National Laboratory
- Farrar, C., & Worden, K. (2013). *Structural Health Monitoring a Machine Learning Perspective*. Wiley. <https://doi.org/10.1002/9781118443118>
- Feng, M., Fukuda, Y., Mizuta, M., & Ozer, E. (2015). *Citizen Sensors For SHM: Use of Accelerometer Data from Smartphones*. *Sensors* 15(2), 2980–2998. <https://doi.org/10.3390/s150202980>
- Figueiredo, E. (2010). *Damage Identification in Civil Engineering Infrastructure Under Operational and Environmental Conditions*. PhD Thesis, University of Minho, Portugal. <https://hdl.handle.net/10216/58566>
- Figueiredo, E., Alves, P., Moldvan, I., Rebelo, H., Silva, L., Souza, L., Lopes, R., Oliveira, P., & Penim, N. (2023). App4SHM – Smartphone Application for Structural Health Monitoring. *Lecture Notes in Civil Engineering*, 270 LNCE, 1034–1043. https://doi.org/10.1007/978-3-031-07322-9_105
- Figueiredo, E., Moldovan, I., & Barata, M. (2013). *Condition assessment of bridges: Past, present and future – A complementary approach*. Universidade Católica Editora.
- Figueiredo, E., Moldovan, I., Alves, P., Rebelo, H., & Souza, L. (2022). *Smartphone Application for Structural Health Monitoring of Bridges*. *Sensors*, 22(21), 8483. <https://doi.org/10.3390/s22218483>
- Friswell, M. I. (2007). *Damage Identification Using Inverse Methods*. *Em Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 365(1851), 393–410. <https://doi.org/10.1098/rsta.2006.1930>
- Gammaconsult. (2000). *Ponte Pedonal – Memória Descritiva e Cálculos Justificativos*. Relatório Técnico. Lisboa, Portugal: Gammaconsult Engenharia.
- Google. (2005). Google Maps. <https://www.google.com/maps/place/Campo+Grande,+Lisboa/@38.7574195,->

9.1531519,126m/data=!3m1!1e3!4m5!3m4!1s0xd1932fd55dd3227:0x500ebbde4904130!8m2!3d38.7511573!4d-9.1539178

Guerreiro, M. (2014). Identificação de Dano Estrutural com Base em Análise Modal. Dissertação de Mestrado. Universidade Nova de Lisboa. <https://run.unl.pt/handle/10362/14177>

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>

Johnson, R. A., & Wichern, D. W. (2002). *Applied Multivariate Statistical Analysis* (5th ed.). Prentice Hall. ISBN: 9780130925530.

Kromanis, R., Xu, Y., Lydon, D., Martinez del Rincon, J., & Al-Habaibeh, A. (2019). *Measuring Structural Deformations in The Laboratory Environment Using Smartphones*. *Frontiers in Built Environment*, 5, Article 44. <https://doi.org/10.3389/fbuil.2019.00044>

Lecun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*, 521(7553), 436– 444. <https://doi.org/10.1038/nature14539>

M. Karbhari, V., & Ansari, F. (2009). *Structural Health Monitoring of Civil Infrastructure Systems* (Elsevier Science). ISBN: 9781845693926

Malekloo, A., Ozer, E., AlHamaydeh, M., & Girolami, M. (2022). *Machine Learning and Structural Health Monitoring Overview with Emerging Technology and High-Dimensional Data Source Highlights*. *Structural Health Monitoring*, 21(4), 1906–1955. <https://doi.org/10.1177/14759217211036880>

Manson, G., Worden, K., & Allman, D. (2003). *Experimental Validation of a Structural Health Monitoring Methodology: Part II. Novelty Detection on A Gnat Aircraft*. *Journal of Sound and Vibration*, 259(2), 345–363. <https://doi.org/10.1006/jsvi.2002.5167>

Maron, O., & Moore, A. W. (1993). *Hoeffding Races: Accelerating Model Selection Search for Classification and Function Approximation*. In J. D. Cowan, G. Tesauro, & J. Alspector (Eds.), *Advances in Neural Information Processing Systems 6* (59–66). Morgan Kaufmann Publishers. <https://proceedings.neurips.cc/paper/1993/file/02a32ad2669e6fe298e607fe7cc0e1a0-Paper.pdf>

Mishra, M., Lourenço, P. B., & Ramana, G. V. (2022). *Structural Health Monitoring of Civil Engineering Structures by Using the Internet of Things: A Review*. *Journal of Building Engineering*, 48, 103954. <https://doi.org/10.1016/J.JOBE.2021.103954>

- Mitre, M. P. (2005). *Metodologia para Inspeção e Diagnóstico de Pontes e Viadutos de Concreto*. São Paulo, Brasil: Editora Pini. ISBN: 978-85-7266-002-9.
- Morais, J. D. A. (2020). *Monitorização da Integridade de Estruturas com Recurso a Data Analytics*. Dissertação de Mestrado, Universidade do Minho, Escola de Engenharia, Guimarães, Portugal.
- Neves, C. (2020). *Structural Health Monitoring of Bridges: Data-Based Damage Detection Method Using Machine Learning*. Master's Thesis, University of Minho, School of Engineering, Guimarães, Portugal.
- Ozer, E., Feng, M. Q., & Feng, D. (2015). *Citizen Sensors For SHM: Towards A Crowdsourcing Platform*. *Sensors* 15(6), 14591–14614. <https://doi.org/10.3390/s150614591>
- Peck, R., & Devore, J. L. (2012). *The Exploration and Analysis of Data (7th ed.)*. Cengage Learning, Boston, MA, USA. ISBN: 978-0-8400-5801-0.
- Poças, R. (2009). *Gestão do Ciclo de Vida de Pontes*. Dissertação de Mestrado, Faculdade de Engenharia, Universidade do Porto, Porto, Portugal.
- Quinlan, J. R. (1986). *Induction of Decision Trees*. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1023/A:1022643204877>
- Ramos, H. (2010). *Manutenção de Sistemas Hidráulicos Prediais - Manual de Intervenção Preventiva*. Dissertação de Mestrado, Faculdade de Engenharia, Universidade do Porto, Porto, Portugal. Disponível em: <https://hdl.handle.net/10216/61192>
- Rytter, A. (1993). *Vibrational Based Inspection of Civil Engineering Structures*. PhD Thesis, Department of Building Technology and Structural Engineering, Aalborg University, Aalborg, Denmark. Disponível em: <https://vbn.aau.dk/en/publications/vibrational-based-inspection-of-civil-engineering-structures>
- Salawu, O. S. (1997). *Detection of Structural Damage through Changes in Frequency: A Review*. *Engineering Structures*, 19(9), 718–723. [https://doi.org/10.1016/S0141-0296\(96\)00149-6](https://doi.org/10.1016/S0141-0296(96)00149-6)
- Santos, L. O., Min, X., Santos, C., Vieira, T., & Roma, J. (2016). *Monitorização da Integridade Estrutural do Viaduto Salah Bey em Constantine, na Argélia*. *Revista de Engenharia Estrutural*, 12(4), 45–60.
- Senatov, F. S., Niaza, K. V., Zadorozhnyy, M. Y., Maksimkin, A. V., Kaloshkin, S. D., & Estrin, Y. Z. (2016). *Mechanical Properties and Shape Memory Effect of 3D-printed PLA-based*

Porous Scaffolds. Journal of the Mechanical Behavior of Biomedical Materials, 57, 139–148. <https://doi.org/10.1016/J.JMBBM.2015.11.036>

Singh, T., Sehgal, S., Prakash, C., & Dixit, S. (2022). *Real-Time Structural Health Monitoring and Damage Identification Using Frequency Response Functions along with Finite Element Model Updating Technique. Sensors*, 22(12), Article 4546. <https://doi.org/10.3390/s22124546>

Tavares, B. D. D. (2021). *Desenvolvimento e Análise do Comportamento de um Modelo Laboratorial para a Implementação de um Sistema SHM. Dissertação de Mestrado, Universidade Nova de Lisboa, Faculdade de Ciências e Tecnologia, Lisboa, Portugal.*

Webb, A. R. (2002). *Statistical Pattern Recognition (2nd ed.)*. Chichester, UK: Wiley. ISBN: 978-0470845142.

Worden, K., & Dulieu-Barton, J. M. (2004). An Overview Of Intelligent Fault Detection In Systems And Structures. *Structural Health Monitoring*, 3(1), 85–98. <https://doi.org/10.1177/1475921704041866>

Yuan, F.-G., Zargar, S. A., Chen, Q., & Wang, S. (2020). *Machine Learning for Structural Health Monitoring: Challenges and Opportunities. In Proceedings of SPIE Smart Structures and Materials + Nondestructive Evaluation and Health Monitoring 2020, Vol. 11379, Article 113791G*. <https://doi.org/10.1117/12.2561610>

Zhao, X., Han, R., & Ding, Y. (2015). *Portable and Convenient Cable Force Measurement Using Smartphone. Journal of Civil Structural Health Monitoring*, 5(5), 655–664. <https://doi.org/10.1007/s13349-015-0132-9>

Zhao, X., Ri, K., Han, R., Yu, Y., Li, M., & Ou, J. (2016). *Experimental Research on Quick Structural Health Monitoring Technique for Bridges Using Smartphone. Advances in Materials Science and Engineering, Article 1871230*. <https://doi.org/10.1155/2016/1871230>