

UNIVERSIDADE DE BRASÍLIA – UNB
FACULDADE DE TECNOLOGIA / FACULDADE DO GAMA
PROGRAMA DE PÓS-GRADUAÇÃO EM INTEGRIDADE DE MATERIAIS DA ENGENHARIA

MONITORAMENTO DA INTEGRIDADE ESTRUTURAL DE VIGAS
UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA

AMANDA ARYDA SILVA RODRIGUES DE SOUSA

ORIENTADOR: PROF. DRA. MARCELA RODRIGUES MACHADO

UNIVERSIDADE DE BRASÍLIA – UNB
FACULDADE DE TECNOLOGIA / FACULDADE DO GAMA

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL DE VIGAS
UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA**

AMANDA ARYDA SILVA RODRIGUES DE SOUSA

ORIENTADOR: PROF. DRA. MARCELA RODRIGUES MACHADO

DISSERTAÇÃO DE MESTRADO EM INTEGRIDADE DE MATERIAIS DA ENGENHARIA
PUBLICAÇÃO: 102A/2023

BRASÍLIA/DF, MARÇO DE 2023

UNIVERSIDADE DE BRASÍLIA – UNB
FACULDADE DE TECNOLOGIA / FACULDADE DO GAMA
PROGRAMA DE PÓS-GRADUAÇÃO EM INTEGRIDADE DE MATERIAIS
DA ENGENHARIA

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL DE VIGAS
UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA**

AMANDA ARYDA SILVA RODRIGUES DE SOUSA

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM INTEGRIDADE DE MATERIAIS DA ENGENHARIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE.

APROVADA POR:

PROF. DRA. MARCELA RODRIGUES MACHADO
ORIENTADOR

DR. FRANCISCO EVANGELISTA JÚNIOR
EXAMINADOR INTERNO - UNB

DR. AMERICO BARBOSA DA CUNHA JUNIOR
EXAMINADOR EXTERNO - UERJ

Relatório (ata) de defesa de dissertação assinado eletronicamente pela banca avaliadora, via Sistema Eletrônico de Informações - SEI, documento 9523272, processo 23106.029351/2023-14.

BRASÍLIA/DF, MARÇO DE 2023

FICHA CATALOGRÁFICA

SOUSA, AMANDA ARYDA SILVA RODRIGUES DE
Monitoramento da Integridade Estrutural de Vigas
utilizando Técnicas de Aprendizado de Máquina[Distrito Federal], 2023.
73p., 210 × 297 mm (FGA/UnB Gama, Mestrado em Integridade de Materiais da Engenharia,
2023).
Dissertação de Mestrado - Universidade de Brasília. Faculdade de Tecnologia.
Faculdade do Gama

1. Aprendizado de Máquina	2. Monitoramento da Integridade Estrutural
3. Detecção de Dano	4. Algoritmos de Aprendizado Supervisionado
I. ENC/FT/UnB.	II. Título (série)

REFERÊNCIA

SOUSA, AMANDA ARYDA SILVA RODRIGUES DE (2023). Monitoramento da Integridade Estrutural de Vigas utilizando Técnicas de Aprendizado de Máquina. Dissertação de mestrado em Integridade de Materiais da Engenharia, Publicação 102A/2023, Programa de Pós-Graduação, Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, 73p.

CESSÃO DE DIREITOS

AUTOR: Amanda Aryda Silva Rodrigues de Sousa

TÍTULO: Monitoramento da Integridade Estrutural de Vigas utilizando Técnicas de Aprendizado de Máquina

GRAU: Mestre

ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

eng.amandaaryda@gmail.com

Brasília, DF – Brasil

*Sabemos que todas as coisas cooperam para o bem
daqueles que amam a Deus, daqueles que são
chamados segundo o seu propósito (Romanos 8:28).*

AGRADECIMENTOS

Em primeiro lugar, quero agradecer a Deus e a minha família, em especial a minha mãe Alzira, a minha irmã Aylla e ao meu sobrinho Joaquim Neto. Muito obrigado por todo suporte, amor e carinho. Vocês são essenciais para mim e serão eternamente minha fonte de inspiração, sou muito grata por tudo que já fizeram na minha vida.

Aos meus amigos que direta ou indiretamente me apoiaram, do Maranhão e de Brasília, em especial Jefferson, Nicolas e Tomé, pelas risadas e ajuda inestimável durante esta etapa.

A minha orientadora Marcela Machado, pela ajuda e dedicação. Sua paciência e atenção foram fundamentais para o desenvolvimento desse trabalho.

A Capes pelo apoio financeiro, que foi primordial durante esses anos.

Aos Professores do GDS.

RESUMO

Danos estruturais induzem mudanças na flexibilidade local do sistema que podem gerar deslocamentos e vibrações indesejáveis. A análise estatística do recurso dinâmico da estrutura permite discriminar a condição estrutural atual e prever sua vida útil por períodos curtos ou longos. Sob condições não danificadas e danificadas, dois índices de danos(DI) construíram o conjunto de dados da frequência natural e da função de resposta de frequência(FRF), analisados em dois tipos de danos, o primeiro dano gerado numericamente através da alteração de profundidade da trinca em uma viga metálica engastada. No segundo dano gerado experimentalmente através da perda de massa de uma viga metálica engastada reforçada com massas. Como o dano influencia diretamente a vibração do sistema, o DI pode detectar danos e quantificar sua severidade. Neste trabalho, o monitoramento estrutural de vigas em balanço é realizado por algoritmos de aprendizado de máquina (ML), através da abordagem multiclasse e usando o conjunto de dados de teste, os algoritmos usados foram k-vizinhos mais próximos (kNN), Máquina de Vetor de Suporte (SVM), Árvore de Decisão (DT), Floresta Aleatória (RF) e Bayes Ingênuo (NB). Os desafios do uso dessas técnicas, desempenho e implementação de cada método são discutidos. O monitoramento estrutural realizado com o algoritmo ML alcançou excelentes métricas ao inserir o conjunto de dados gerado pela simulação, até 100%, e até 64% tendo como conjunto de dados de entrada fornecido a partir de testes experimentais. Demonstrando que o algoritmo ML pode classificar corretamente a condição de integridade da estrutura.

Palavras-chave: Aprendizado de máquina, monitoramento de integridade estrutural, detecção de danos, algoritmo de aprendizado supervisionado.

ABSTRACT

Structural damage can cause changes in a system's local flexibility, resulting in unwanted displacements and vibrations. Statistical analysis of dynamic structural features enables us to differentiate between the current structural condition and predict its lifespan for short or extended periods. Two damage indexes are used to build a dataset from the beam's natural frequency and frequency response function (FRF) under both undamaged and damaged conditions, analyzed in two types of damage, the first numerically generated damage by changing the crack depth in a cantilevered steel beam. The second experimentally generated damage through the mass loss of a cantilevered steel beam reinforced with masses. As the damage can directly impact system vibration, the DI can detect damage and measure its severity. In this work, we use machine learning (ML) algorithms, through the multiclass approach and use the test dataset, such as k-nearest neighbors (kNN), Support Vector Machine (SVM), Decision Tree (DT), Random Forest (RF), and Naïve Bayes (NB), to monitor the structural integrity of a cantilevered beam. We discuss the challenges of using, performing, and implementing each method. The structural monitoring performed with the ML algorithm achieved excellent metrics when inputting the simulation-generated dataset, up to 100%, and up to 64% having as input dataset provided from experimental tests. Demonstrating that the ML algorithm could correctly classify the health condition of the structure.

Keywords: Machine learning, Structural Health Monitoring, Damage detection, Supervised learning algorithm.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Contextualização e Motivação	1
1.2	Técnicas de Monitoramento da Integridade Estrutural	2
1.3	Metodologia	5
1.4	Objetivos	6
1.4.1	Objetivos Específicos	7
1.5	Estrutura do Trabalho	7
2	REVISÃO BIBLIOGRÁFICA	8
2.1	Aprendizado de Máquina para Monitoramento de Integridade em Estrutura semelhante em vigas	9
2.1.1	Algoritmos supervisionados	12
2.1.2	Algoritmos não-supervisionados	14
2.2	Método do Elemento Espectral	15
2.3	Índice de Dano	16
3	FUNDAMENTAÇÃO TEÓRICA	18
3.1	Método do Elemento Espectral	18
3.1.1	Elemento Espectral	18
3.1.2	Elemento Espectral de Viga com trinca	20
3.2	Métodos de índice de dano usando parâmetros modais	23
3.2.1	Índice de dano baseado na frequência natural	23
3.2.2	Índice de dano baseado na função de resposta em frequência	25
3.3	Etapas do Aprendizado de Máquina	26
3.4	Algoritmos de Aprendizado de Máquina	28
3.4.1	Classificador K-vizinho mais próximo	28

3.4.2	Árvore de Decisão e Floresta Aleatória	30
3.4.3	Máquina de Vetor de Suporte	32
3.4.4	Bayes Ingênuo	34
4	RESULTADOS SIMULAÇÃO NUMÉRICA	36
4.1	Conjunto de Dados	36
4.1.1	Conjunto de dados 1: DI estimado a partir da frequência natural	38
4.1.2	Conjunto de dados 2: DI estimado a partir do FRF	41
4.2	Avaliação do dano utilizando dados de simulação numérica	43
4.2.1	Detecção de dano usando frequência natural-DI	43
4.2.2	Quantificação da severidade do dano usando FRAC-DI	49
5	RESULTADOS DO ENSAIO EXPERIMENTAL	55
5.1	Aparato experimental	55
5.2	Conjunto de DIs extraído de dados experimentais	58
5.3	Avaliação experimental de dano usando viga reforçada com massa	59
6	CONCLUSÃO	64
6.1	Propostas para trabalhos futuros	64
	Lista de Referências	65

LISTA DE TABELAS

2.1	Países de publicações aderentes ao tema	11
4.1	Obtenção das frequências naturais saudáveis e danificadas e cálculo do índice de dano	38
4.2	Resultado da comparação de acurácia entre as métricas de cada algoritmo de ML proposto, usando frequência natural DI.	44
4.3	Resultado da comparação entre as métricas de cada algoritmo de ML proposto, usando FRAC DI.	50
5.1	Resultado da comparação entre as métricas de cada algoritmo de ML proposto, usando FRAC DI para ensaio experimental.	60

LISTA DE FIGURAS

1.1	Acidentes que ocorreram por falta de manutenção.	2
1.2	Fluxograma do processo de avaliação de danos usando conjunto de dados de simulação numérica e experimental.	6
2.1	Etapas do processo Proknow-C.	10
2.2	Evolução da aplicação ML em SHM ao longo dos anos.	10
2.3	Os 10 principais periódicos nos quais os estudos filtrados foram publicados.	11
2.4	Mapa de rede ML e SHM relacionando as palavras-chave presentes na literatura.	12
3.1	Elemento espectral de viga de dois nós (MACHADO M.R.; DOS SANTOS, 2021)	18
3.2	Elemento espectral de viga rachado com dois nós (MACHADO M.R.; DOS SANTOS, 2021)	20
3.3	Fluxograma da utilização do algoritmo ML no processo SHM.	27
3.4	Matriz de confusão.	28
3.5	Classificador K-Vizinho Mais Próximo.	29
3.6	Esquema do classificador árvore de decisão.	30
3.7	Operação do algoritmo SVM.	33
4.1	Projeto esquemático da viga em balanço, a forma modal e as FRFs de inércia para diferentes níveis de profundidade de fissura.	37
4.2	Correlações de DIs para profundidade de trinca de 5, 10, 15 e 20% estimadas com ω_4 e ω_5	39
4.3	Correlações de DIs para profundidade de trinca de 25, 30, 35% estimadas com ω_4 , ω_5 e ω_6	40
4.4	Correlações FRAC DIs para profundidade de trinca de 0, 10, 15, 20, 25 e 30% estimadas com FRFs sem ruído e com ruído.	42
4.5	Correlação de precisão para as frequências naturais de DIs.	44
4.6	Correlação de recall para as frequências naturais de DIs.	45
4.7	Correlação de F1-score para as frequências naturais de DIs.	45

4.8	Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a, c, e) SVM, b, d, f) kNN	47
4.9	Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a, c, e) Bayes Ingênuo, b, d, f) RF.	48
4.10	Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a-c) Árvore de Decisão.	49
4.11	Correlação de precisão, usando FRAC DI.	50
4.12	Correlação de recall, usando FRAC DI.	51
4.13	Correlação de F1-score, usando FRAC DI.	51
4.15	Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a, c, e) Bayes Ingênuo, b, d, f) RF.	52
4.14	Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a, c, e) SVM, b, d, f) KNN.	53
4.16	Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a-c) Árvore de Decisão.	54
5.1	Viga física anexada com massas (topo). Amostras de localização de massas aleatórias para cada massa anexada (inferior).	56
5.2	Representação gráfica dos testes realizados no experimento. (a) Viga intacta com massas reforçada; (b) Viga danificada com perda de massa de 2,96% da massa total; (c) Viga danificada com perda de massa de 5,92% da massa total; (d)Viga danificada com perda de massa de 8,84% da massa total.	57
5.3	Viga medida experimental com FRFs de inertância de massa reforçada, em azul a curva é a posição determinística das massas e a curva em cinza considerando a aleatoriedade na posição da massa. (a) FRFs de viga não danificados; (b) FRFs de viga danificada com perda de massa de 2,96% da massa total; (c) FRFs de vigas danificadas com perda de massa de 5,92% da massa total; e (d) FRFs de vigas danificadas com perda de massa de 8,84% da massa total.	58
5.4	Gráfico de dispersão correlacionando o conjunto de dados de amostras de grupos de FRAC DIs obtido para a viga com massas armadas para diferentes perdas de massa.	59
5.5	Correlação de acurácias para as três frequências naturais de DIs	60
5.6	Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI a) SVM, b) k-NN, c) NB, d) RF e f) DT.	62

LISTA DE NOMENCLATURAS E ABREVIACÕES

CM Monitoramento de Condição, do inglês *Condition Monitoring*

NDE Avaliação não destrutiva, do inglês *Non-destructive Assessment*

NDT Teste não destrutivo, do inglês *Nondestructive testing*

HUMS Monitoramento de saúde e uso, do inglês *Health and usage monitoring system*

SPC Controle estatístico de processos, do inglês *Statistical Process Control*

DP Prognóstico de danos, do inglês *Damage Prognosis*

SHM Monitoramento da Integridade Estrutural, do inglês *Structural Health Monitoring*

ML Aprendizado de máquina, do inglês *Machine Learning*

NB Bayes Ingênuo, do inglês *Naïve Bayes*

kNN k vizinho mais próximo, do inglês *K-Nearest-Neighbor*

DT Árvore de Decisão, do inglês *Decision Tree*

RF Floresta de decisão, do inglês *Random Forest*

SVM Máquina de Vetores de Suporte, do inglês *Support Vector Machine*

DI Índice de dano

FRF Função de resposta em frequência

LC Classificação Linear

CNN Redes Neurais Convolucionais, do inglês *Convolutional Neural Networks*

ANN Redes Neurais Artificiais, do inglês *Artificial Neural Networks*

GA Algoritmos Genéticos, do inglês *Genetic Algorithms*

SVC Classificador de Vetor de Suporte, do inglês *Support Vector Classifier*

SEV Valores Extremos Semi-paramétricos, do inglês *Semi-parametric Extreme Values*

KM k-means

GMM modelo de mistura gaussiana

PSO-SVM Particle Swarm Optimization and Support Vector Machine

DCNN Redes Neurais Convolucionais Profundas, do inglês *Deep Convolutional Neural Networks*

FFT Transformada Rápida de Fourier, do inglês *Fast Fourier Transform*

xgboost eXtreme Gradient boosting

FRESH Frequency Shift

PRFC Polímero Reforçado com Fibra de Carbono

EA Emissões Acústicas

EMD Decomposição de modo empírico, do inglês *Empirical Mode Decomposition*

DWT Transformada Wavelet Discreta, do inglês *Discrete Wavelet Transform*

SRN Spiking Redes Neurais

SEM Método dos Elementos Espectrais, do inglês *Spectral Element Method*

FRAC Critério de Garantia de Resposta de Frequência, do inglês *Frequency Response Assurance Criterion*

DLAC Critério de Garantia de Localização de Danos, do inglês *Damage Location Assurance Criterion*

MDLAC Critério de Garantia de Localização de Danos Múltiplo, do inglês *Multiple Damage Location Assurance Criterion*

VP verdadeiros positivos

VN verdadeiros negativos

FP falsos positivos

FN falsos negativos

FAAC Critério de Garantia de Amplitude de Frequência, do inglês *Frequency Amplitude Assurance Criterion*

GSC Critério de Forma Global , do inglês *Global Shape Criterion*

GAC Critério de Amplitude Global , do inglês *Global Amplitude Criterion*

AIGSC, AIGAC Integração Média GSC/GAC, do inglês *Average Integration GSC/GAC*

Di Índice de Danos de Monnier, do inglês *Monnier's Damage Index*

LISTA DE SÍMBOLOS

Arábicos

- a Profundidade da trinca
- A Área da seção transversal
- b Base
- c Coeficiente de flexibilidade da fissura
- C_j Quantidade de amostras da classe
- d Grau do núcleo polinomial
- E Módulo de Young
- F Força externa
- f função de correção do fator de intensificação de tensão do modo I
- h Altura da seção transversal da viga
- I Momento de inércia
- i Número imaginário
- kn Mudança na matriz rigidez devido à presença de danos
- K Número de classes
- k Número de onda
- L Comprimento
- \hat{M} Forças nodais
- M Momento fletor na posição da trinca
- m Quantidade total dos amostras
- n_i Número de registros no subconjunto S_i
- N_{yi} Número de vezes que o recurso i aparece em uma amostra de classe
- n Número de registros no conjunto S
- N Número da faixa de frequência
- n_c Mudança na matriz rigidez devido à presença de dano

- p_i Probabilidade relativa da classe C_i em S
- S Quantidade total das amostras
- S_i Quantidade de amostras para a partição
- T Transposição do vetor FRF
- \hat{v}^l Deslocamentos verticais à esquerda da fissura
- \hat{v}^r Deslocamentos verticais à direita da fissura
- \hat{V} Forças nodais
- \hat{v} Deslocamento no domínio da frequência
- x Pontos dentro do hiperplano
- y Conjunto de treinamento T
- w Pesos que determinam a orientação do hiperplano
- $\|w\|$ Norma euclidiana

Matrizes

- M Matriz de massa
- $\mathbf{S}_B(\omega)$ Matriz de rigidez dinâmica do elemento espectral de viga saudável de Euler-Bernoulli
- S_c Matriz de sensibilidade que contém as derivadas de primeira ordem de n frequências naturais em relação a m variáveis de dano x

Vetores

- x_i Vetor no espaço entrada \mathfrak{R}
- y_i Vetor no espaço de entrada \mathfrak{R}
- d Vetor de deslocamento
- Φ_i Vetor de forma do modo
- ω_A Vetor de mudança de frequência experimental

Gregos

- α Variação da profundidade da trinca
- γ Parâmetro positivo para controlar a influência de novos recursos no limite de decisão
- θ_{yi} Probabilidade $P(x_i|y)$ de característica aparecendo em uma amostra pertencente à classe
- ω_B a mudança teórica para dano que está situado na i -ésima posição

- Ω Frequência circular
- ω Frequência natural
- ρ Densidade
- η Fator de perda estrutural histerética
- θ Flexibilidade adimensional da trinca
- ρ Densidade
- $\hat{\phi}$ Deslocamento nodal

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO

Dano pode ser considerado qualquer alteração na flexibilidade local de uma estrutura que crie deslocamentos e vibrações indesejáveis (LÉORNAD et al., 2001), reduzindo assim a rigidez e aumentando o amortecimento na estrutura, devido a sobrecarga, fadiga e eventos extremos. A presença de dano em sistemas aeroespaciais, civis e mecânicos podem comprometer seu funcionamento e gerar riscos futuros. Neste contexto, a detecção precoce do dano e a avaliação periódica da integridade estrutural são necessárias para que o sistema opere corretamente e para que os danos sejam identificados, monitorados e corrigidos. Desta forma, muitas técnicas de Monitoramento da Integridade Estrutural, do inglês *Structural Health Monitoring* (SHM), tem sido usadas para identificar e validar danos offline, quase em tempo real e online. Essas técnicas, usam tecnologias que combinam sensores modernos e algoritmos computacionais inteligentes. A extração de informações sensíveis a danos e a análise estatística dessas medidas permitem discriminar a condição estrutural atual para períodos curtos ou longos (FARRAR; WORDEN, 2013; SILVA, 2017). O SHM fornece meios práticos para avaliar e prever o desempenho estrutural sob condições operacionais (PATHIRAGE et al., 2018) e possibilita o desenvolvimento de sistemas de controle integrados a estrutura a ser monitorada, devido ao desenvolvimento de materiais funcionais. Além de ser usado para validação, aquisição, e análise de dados, utilizadas para facilitar nas decisões de gerência do ciclo de vida de sistemas.

As técnicas de SHM, tem sido tema de grandes interesse na engenharia. Isso pode ser atribuído aos elevados custos de manutenção e reparo. Por ano estima-se gasto na ordem que ultrapassam US \$ 200 bilhões em manutenção de equipamentos e instalações. Manutenção e reparos representam cerca de um quarto dos custos operacionais de aeronaves comerciais (GIURGIUTIU, 2014a). Associado a danos que se propagam ao longo da estrutura tem-se acidentes catastrófico e em última instância perda de vidas. Em 2018, parte do viaduto no Eixão Sul - Brasília desabou devido a vários problemas dos quais variavam desde infiltrações e corrosão da armadura de proteção até descolamentos do concreto e fendas abertas, figura 1.1a . A principal causa apontada pelos laudos técnicos foi a falta de manutenção adequada por parte da equipe responsável, felizmente não teve nenhuma vítima (RELATÓRIO-UNB, 2018). Quando se trata de sistemas mecânicos, um dos casos de acidentes mais famoso que gerou grande repercussão na mídia foi da descompressão explosiva no vôo 243 da Aloha Airlines em 1988, Figura 1.1b, o qual foi causado por manutenção insatisfatória da aeronave (AIRCRAFT, 1988).



(a) Viaduto que desabou no centro de Brasília, em 2018.



(b) Descompressão explosiva no vôo 243 da Aloha Airlines em 1988.

Figura 1.1. Acidentes que ocorreram por falta de manutenção.

A melhoria da segurança é sem dúvida essencial, tal prática pode ajuda a evitar acidentes e prolongar a vida útil de uso de equipamento e estruturas. De acordo com esse preceito, é de interesse geral que os danos estruturais sejam identificados de forma simples, rápida e eficiente, para que acidentes como esses não ocorram. Assegurar a integridade de estruturas significa evitar perdas, tanto econômicas quanto humanas. Contudo, segurança, confiabilidade, alto desempenho em operação e redução nos custos de manutenção são os principais benefícios concedidos pelas técnicas de SHM. Estas podem ser baseadas em inspeções visuais, tais como, radiografia e o ultra-som. No entanto, essa técnica precisa de um prévio conhecimento do local do dano para gerar resultados confiáveis. As técnicas baseadas em vibrações, que levam a resultados conclusivos, mesmo quando o local do dano não está acessível ou é até mesmo desconhecido. Isto porque um dano, tem o poder de alterar as propriedades físicas de um sistema, resultando na mudança da resposta dinâmica.

1.2 TÉCNICAS DE MONITORAMENTO DA INTEGRIDADE ESTRUTURAL

A identificação de danos geralmente é realizada no contexto de uma ou mais ações diretamente relacionadas, que incluem: Monitoramento de Condição, do inglês *Condition Monitoring* (CM), Avaliação não destrutiva, do inglês *Non-destructive Assessment* (NDE)- também comumente chamado de Teste não destrutivo, do inglês *Nondestructive testing* (NDT), Monitoramento de saúde e uso, do inglês *Health and usage monitoring system* (HUMS), Controle estatístico

de processos, do inglês *Statistical Process Control* (SPC), Prognóstico de danos, do inglês *Damage Prognosis* (DP) e SHM, sendo este último uma área de crescente interesse tanto na pesquisa acadêmica quanto industrial, considerado importante nos últimos anos devido à sua capacidade de adquirir, validar e analisar dados técnicos que facilitem a decisão do ciclo de vida da estrutura (AVCI et al., 2021; CHEUNG et al., 2008; FARRAR; WORDEN, 2013). O foco principal de cada uma dessas áreas está na avaliação e acompanhamento da integridade estrutural de um sistema. Portanto, todas essas áreas são agrupadas nas técnicas de SHM.

As técnicas SHM, tem a função de detectar e interpretar mudanças na estrutura, com o intuito de obter alto desempenho em operação e conseqüentemente reduzir custos com manutenção, aumentando assim a segurança e confiabilidade da estrutura. Rytter (RYTTER, 1993) propôs quatro níveis para diferenciar os diversos métodos de monitoramento, separados de acordo com a dificuldade de implementação:

- Nível 1: detecta a presença do dano na estrutura;
- Nível 2: detecta e localiza o dano;
- Nível 3: detecta, localiza e quantifica o dano;
- Nível 4: detecta, localiza, quantifica e prevê a vida útil restante do equipamento.

Inman (INMAN, 2001), propôs mais três níveis de classificação, baseados na utilização de materiais inteligentes, englobando técnicas de auto-reparo e controle:

- Nível 5: adiciona ao nível 4 as estruturas inteligentes para auto-diagnóstico de danos;
- Nível 6: adiciona ao nível 4 as estruturas inteligentes e sistemas de controle para formar um conjunto capaz de realizar um auto-reparo estrutural;
- Nível 7: adiciona ao nível 1 um sistema de controle ativo e estruturas inteligentes para formar um conjunto simultâneo de controle e monitoramento.

Algumas técnicas de SHM podem ser baseadas em inspeções visuais ou em sinais de vibração, sendo os sinais de vibração considerados mais versáteis. Os sinais de vibrações para monitoramento estrutural passou a ser usado no fim dos anos 70 e começo dos 80, particularmente nas indústrias aeroespacial e petrolíferas off-shore. Os primeiros estudos foram baseados em modelos numéricos e na medição das propriedades modais do sistema, em condições saudáveis de funcionamento e desconhecidas (FARRAR C. R.; DOEBLING, 1999). Os sinais de vibrações podem ser separados em relação ao domínio do tempo (os observadores de estado, wavelet e as baseadas em séries temporais), da frequência (impedância elétrica e ondas de Lamb) e o domínio modal (frequências naturais e na forma dos modos de vibrar). As medições de vibração são realizados no domínio do tempo, a partir deste, os dados são convertidos para o domínio da frequência ou modal, através da transformada de Fourier (MARQUI, 2007). Em ambos os casos, materiais piezoelétricos podem ser utilizados como sensores e atuadores.

A primeira etapa do SHM é a detecção de danos, seguida de avaliação e monitoramento. Portanto, uma das técnicas que estão ganhando grande destaque nos últimos anos é o uso do SHM com algoritmos de Aprendizado de máquina, do inglês *Machine Learning* (ML), que é usado para classificar os dados que foram treinados para gerar o resultado mais provável e validar o modelo com base em dados de conjuntos não vistos. Os algoritmos de ML fornecem as ferramentas necessárias para aprimorar os recursos dos sistemas SHM e fornecer soluções inteligentes para os desafios do passado. Ele oferece soluções eficientes para construir modelos ou representações para mapear padrões de entrada em dados de sensores medidos para alvos de saída para uma avaliação de danos em diferentes níveis (RYTTER, 1993). O conceito de ML entra no paradigma de seleção de recursos e modelagem estatística para discriminação de recursos, conforme descrito em (MACHADO; ADHIKARI; SANTOS, 2017a; KURIAN; LIYANAPATHIRANA, 2020). O recurso pode ser extraído usando técnicas baseadas em visão computacional, incluindo câmeras ou imagens digitais, e técnicas baseadas em sensores, que contêm as informações do sistema de vibração, por exemplo, parâmetros modais.

O foco deste trabalho está nas técnicas baseadas em sinais de vibração de sistemas e estruturas. Métodos de identificação de danos usando características de vibração estrutural são amplamente utilizados porque mudanças nos parâmetros físicos estruturais, como rigidez e massa, também alteram as características de vibração estrutural. Portanto, algumas técnicas de monitoramento estrutural são usadas para adicionar uma mudança de massa transversal auxiliar na estrutura para aumentar os efeitos de descontinuidades na resposta dinâmica e facilitar a identificação e localização do dano. Zhang, Lie e Xiang (2013), propôs usa a curva de deslocamento de frequência com uma massa auxiliar em uma estrutura para detecção de danos (Nível 2). Wang, Lie e Zhang (2016), usou um método nominado Frequency Shift (FRESH) para explicar o comportamento dinâmico de estruturas fundidas com massa auxiliar. O método é considerado racional e computacionalmente operacional na identificação da perda. As vigas danificadas através de trincas são comumente mais usadas para estimação de dano (Nível 1). A identificação de danos em vigas usando ML foi explorada por Ghadimi e Kourehli (2017), neste estudo, os autores implementaram uma máquina de aprendizagem extrema modificada para uma viga simplesmente apoiada, uma viga em balanço e uma viga fixa-simplesmente apoiada, com e sem efeito de ruído, e pórticos usando frequências naturais e formas modais. Os resultados indicaram que o método proposto é muito rápido e preciso no problema de detecção e estimativa de fissuras em estruturas de vigas e pórticos (Nível 2). Gillich N.; Tufisi (2022) identificou a localização e a severidade de uma viga em balanço a partir da frequência natural. A viga apresentou diferentes níveis de fixação (fixação ideal e não ideal), e os resultados mostraram que os erros na estimativa da localização e severidade da fissura (Nível 4) utilizando Redes Neurais Artificiais, do inglês *Artificial Neural Networks* (ANN) foram menores em comparação com o algoritmo Floresta de decisão, do inglês *Random Forest* (RF).

Diferentes classificadores estatísticos como Bayesiano, k vizinho mais próximo, do inglês *K-Nearest-Neighbor* (kNN), RF e Máquina de Vetores de Suporte, do inglês *Support Vector Machine* (SVM) foram usados em Rathod, Mukherjee e Deng (2020) para identificar danos em uma placa por meio de sensores que extraem sinais subtraídos da linha de base. Os

autores descobriram que os classificadores SVM e RF funcionaram melhor no conjunto de dados construído, pois a taxa de erro foi a menor (Nível 1). Liu e Meng (2005), descobriram que o SVM é um método promissor para diagnosticar o dano. Eles aplicaram o SVM para identificar e localizar danos em vigas em balanço, com e sem ruído (Nível 2). Ashigbi et al. (2021) implementou um sistema de inferência fuzzy para prever a profundidade e a localização da trinca ao longo de quinze vigas rachadas, onde apenas uma estava intacta. As entradas para o sistema Fuzzy foram a primeira frequência natural e a curtose do sinal de resposta de vibração. Um conjunto de regras Fuzzy foi estabelecido por aprendizado de máquina a partir dos conjuntos de dados experimentais e aplicado a funções de pertinência triangulares, gaussianas, trapezoidais e em forma de sino. Este método demonstra uma solução prática para abordar a avaliação contínua de danos e a tomada de decisões, ambos componentes críticos da estratégia SHM (Nível 4).

1.3 METODOLOGIA

No SHM, uma abordagem típica é monitorar, localizar, categorizar e estimar a severidade do dano estrutural como um todo. Portanto, ainda é um grande desafio estabelecer um algoritmo de monitoramento de aprendizado de máquina com uma forte capacidade de generalização para sinais de monitoramento baseados em vibração de monitoramento multitarefa. Considerada a escassez de investigações voltadas ao estudo de SHM utilizando ML que alcance o Nível 3: detectar e quantificar o dano, conclui-se que este trabalho possui clara contribuição neste sentido. A geração de uma base de dados, que contenha todas as variáveis de interesse, medidas de forma precisa e refinada, foi uma contribuição fundamental para ampliar o conhecimento do problema.

A metodologia empregada neste trabalho está baseada na técnica de SHM baseada em sinais de vibrações, considerada na literatura a mais versátil. A figura 1.2 ilustra o passo a passo esquematizando a metodologia deste trabalho. Onde inicia-se pela aquisição da resposta dinâmica da estrutura por uma interface de simulação e outra experimental. Seguido pela estimação e averiguação para normalização usando índice de dano, além da geração do banco de dados para alimentar os algoritmos de ML. O último passo é a fase de treinamento e teste dos algoritmos e utilização dos dados de teste para identificar e quantificar danos na estrutura.

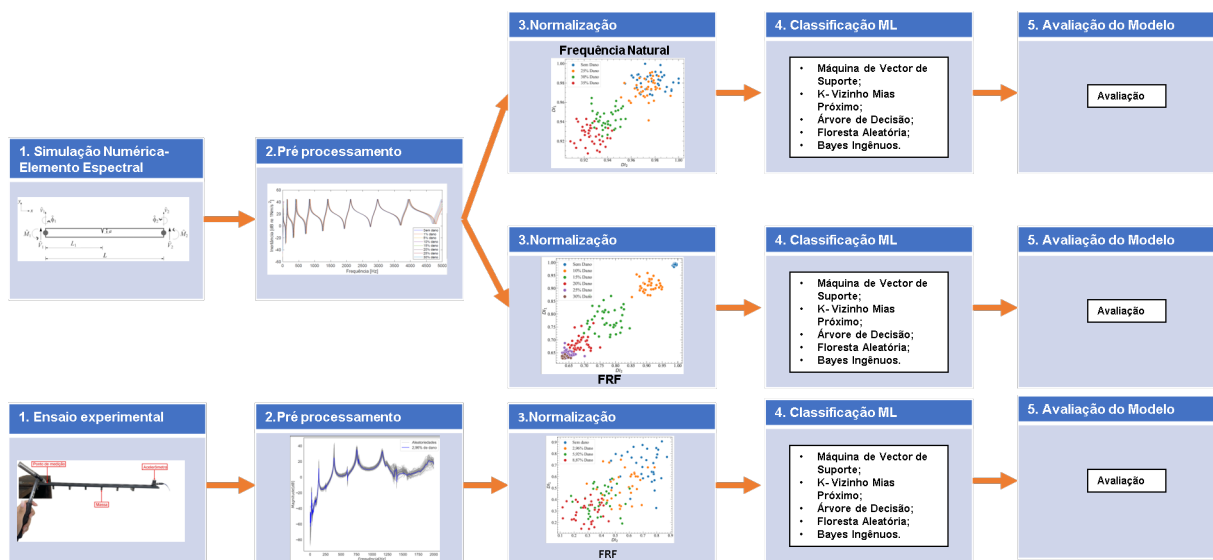


Figura 1.2. Fluxograma do processo de avaliação de danos usando conjunto de dados de simulação numérica e experimental.

Portanto, para resolver o problema da pesquisa de como chegar ao Nível 3 do SHM, sendo este identificação e quantificação de dano, realizou-se uma avaliação em estrutural do tipo viga metálica com diferente tipos de dano. O estudo dividiu-se em duas etapas:

- a primeira é a avaliação através da simulação numérica, onde a modelagem da viga metálica foi realizada através do método dos elementos espectrais. Dois parâmetros modais (frequência natural e a Função de resposta em frequência (FRF)) foram utilizados para extrair característica da estrutura. Os índices de dano(DI), apresentado no capítulo 3, foram utilizados então como dados para alimentar os algoritmos de ML, para frequência natural e para FRF.
- a segunda avaliação se dá através de sinais de vibrações experimentais em uma viga metálica reforçada com ímãs, os dados foram extraídos usando um sensor acelerômetro na extremidade livre e aplicando uma força com martelo modal próximo a extremidade engastada. A aquisição do sinal das FRFs foi realizado no programa Polytec. A estimação do índice de dano foi realizado através do Critério de Garantia de Resposta de Frequência, do inglês *Frequency Response Assurance Criterion* (FRAC). No capítulo 4, apresenta-se detalhadamente como foi gerado os dados. Posteriormente os dados coletados foram organizando em uma tabela dividindo em saudável e danificado (quantidade de dano) e por fim avaliação da robustez dos algoritmos de ML: kNN, SVM, Árvore de Decisão, do inglês *Decision Tree* (DT), RF e Bayes Ingênuo, do inglês *Naïve Bayes* (NB) para o caso estudado.

1.4 OBJETIVOS

O objetivo deste trabalho reside em utilizar o SHM juntamente com cinco algoritmos de ML supervisionados para alcance do Nível 3: detectar e quantificar o dano da estrutura do tipo

de viga metálica e viga metálica reforçada com ímãs através da sua resposta dinâmica. Bem como avaliar a eficiência dos algoritmos ML em SHM e verificar a sua acurácia e robustez para detecção e quantificação do dano para o caso de multiclasse .

1.4.1 Objetivos Específicos

1. Modelar numericamente a viga metálica com e sem trinca usando o método do elemento espectral;
2. Avaliar o dano na viga metálica reforçada com ímãs experimentalmente alterando a perda de massa do reforço da estrutura;
3. Analisar o melhor índice de dano utilizando os parâmetros de vibrações do sistema.
4. Avaliar cinco algoritmos de aprendizado de máquina supervisionados para detecção e quantificação de danos estruturais que são descritos com dados numéricos e experimentais no contexto do SHM. Os algoritmos kNN, SVM, DT, RF e NB são usados neste trabalho.

1.5 ESTRUTURA DO TRABALHO

Esta dissertação está organizada da seguinte forma:

Este primeiro capítulo é uma introdução do assunto estudado, traz uma contextualização e motivação para realização do trabalho, além de algumas técnicas de SHM que são mais estudadas. Nesta seção é apresentada a estrutura do trabalho.

O capítulo 2, apresenta uma revisão bibliográfica dos trabalhos publicados sobre os assuntos estudados. Os trabalhos mais utilizados para o desenvolvimento deste trabalho estão listados neste capítulo.

O Capítulo 3 traz uma fundamentação teórica explicando a formulação e como funciona a detecção de trincas utilizando o elemento espectral de vigas, a formulação do índice de dano, tanto para frequência natural, como para função de resposta em frequência e posteriormente apresentação dos algoritmos de ML que foram estudados.

O Capítulo 4 , os resultados obtidos pelo método número e expõe a geração de dados do processo de modelagem dinâmica e proposta dos índices de dano selecionados e avaliação dos algoritmos de ML.

No Capítulo 5, os resultados do ensaio experimental são apresentados, bem como as respectivas análises. Por fim, o Capítulo 6, apresenta as conclusões inferidas para este trabalho e proposta para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e com a evolução do *big-data* gerado por diferentes setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, reduzindo a necessidade de intervenção humana. O ML, entra para solucionar esse problema, pois funciona como uma disciplina que faz uso de toda uma série de procedimentos e algoritmos para identificar padrões, agrupamentos ou tendências. Descreve como aprender e como fazer previsões sobre dados, extrai informação útil para análise de dados, de maneira totalmente automática (NELLI, 2015; MEHTA P., 2019).

As técnicas de ML focam mais nas previsões, onde a meta é encontrar uma função a partir dos dados de treinamento que possa ser utilizada para prever um rótulo ou valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada. Para isso, cada objeto do conjunto de treinamento deve possuir atributos de entrada e saída. Dessa forma, utiliza-se o modelo estimado em dados não vistos anteriormente, chamados de dados de teste, então, pode-se comparar os dados de saída do modelo com o dado real a fim de avaliar a acurácia e outras métricas, isto é, quão próximo do real, as previsões chegam, conseqüentemente melhor será o modelo, quando se aproxima dos dados reais (FACELI K., 2011).

Os principais algoritmos de aprendizado são os métodos supervisionado, não supervisionado e semi-supervisionado e aprendizagem por reforço (MALEKLOO et al., 2021; SANTOS E. FIGUEIREDO, 2016). O aprendizado supervisionado, precisa de um supervisor externo que conheça a saída desejada pra cada evento, neste caso esse supervisor pode avaliar e rotular os valores de saída, por exemplo, um conjunto de dados de condições danificadas e não danificadas, inicialmente o supervisor rótula as condições antes de treinar o algoritmo. As tarefas mais comuns de aprendizado supervisionado são a de classificação de grupo e análise de regressão. Os algoritmos não supervisionados são quando os algoritmos de ML não fazem uso de atributos de saída, é recomendado como exemplo quando apenas os dados da estrutura não danificada estão disponíveis para treinamento, onde os métodos de detecção por agrupamento ou associação são as principais classes de algoritmos usados nessa situação. Uma tarefa descritiva de agrupamento de dados, tem por meta encontrar grupos de objetos semelhantes no conjunto de atributos. Outra tarefa descritiva é encontrar regras de associação que relacionam um grupo de atributos a outro grupo de atributos (FACELI K., 2011).

No aprendizado semi-supervisionado, os dados são misturados entre classificados e não classificados. Essa combinação de dados rotulados e não rotulados é usada para gerar um modelo apropriado para a classificação dos dados. Na maioria das situações, os dados rotulados

são escassos e os dados não rotulados são abundantes. O alvo do semi-supervisionado classificação é aprender um modelo que irá prever classes de futuras dados de teste melhores do que o modelo gerado usando os dados rotulados sozinho. O método de aprendizado por reforço visa usar observações coletadas da interação com o ambiente para tomar ações que maximizem a recompensa ou minimizar o risco (MOHAMMED M., 2017).

2.1 APRENDIZADO DE MÁQUINA PARA MONITORAMENTO DE INTEGRIDADE EM ESTRUTURA SEMELHANTE EM VIGAS

Nesta seção é apresentado uma revisão bibliométrica dos principais algoritmos tanto supervisionados quanto não supervisionados para SHM em estruturas semelhantes a viga, os artigos foram separados de acordo com os níveis de SHM. Na literatura entre os anos de 1996 a 2022, foram encontrados aproximadamente 92 artigos relacionados a este estudo. A seleção das pesquisas foi realizada por meio do processo Proknow-C (ENSSLIN L.; PACHECO, 2012; ENSSLIN S.R.; PEREIRA, 2014), que é um método robusto de seleção de artigos de referências teóricas.

O método Proknow-C consiste em seis etapas principais, mostradas na Figura 2.1. A etapa 1 seleciona palavras-chave de acordo com o tópico de pesquisa, bancos de dados de pesquisa, período de tempo e outros filtros limitantes. O processo Proknow-C determina que o número de artigos originados na primeira etapa deve estar entre 2.000 e 10.000 (ENSSLIN L.; TASCA, 2010). Assim, o repositório bruto foi composto por 8.538 artigos. A etapa 2 é filtrar artigos e revistas, incluindo áreas de engenharia civil, mecânica e aeroespacial, o repositório bruto consistia em 109 artigos. O passo 3 é a leitura dos títulos de todos os artigos para selecionar aqueles alinhados com o tema da pesquisa. O processo Proknow-C determina que o número de artigos filtrados com títulos alinhados deve ser inferior a 1.000 (ENSSLIN L.; TASCA, 2010). Assim, o repositório de títulos alinhados foi composto por 92 artigos. O passo 4 é selecionar os artigos mais citados com base em uma regra de representatividade, como Pareto, os artigos que compõem 80% das citações são selecionados para os repositórios, chegando a 25 artigos; posteriormente, cria-se um repositório de autores, com artigos selecionados pelo método de Pareto, e analisam-se artigos com autores de maior relevância, chegando a 6 artigos; além de incluir artigos dos últimos dois anos, chegando a 36 artigos. O passo 5 é ler resumos de artigos representativos e artigos recentes para selecionar os mais alinhados. Assim, o repositório foi composto por 67 artigos. A etapa 6 é a verificação da disponibilidade e leitura sistemática do conjunto final de artigos selecionados. Por fim, a seleção final após todas as etapas do processo bibliométrico Proknow-C foi de 17 artigos.

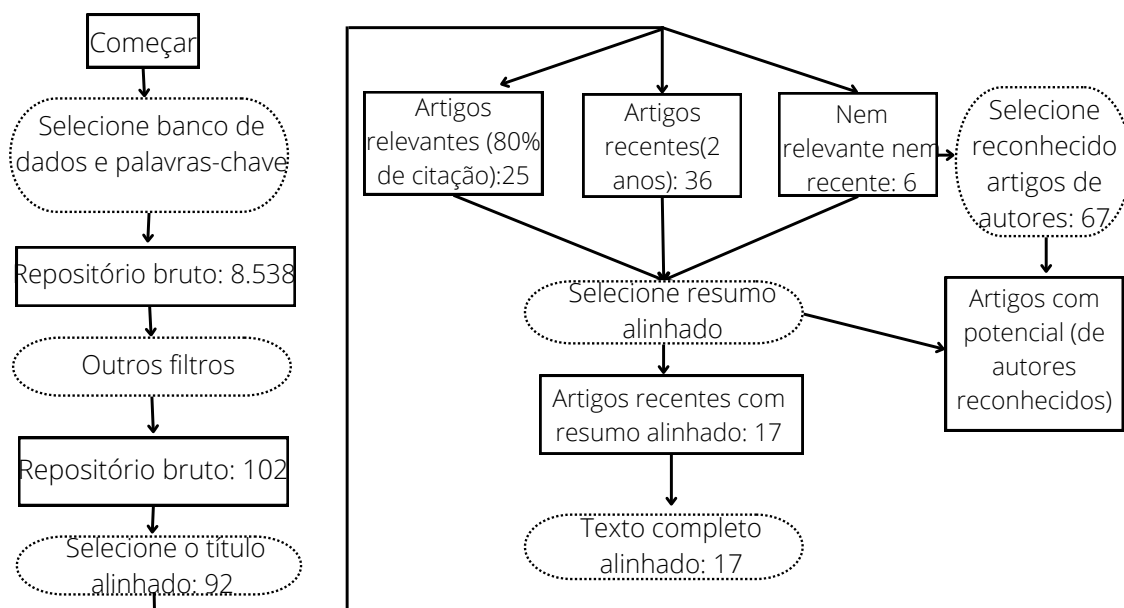


Figura 2.1. Etapas do processo Proknow-C.

A coleta de dados foi realizada no mês de maio de 2022, na plataforma Web of Science. Entre 2018 e 2021, o número de estudos relacionados aumentou acentuadamente, com 13 publicações em 2018 e mais de 26 publicações em 2021. A Figura 2.2 mostra uma evolução ascendente do uso de técnicas de ML aplicadas no monitoramento de estruturas semelhantes a vigas.




Figura 2.2. Evolução da aplicação ML em SHM ao longo dos anos.

Na Tabela 2.1, apresenta o número de publicações referentes a cada país, com os Estados Unidos à frente na produção científica com 7 publicações, seguido da Inglaterra, Colômbia, Irã e Espanha, com 3, 2, 2 e 2 publicações, respectivamente.

Tabela 2.1. Países de publicações aderentes ao tema

Países	Quantidade de artigos
Estados Unidos	7
Inglaterra	3
Colombia	2
Irã	2
Espanha	2
Australia	1
Brasil	1
França	1
Alemanha	1
Italia	1
Nova Zealandia	1
Qatar	1
Coreia do Sul	1
Vietnã	1

A figura 2.3 mostra os 10 principais periódicos internacionais em que foram publicados pelo menos 2 artigos científicos. Destaca-se a revista científica Sensor com um total de 7 publicações que abordam o tema.




Figura 2.3. Os 10 principais periódicos nos quais os estudos filtrados foram publicados.

Uma rede bibliométrica realizada no VOSviewer exhibe a ligação entre o SHM e o algoritmo ML mais utilizado. O VOSviewer é uma ferramenta para mapear a rede de tópicos com base na distância entre dois nós do assunto, onde a distância entre os nós indica a intensidade de seu relacionamento e o tamanho do nó representa a ocorrência. A Figura 2.4 mostra uma visão ampla dos tópicos mais discutidos na literatura que nos permitem entender profundamente as tendências de pesquisa na área de SHM e ML. SHM, identificação de danos e detecção têm os eventos de link mais altos com os métodos ML. Os algoritmos supervisionados mais usados mostrados na Fig. 2.3 são SVM, DT, RF, ANN e kNN. Os algoritmos não supervisionados são agrupamento k-means (KM), autoencoders e redes neurais. Neste sentido, guiados pela

relevância e abrangência da literatura foram escolhidos as técnicas de ML utilizadas neste trabalho aplicada ao monitoramento de estruturas.

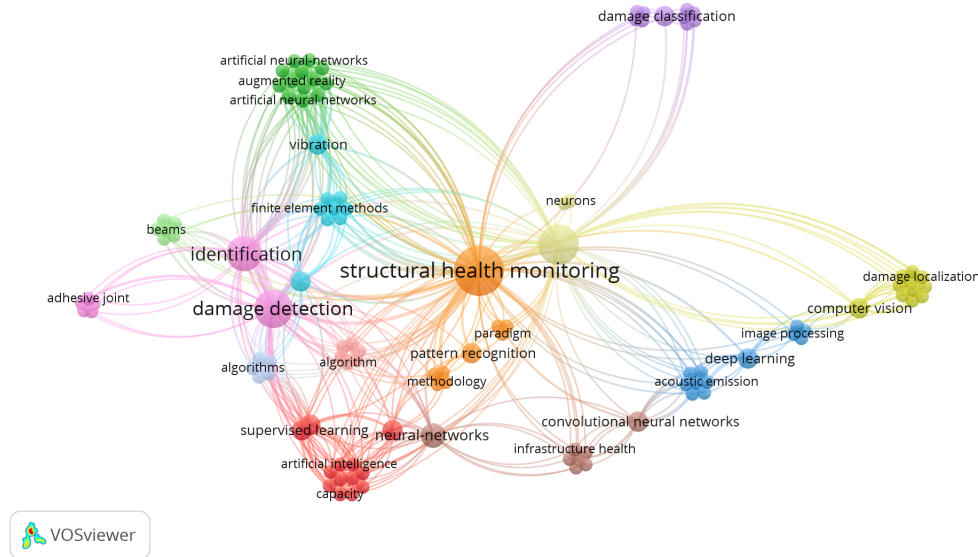


Figura 2.4. Mapa de rede ML e SHM relacionando as palavras-chave presentes na literatura.

Os principais trabalhos encontrados à análise são apresentados nesta seção subdividida em algoritmos supervisionados e não- supervisionados. Como exposto no capítulo 1, o SHM pode ser dividido em níveis, desta forma os artigos pesquisados foram divididos de acordo com os níveis de SHM.

2.1.1 Algoritmos supervisionados

Sun, Santos e Caetano (2022a) usou a série temporal original de pesagem em movimento do trem codificada em imagens para identificar danos na ponte. Eles usaram AdaBoost, SVM, kNN e modelo de Classificação Linear (LC) e descobriram que o SVM leva a uma maior precisão de previsão e menor tempo computacional (Nível 1). Iyer et al. (2021) implementou um sistema multi-robô com codificação de imagem capaz de monitorar e detectar defeitos de superfície em trilhos de trem, incluindo fraturas, agachamentos, ondulações e ferrugem. Os resultados foram comparados a quatro algoritmos de aprendizado de máquina, Redes Neurais Convolucionais, do inglês *Convolutional Neural Networks* (CNN), ANN, RF e SVM. Verificou-se que o modelo CNN superou todos os algoritmos em análise. Portanto, o sistema proposto ajudou a eliminar a necessidade de inspeção visual, pois o mecanismo de alerta automatizado permitiu o rastreamento visual e baseado em localização em tempo real da detecção de falhas nas linhas ferroviárias (Nível 2).

Farrar C.R. (2007) usaram redes neurais, SVM e Algoritmos Genéticos, do inglês *Genetic Algorithms* (GA) aplicados em SHM. Mais tarde, Nick W. (2015) estendeu o aplicativo ML em

SHM usando classificadores gaussianos, SVM, RF e algoritmos Adaboost no monitoramento (Nível 1). Kurian e Liyanapathirana (2020) usaram três algoritmos de ML, kNN, SVM e RF, para prever danos em estruturas de concreto com a ajuda da tecnologia de sensores. O algoritmo classificador de RF gerou boas previsões em condições danificadas e não danificadas com boa precisão em comparação com outros algoritmos (Nível 1). Pratico et al. (2020) usou oito classificadores ML (ou seja, percepção multicamada, CNN, RF e Classificador de Vetor de Suporte, do inglês *Support Vector Classifier (SVC)*) para uma assinatura vibroacústica específica em diferentes pavimentos de estradas rachadas, onde o classificador SVC tiveram maior acurácia entre os métodos (Nível 1). Daneshvar e Sarmadi (2022) propuseram um novo método de detecção de danos multiplicando a densidade local de cada feição por seu valor mínimo de distância nas amostras de treinamento. Além disso, eles consideraram a regra do vizinho mais próximo de uma classe, calculada por meio de um novo método probabilístico sob a teoria dos Valores Extremos Semi-paramétricos, do inglês *Semi-parametric Extreme Values (SEV)*. Estudos comparativos em duas pontes revelaram que o método SEV é superior aos detectores de anomalias conhecidos, agrupamento de KM, modelo de mistura gaussiana (GMM) e ANN, fornecendo menores taxas de erro e fornecendo melhor detecção de danos (Nível 1). O Particle Swarm Optimization and Support Vector Machine (PSO-SVM), estudado por Cuong-Le et al. (2021), mostrou ser uma boa técnica para identificar danos em estruturas treliçadas e pórticos usando parâmetros modais. He et al. (2021) combinou Redes Neurais Convolucionais Profundas, do inglês *Deep Convolutional Neural Networks (DCNN)* e Transformada Rápida de Fourier, do inglês *Fast Fourier Transform (FFT)* para detecção de danos em um prédio de três andares. O resultado experimental mostrou que o método proposto alcança alta precisão em comparação com algoritmos clássicos de aprendizado de máquina como SVM, RF, kNN e eXtreme Gradient boosting (xgboost) (Nível 1).

De acordo com Sun, Santos e Caetano (2022b), os algoritmos de aprendizado supervisionado mais usados na construção de projetos estruturais e avaliação de desempenho de estruturas são Regressão Linear, Regressão de Kernel, Algoritmos Baseados em Árvores, Regressão Logística, SVM, kNN e Redes Neurais. Vitola et al. (2017) e Tibaduza et al. (2018) utilizaram diferentes tipos de algoritmos kNN, aplicando uma rede de sensores piezoelétricos para obter o banco de dados. No trabalho de Vitola, os autores inspecionam e avaliam os danos em um perfil retangular de alumínio, uma placa de alumínio e uma placa composta. Os resultados mostram que o kNN fino e o kNN ponderado tiveram melhor desempenho entre os algoritmos estudados (Nível 1). No artigo de Tibaduza, os autores analisaram uma estrutura sanduíche composta de Polímero Reforçado com Fibra de Carbono (PRFC) e uma placa composta de PRFC, obtendo resultados semelhantes ao Vitola de acordo com o kNN. De Lautour e Omenzetter (2010) usaram a classificação supervisionada do vizinho mais próximo e a quantificação do vetor de aprendizado para estudar uma estrutura de rack de laboratório de 3 andares assumindo um estado não danificado e vários estados danificados. Os resultados mostraram que ambas as técnicas de classificação foram capazes de classificar os danos (Nível 1).

Salehi et al. (2018) estudaram três métodos de algoritmos supervisionados (SVM, kNN e ANN) para avaliar o desempenho da abordagem de detecção de danos no estabilizador de asa de aeronave submetido a carregamento dinâmico. Os resultados demonstram que a metodologia

SHM desenvolvida usando ML detecta eficientemente danos em uma nova rede de sensores autoalimentada, mesmo com ruído e dados binários incompletos (Nível 1). Coelho, Das e Chattopadhyay (2009) apresentou uma metodologia para mineração de dados de sinal do sensor em uma estrutura SHM para classificação de danos usando SVM. Uma estrutura de árvore de decisão hierárquica foi construída para classificação de danos, e experimentos foram conduzidos em estruturas metálicas e mistas. Eles também demonstraram que usar uma estrutura de árvore binária reduz a intensidade computacional de cada classificador sucessivo e a eficiência do algoritmo. Os resultados obtidos com essa classificação mostram que esse tipo de arquitetura funciona bem para grandes conjuntos de dados, pois é necessário um número reduzido de comparações (Nível 1). Tsuchimoto K. e Kitagawa (2004) propôs um sistema de detecção de danos estruturais que usa frequências naturais em uma estrutura de cinco andares, modelada com um sistema de cisalhamento de cinco massas, os locais de danos foram detectados pela primeira vez globalmente usando o método de ANN. A falha foi identificada localmente pela determinação de mudanças na excentricidade da estrutura entre os centros de rigidez e peso devido ao dano. A ANN apresentou boa acurácia na detecção de danos (Nível 2).

2.1.2 Algoritmos não-supervisionados

Abdeljaber et al. (2018) usaram CNN para identificar danos em uma estrutura de quatro andares, usando caixas danificadas e não danificadas, onde 1D-CNN foi considerado bem-sucedido (Nível 1). Ebrahimkhanlou e Salamone (2018) implementaram autoencoders e uma CNN para localizar fontes de Emissões Acústicas (EA). Eles usaram sensores em placas de metal, com reforços conectados por rebites, para localizar danos e trincas de fadiga simuladas experimentalmente por testes de trincas Hsu-Lapis Nielsen. Os resultados mostram que ambas as redes de aprendizado profundo podem aprender a mapear sinais de EA para suas fontes (Nível 2). Manjurul Islam e Kim (2019) propuseram uma detecção de dano baseada em uma DCNN, que consiste em um sistema neural totalmente convolucional com uma estrutura de classificação de codificação semântica que detecta danos e decodifica com precisão. Os resultados experimentais indicam que o método proposto é altamente eficaz para a classificação de fissuras (Nível 3). Mansouri Nejad et al. (2021) combinou ANN com Decomposição de modo empírico, do inglês *Empirical Mode Decomposition* (EMD) e Transformada Wavelet Discreta, do inglês *Discrete Wavelet Transform* (DWT) processando respostas de aceleração medidas em uma plataforma semelhante a uma jaqueta offshore. Os resultados indicaram que o DWT, em comparação com o EMD, possui um método de processamento de sinal mais confiável na detecção de danos devido à melhor redução de ruído (Nível 1).

Nunes et al. (2021) implementou uma metodologia que combina métodos de classificação de ANN supervisionados e não supervisionados (k-means clustering) para construir um classificador híbrido. A robustez da abordagem proposta é avaliada por meio de dados obtidos a partir de simulações numéricas e testes experimentais realizados em laboratório e *in situ*. O classificador híbrido teve um bom desempenho, identificando comportamentos previamente

conhecidos e detectando novas condições estruturais (Nível 2). Dang Mohsin Raza (2021) aplicou quatro algoritmos proeminentes de aprendizado profundo, percepção de várias camadas, rede de memória de longo prazo, 1D-CNN e CNN, para detectar danos estruturais usando dados brutos. São investigados uma viga contínua 1D sob excitação aleatória, uma estrutura de aço 2D submetida a movimento do solo por terremotos e uma ponte estaiada 3D sob cargas veiculares. Os resultados enfatizam a alta confiabilidade da 2D-CNN e o bom equilíbrio entre a precisão e a complexidade da Memória Longa de Curto Prazo e da 1D-CNN (Nível 2). Yuan et al. (2020) apresentou resultados preliminares de modelagem dinâmica de estruturas de vigas usando ANN informada por física. Os autores também incorporaram conhecimento de domínio de NDI/SHM (inspeção visual, impacto) no pipeline de aprendizado de máquina para avaliar o paradigma de detecção de medições de campo completo sem contato para danos (Nível 1).

Novos algoritmos foram testados para buscar eficácia na identificação de danos. Bull et al. (2019) usou um algoritmo de classificação on-line para aplicar os dados da ponte Z24, um conjunto de dados de usinagem de EA e medições de teste de vibração do solo. Eles descobriram que o aprendizado ativo melhora o desempenho da classificação online para detecção de danos e classificação em experimentos (Nível 3). Fathalizadeh Najib e Salehzadeh Nobari (2021) estudaram um novo modelo de entrada exógena com um procedimento baseado em um modelo autorregressivo não linear. Eles investigam o método usando o modelo de elementos finitos de uma viga conectada a um suporte rígido considerando uma camada adesiva flexível. O método proposto é vantajoso no banco de dados de padrões de danos e no processo de identificação de danos com base em um modelo do mundo real e no reconhecimento de padrões (Nível 1).

Zanatta F. Barchi e Acquaviva (2021) detectou danos à infraestrutura em uma ponte rodoviária e propôs uma nova abordagem SHM usando Spiking Redes Neurais (SRN) aplicada a dados de sistemas microeletromecânicos (MEMS). O SRN pode efetivamente discriminar se uma estrutura está em uma condição saudável ou danificada com um nível de precisão semelhante do ANN (Nível 2). Perry, Guo e Mahmoud (2022) usaram um modelo de Processo Gaussiano para prever fatores de intensidade de tensão em um fluxo de trabalho automatizado para avaliar o mecanismo de fratura de estruturas de aço usando imagens de inspeção. Um U-Net foi projetado para encontrar a localização do pixel de uma rachadura. O fluxo de trabalho proposto permite uma inspeção fácil de trincas de aço e prevê a propagação de trincas a partir de uma coleção de imagens brutas (Nível 3).

2.2 MÉTODO DO ELEMENTO ESPECTRAL

O método do elemento espectral (SEM) foi proposto a partir da solução analítica da equação de deslocamento de onda escrita no domínio da frequência (DOYLE, 1997; LEE, 2009). Uma das maiores vantagens do SEM é o pequeno número de elementos necessários para representar um sistema. Esse recurso leva a um nível de eficiência computacional significativo em análises dinâmicas e de propagação de ondas onde uma discretização fina é normalmente

necessária seguindo as abordagens convencionais baseadas em elementos finitos. No trabalho atual baseado no SEM, as funções de forma do elemento são obtidas a partir da solução exata de equações diferenciais e as soluções do sistema dinâmico são escritas na frequência domínio. Esta característica melhora a precisão da solução do sistema dinâmico (MACHADO et al., 2022).

Devido ao SEM ser a solução exata das equações diferenciais que regem o problema, tornou-se uma técnica adequada para modelar a detecção de danos estruturais. Em geral, as alterações nas propriedades estruturais globais ou locais podem estar associadas a uma imperfeição ou dano. Este comportamento pode ser explicado pela presença de uma fissura ou trinca na estrutura introduzindo uma flexibilidade local que afeta a sua resposta. Também gera mudanças mais evidentes nas ondas elásticas que se propagam na estrutura. A propagação de ondas elásticas em uma estrutura danificada em bandas de média e alta frequência usando SEM foi apresentada por Krawczuk, Palacz e Ostachowics (2002), Palacz e Krawczuk (2002), Ostachowicz (2008), Machado, Appert e Khalij (2019), Dutkiewicz e Machado (2019) e Zhang et al. (2018). Palacz (2018) publicou uma visão geral dos métodos espectrais para modelar e usar a propagação de ondas em problemas de detecção de danos. Ng, Veidt e Lam (2011), Flynn et al. (2012), Machado e Santos (2015), Machado, Adhikari e Santos (2017b) e Machado, Adhikari e Santos (2018) propuseram uma detecção de danos estruturais incluindo parâmetros aleatórios e modelos estocásticos.

2.3 ÍNDICE DE DANO

Dano é a mudança feita em um sistema que afeta adversamente seu desempenho atual ou futuro (FARRAR; WORDEN, 2006). Este conceito de detecção de dano envolve uma comparação entre dois estados diferentes de um sistema. Várias abordagens têm sido desenvolvidas para definir e extrair características de sinal, por sua vez, identificar danos estruturais, e dentre essas técnicas, destacam-se os índices de danos. Índices de dano ou índice de dano (DI), é associado ao algoritmo de detecção de dano que consiste em comparar dois sinais e retornar um valor escalar, que indica um nível de dano presente na estrutura. O desenvolvimento de DIs e algoritmos de identificação de danos continua sendo uma área aberta para a aplicação prática do monitoramento estrutural (HO; EWINS, 2000; GIURGIUTIU, 2014b).

Su e Ye (2009) enumerou características de sinais de ondas Lamb que podem ser usadas no desenvolvimento de DIs, incluindo tempo de propagação, valor quadrático médio da raiz Rizzo e Lanza (2006), Ghaffarzadeh et al. (2016), variação de sinal Rizzo e Lanza (2006), amplitude pico a pico Su e Ye (2009), taxa de atenuação da energia de deformação (SHARMA; RUZZENE; HANAGUD, 2006; APETRE et al., 2008), impedância local Lee e Staszewski (2003), entre outros. A comparação do método DIs para realizar a detecção de dano apresenta complicações relacionadas à escala e amplitudes ou a inexistência de magnitude, o que dificulta sua avaliação. Numerosos DIs foram propostos usando a propagação de ondas no domínio do tempo. A raiz do desvio quadrado médio (RMSD) ou também chamada de norma euclidiana Giurgiutiu e Roges (1998), Park, Yun e Roh (2006), Su e Ye (2009), DeLuca et al.

(2020), o desvio percentual médio absoluto (MAPD) Tseng e Naidu (2002) covariância (COV) Monnier (2006) e o desvio do coeficiente de correlação (CCD) Tseng e Naidu (2002), Giurgiu-tiu (2014b), Stawiarski e Muc (2019) são as DIs mais utilizadas. Barreto et al. (2021) propuseram DIs normalizadas que avaliam sinais da estrutura no domínio do tempo. Eles também investigam o efeito do ruído nas medições na estimativa de DIs. Em Sinou (2009) é apresentando um revisão de trabalhos que utilizam parâmetros modais de estruturas e sistemas, bem como diversas técnica de DIs que utilizam característica dinâmica.

OWOLABI G.; SWAMIDAS e SESHADRI (2003) e KIN e STUBBS (2003) utilizaram respostas dinâmicas medidas de vigas danificadas para detectar a presença de uma trinca e determinar sua localização e tamanho. Maia J. M. M. Silva (2003), Maia N.M.M. (2011) propuseram um indicador de quantificação de dano relativo usando uma adaptação do RVAC. Técnicas vastamente abordadas na literatura são a função de correlação de forma global (GSC), a função de correlação de amplitude global (GAC), a primeira função de correlação de amplitude global (AIGSC) e a segunda função de correlação de amplitude global (AIGAC) Zang C. e Imregun (2001), Critério de garantia de resposta de frequência (FRAC) Heylen e Lammens (1996b), Critério de garantia de domínio de frequência (FDAC), Critério de garantia de vetor de resposta (RVAC) PASCUAL R.; GOLINVAL e RAZETO (1997), PASCUAL e GOLINVAL (1999), e Método de curvatura de resposta de frequência (PALACZ; KRAWCZUK, 2002). Todas essas usam a diferença entre estruturas FRF danificadas e não danificadas para localizar ou estimar danos (SINOUE, 2009).

3 FUNDAMENTAÇÃO TEÓRICA

Buscando obter o modelo para os problemas estudados, este capítulo apresenta a teoria base da simulação numérica de viga saudável e viga trincada utilizando para simulação Método dos Elementos Espectrais, do inglês *Spectral Element Method* (SEM), para normalização dos dados gerados foi estudado dois tipos de índices de danos, relacionado aos parâmetros modais (frequência natural e FRF), e a teoria base dos algoritmos de ML abordados.

3.1 MÉTODO DO ELEMENTO ESPECTRAL

A formulação de um modelo para uma estrutura usando o SEM é similar ao Método dos Elementos Finitos. O SEM consiste no deslocamento exato da equação de onda da solução analítica no domínio da frequência, tornando-o mais adequado para resolver o problema da trinca. A vantagem do SEM é o número reduzido de elementos necessários para modelar o sistema em comparação com outros métodos computacionais e a solução exata do comportamento de um viga em alta frequência pode ser obtida com baixo esforço computacional. SEM tem sido usado em muitas aplicações de dinâmica estrutural, transmissão aérea (SOARES Y.M.F, 2022), material inteligente (MOURA B.B., 2022; MACHADO M.R., 2022), monitoramento estrutural (MACHADO M.R.; DOS SANTOS, 2021), entre outros.

3.1.1 Elemento Espectral

Os deslocamentos nodais são \hat{v} e $\hat{\phi}$ e as forças nodais \hat{V} e \hat{M} presentes na viga de comprimento L . A Figura 3.1 ilustra um modelo de elemento espectral de viga saudável de dois nós com dois graus de liberdade por nó e duas cargas nodais por nó.




Figura 3.1. Elemento espectral de viga de dois nós (MACHADO M.R.; DOS SANTOS, 2021)

A viga é assumida como esbelta com deslocamento nodal transversal e rotacional, cisa-

lhamento e forças nodais de momento. Desprezando as deformações de cisalhamento, a equação diferencial do movimento em sua forma espectral pode ser escrita como

$$\frac{d^4 \hat{v}}{dx^4} - k^4 \hat{v} = F, \quad (3.1)$$

A solução geral da equação (3.1) para este elemento é dada por

$$\hat{v}(x, \Omega) = a_1 e^{-ikx} + a_2 e^{-kx} + a_3 e^{-ik(L-x)} + a_4 e^{-k(L-x)}, \quad (3.2)$$

onde,

$$\mathbf{e}(x, \Omega) = [e^{-ikx} \quad e^{-kx} \quad e^{-ik(L-x)} \quad e^{-k(L-x)}],$$

$$\mathbf{a} = [a_1 \quad a_2 \quad a_3 \quad a_4]^T,$$

sendo L o comprimento da viga. Os números de onda, k , k_1 e k_2 são dados por

$$k^2 \equiv \sqrt{\frac{\Omega^2 \rho A}{EI}}, \quad k_1 = \pm k, \quad k_2 = \pm ik, \quad (3.3)$$

onde Ω é a frequência circular, E é o módulo de Young, A é a área da seção transversal, ρ é a densidade, I é o momento de inércia e $i = \sqrt{-1}$. Usando um módulo de Young complexo, $E_c = E(1 + i\eta)$, introduz-se amortecimento estrutural interno onde η é o fator de perda estrutural histerética. Os deslocamentos nodais espectrais e as rotações nodais espectrais de um viga de Euler-Bernoulli podem ser alocados a um vetor de deslocamento \mathbf{d} como no nó 1 ($x = 0$) e no nó 2 ($x = L$)

$$\mathbf{d} = \begin{Bmatrix} \hat{v}_1 \\ \hat{\phi}_1 \\ \hat{v}_2 \\ \hat{\phi}_2 \end{Bmatrix} = \begin{Bmatrix} \hat{v}(0) \\ \hat{v}'(0) \\ \hat{v}(L) \\ \hat{v}'(L) \end{Bmatrix} = \begin{Bmatrix} e(0, \Omega) \\ e'(0, \Omega) \\ e(L, \Omega) \\ e'(L, \Omega) \end{Bmatrix} \quad (3.4)$$

onde $\mathbf{a} = \mathbf{H}_B(\Omega)^{-1} \mathbf{d}$, e

$$\mathbf{H}_B(\Omega) = \begin{bmatrix} 1 & 1 & e^{-ikL} & e^{-kL} \\ -ik & -k & ik e^{-ikL} & k e^{-kL} \\ e^{-ikL} & e^{-kL} & 1 & 1 \\ -ik e^{-ikL} & -k e^{-kL} & ik & k \end{bmatrix}.$$

O deslocamento dependente da frequência dentro de um elemento é interpolado a partir do vetor de deslocamento nodal \mathbf{d} , eliminando o vetor constante, é expresso por

$$\hat{v} = e(x, \Omega) H_B^{-1}(\Omega) \mathbf{d}. \quad (3.5)$$

As forças de cisalhamento e os momentos de flexão definidos para a viga estão relacionados

às forças e momentos definidos em uma forma nodal espectral como

$$f = \begin{Bmatrix} \hat{V}_1 \\ \hat{M}_1 \\ \hat{V}_2 \\ \hat{M}_2 \end{Bmatrix} = \begin{Bmatrix} -V(0) \\ -M(0) \\ V(L) \\ M(L) \end{Bmatrix} = \begin{Bmatrix} -\hat{v}(0)''' \\ -\hat{v}(0)'' \\ \hat{v}(L)''' \\ \hat{v}(L)'' \end{Bmatrix}. \quad (3.6)$$

onde, ao aplicar condições de contorno,

$$f = EI \begin{Bmatrix} -ik^3 & k^3 & ie^{-ikL}k^3 & e^{-kL}k^3 \\ k^2 & -k^2 & e^{-ikL}k^2 & -e^{kL}k^2 \\ ie^{-ikL}k^3 & -e^{kL}k^3 & -ik^3 & k^3 \\ -e^{-ikL}k^2 & e^{-kL}k^2 & -k^2 & k^2 \end{Bmatrix} \mathbf{a} = G(\Omega)\mathbf{a}. \quad (3.7)$$

Ao relacionar as forças nodais com o deslocamento nodal, tem-se

$$\mathbf{f} = \mathbf{G}(\Omega)\mathbf{H}_B^{-1}(\Omega)\mathbf{d} = \mathbf{S}_B(\Omega)\mathbf{d} \quad (3.8)$$

onde $\mathbf{S}_B(\Omega) = \mathbf{G}(\Omega)\mathbf{H}_B^{-1}(\Omega)$ é a matriz de rigidez dinâmica do elemento espectral de viga de Euler-Bernoulli.

3.1.2 Elemento Espectral de Viga com trinca

A trinca é modelada pela flexibilidade adimensional local representada por θ que é calculada pelo teorema de Castigliano e pela lei da mecânica da fratura (TADA H.; PARIS, 1973). O elemento contém dois nós com dois graus de liberdade cada, onde L é o comprimento, L_1 é a posição da trinca em relação ao nó 1 e a é a profundidade da trinca, ilustrada na Figura 3.2.




Figura 3.2. Elemento espectral de viga rachado com dois nós (MACHADO M.R.; DOS SANTOS, 2021)

Para a viga trincada, a solução da Eq. (3.1) é dada por

$$\hat{v}^l(x) = A_1 e^{-i(k_1 x)} + B_1 e^{-(k_2 x)} + C_1 e^{-ik_1(L_1-x)} + D_1 e^{-k_2(L_1-x)} \quad (3.9)$$

$$\hat{v}^r(x) = A_2 e^{-ik_1(L_1+x)} + B_2 e^{-k_2(L_1+x)} + C_2 e^{-ik_1(L-(L_1+x))} + D_2 e^{-k_2(L-(L_1+x))} \quad (3.10)$$

onde \hat{v}^l e \hat{v}^r são os deslocamentos verticais à esquerda e à direita da trinca, respectivamente. Os coeficientes $A_1; B_1; C_1; D_1; A_2; B_2; C_2$ e D_2 são determinados por condições de contorno, da equação 3.11, 3.12 e 3.13.

Os coeficientes de a_i , ($i = 1 : 8$) podem ser calculados como uma função dos deslocamentos espectrais nodais, levando em conta as condições de contorno para o elemento. Assim, para o elemento de viga trincado devem ser consideradas as condições de contorno nas extremidade da viga e na posição da trinca conforme segue:

- No lado esquerdo do elemento para ($x = 0$):

$$\hat{v}^l(x) = \hat{v}_1, \frac{\partial \hat{v}^l(x)}{\partial x} = \hat{\phi}_1 \quad (3.11)$$

- Na posição da trinca são considerados o deslocamento e a rotação para $\hat{v}^l(x)$ então $x = L_1$, e para $\hat{v}^r(x)$ onde $x = 0$,

$$\begin{aligned} \hat{v}^l(x) &= \hat{v}^r(x) \\ \frac{\partial \hat{v}^r(x)}{\partial x} - \frac{\partial \hat{v}^l(x)}{\partial x} &= \theta \frac{\partial^2 \hat{v}^r(x)}{\partial x^2} \\ \frac{\partial \hat{v}^l(x)}{\partial x} &= \frac{\partial^2 \hat{v}^r(x)}{\partial x^2} \\ \frac{\partial^3 \hat{v}^l(x)}{\partial x^3} &= \frac{\partial^3 \hat{v}^r(x)}{\partial x^3} \end{aligned} \quad (3.12)$$

- No lado direito do elemento, assim ($x = L - L_1$)

$$\hat{v}^r(x) = \hat{v}_2, \frac{\partial \hat{v}^r(x)}{\partial x} = \hat{\theta}_2 \quad (3.13)$$

A partir dos deslocamentos e das cargas nodais, obtém-se a matriz de rigidez de forma semelhante ao elemento espectral de viga saudável. No entanto, a matriz de rigidez dinâmica do elemento espectral de viga rachado é escrita como

$$\begin{bmatrix} \hat{v}_1 \\ \hat{\theta}_1 \\ 0 \\ 0 \\ 0 \\ 0 \\ \hat{v}_2 \\ \hat{\theta}_2 \end{bmatrix} \begin{bmatrix} 1 & 1 & a & b & 0 & 0 & 0 & 0 \\ -ik & -k & ika & kb & 0 & 0 & 0 & 0 \\ a & b & 1 & 1 & -a & -b & -c & -d \\ iak - a\theta k^2 & bk - b\theta k^2 & -ik - \theta k^2 & -k - \theta k^2 & -ika & -kb & ikc & kd \\ -k^2 a & k^2 b & -k^2 & k^2 & k^2 a & -k^2 b & k^2 c & -k^2 d \\ -ik^3 a & -k^3 b & -ik^3 & k^3 & -ik^3 a & k^3 b & k^3 c & k^3 d \\ 0 & 0 & 0 & 0 & f & g & 1 & 1 \\ 0 & 0 & 0 & 0 & -ikf & -kg & ik & k \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \\ a_6 \\ a_7 \\ a_8 \end{bmatrix} \quad (3.14)$$

onde $a = e^{ikL_1}$, $b = e^{-ikL_1}$, $c = e^{-ik(L-L_1)}$, $d = e^{(L-L_1)}$, $f = e^{-ikL}$, $g = e^{-kL}$.

A Equação 3.14 recai na formulação geral do elemento, onde $d = H_c^1(\Omega)a$. Os coeficientes a_i , ($i = 1 : 8$) podem ser relacionados aos deslocamentos espectrais nodais pelas relações:

$$a_i = H_{ci}^{-1}(\hat{v}_1) + H_{ci2}^{-1}(\hat{\theta}_1) + H_{ci3}^{-1}(\hat{v}_2) + H_{ci4}^{-1}(\hat{\theta}_2) \quad (3.15)$$

Neste ponto, a matriz $H_c(\Omega)$ originalmente de dimensão 8x8 se reduz a uma matriz 8x4. Este processo se dá conforme a na Equação 3.15, onde H_{ci}^{-1} ($i= 1, 8; j = 1, 2, 7, 8$) representa os elementos da matriz inversa da Equação 3.14. As forças espectrais nodais podem ser representadas pela diferenciação dos deslocamentos espectrais \hat{v}^l e \hat{v}^r com relação a x , e então podem ser representadas como no caso geral, tal que $f = G_c(\Omega)a$ e na forma matricial como:

$$\begin{bmatrix} \hat{f}_1 \\ \hat{f}_2 \\ \hat{f}_3 \\ \hat{f}_4 \end{bmatrix} = \begin{bmatrix} ik^3 & -k^3 & ik^3a & k^3 & 0 & 0 & 0 & 0 \\ -k^2 & k^2 & ik^2a & k^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & ik^3f & ik^3g & -ik^3 & k^3 \\ 0 & 0 & 0 & 0 & -k^2f & k^2g & -k^2 & k^2 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ a_4 \\ a_5 \\ a_6 \\ a_7 \\ a_8 \end{bmatrix} \quad (3.16)$$

A partir das cargas e deslocamentos nodais, Equação 3.14 e Equação 3.16, a matriz de rigidez dinâmica dependente da frequência do elemento de viga de Euler-Bernoulli com uma trinca transversal aberta e não propagante pode ser calculada relacionando a força com o deslocamento nodais,

$$f_{[4x1]} = G_c(\Omega)_{[4x8]} H_c^{-1}(\Omega)_{[8x4]} d = S_c^{-1}(\Omega)_{[4x4]} d \quad (3.17)$$

sendo uma matriz 4x4 que descreve a matriz de rigidez dinâmica da viga trincada.

O coeficiente de flexibilidade da trinca θ é obtido pelo método de Castigliano, onde a flexibilidade na posição da trinca para um elemento espectral de viga unidimensional pode ser obtida por

$$c = \frac{72\pi}{bh^2} \int_0^{\bar{a}} \bar{a} f^2(\bar{a}) d\bar{a} \quad (3.18)$$

onde c coeficiente utilizado para obter a flexibilidade da fissura, b é a base e h é a altura da seção transversal da viga; α é a variação da profundidade da trinca; M é o momento fletor na posição da trinca e f é uma função de correção do fator de intensificação de tensão do modo I que é escrito como

$$f\left(\frac{\alpha}{h}\right) = \sqrt{\frac{2h}{\pi\alpha} \tan\left(\frac{\pi\alpha}{2h}\right) \frac{0.923 + 0.199(1 - \sin(\pi\alpha/2h))^4}{\cos(\pi\alpha/2h)}} \quad (3.19)$$

e $\bar{a} = a/h$ e $\bar{\alpha} = \alpha/h$ flexibilidade sem dimensão local é dada por

$$\theta = \frac{EIc}{L} \quad (3.20)$$

3.2 MÉTODOS DE ÍNDICE DE DANO USANDO PARÂMETROS MODAIS

Algumas técnicas de detecção de danos conseguem localizar e quantificar os danos ocorridos em uma estrutura usando as mudanças observadas em suas características dinâmicas. A vibração é utilizada como indicador sensível à integridade estrutural e pode ser usada para monitorar o surgimento de dano, neste caso a detecção de danos é realizada comparando-se dois estados da estrutura, uma considerada íntegra e a outra danificada por meio de sua assinatura de vibração. A identificação de danos por métodos vibracionais se baseia no fato de que o dano causa mudanças nas propriedades físicas de uma estrutura, como massa, amortecimento e rigidez, alterando a resposta dinâmica como a frequência natural, frequência de ressonância, forma do modo e FRF. Portanto, as mudanças nas características dinâmicas podem ser utilizadas como indicadores de danos quando comparadas à resposta original. Neste trabalho, o foco está nos índices de danos baseados em frequência natural e FRF.

3.2.1 Índice de dano baseado na frequência natural

A mudança na frequência natural é utilizada em métodos de detecção de danos para averiguar a integridade da estrutura. Quando existe um dano na estrutura a rigidez é reduzida e consequentemente a frequência natural diminui. A vantagem dessa técnica é que as medidas podem ser realizadas de forma rápida e fácil, tornando-se muito barata para procedimentos experimentais, devido ao grande número de pontos que são gerados. Além disso, é usado os desenvolvimentos analíticos ou modelos de elementos finitos para obter o comportamento dinâmico global do sistema não danificados. Permitindo assim a medição de pontos para detecção rápida e eficiente das alterações em frequências, e a identificação da localização e severidade do dano (SINOUE, 2009).

Lifshitz e Rotem (1969) realizou uma das primeiras pesquisas que propunha usa a mudança na frequência natural por meio de mudanças nos módulos dinâmicos para detectar danos em elastômeros. Hearn e Testa (1991) demonstraram que a mudança na i -ésima frequência natural pode ser aproximado pela equação 3.21, a expressão assume que o dano não altera a matriz de massa.

$$\Delta\omega_i^2 = \frac{(\epsilon_N(\Phi_i))^T \Delta k_n(\epsilon_N(\Phi_i))}{\Phi_i^T M \Phi_i} \quad (3.21)$$

onde, M é a matriz de massa, Φ_i define o vetor de forma do modo, i^{th} e $\epsilon_N(\Phi_i)$ o elemento vetor de deformação que é calculado a partir das formas de modo. kn é a mudança na matriz rigidez devido à presença de danos.

Alguns pesquisadores comparam a frequência natural da estrutura não danificada e danificada, relacionado a diminuição associada a frequência. Deste modo, as frequências naturais normalizadas que definem a proporção de danos frequência natural para a frequência natural não danificada da estrutura pode ser dada pela equação 3.22.

$$NNF_i = \frac{\omega_i^{danificada}}{\omega_i^{não-danificada}} \quad (3.22)$$

onde, $\omega_i^{danificada}$ e $\omega_i^{n\tilde{a}o-danificada}$ defino a i -ésima pulsação da estrutura não danificada e danificada, respectivamente. Também pode ser estudado as mudanças percentuais nas nas frequências naturais $\%C_i$ (equação 3.23), proposta por Sinou e Lees (2005).

$$\%C_i = 100 \times \frac{\omega_i^{n\tilde{a}o-danificada} - \omega_i^{danificada}}{\omega_i^{n\tilde{a}o-danificada}} \quad (3.23)$$

Nos dois casos, as frequências naturais da estrutura não danificadas precisam ser cuidadosamente estimadas para poder mostrar com precisão se as frequências medidas foram menores do que esperado. Quando a estrutura tem pequenas trincas ou locais específicos da trinca, variação percentual das frequências naturais pode ser muito baixa e inferior a 1%. Os resultados clássicos indicaram que a trinca tem baixo efeito se estiver situada próxima a um nó dos modos de vibração. A diminuição do fator $\%C_i$ é mostrada se a trinca estiver localizada onde o momento fletor do modo i^{th} é maior. Em seguida, aumente a profundidade da trinca, diminua o fator $\%C_i$, indicando perda de rigidez para a viga danificada.

Outro método semelhante ao anterior para estimar a severidade e a localização da trinca considera apenas a frequência das estruturas danificadas. Diante disso, é necessário o conhecimento das propriedades do material, como o módulo de Young e a densidade. Sinou (2007) definiu outro indicador baseado nas mudanças na razão de frequências, descrito na equação 3.24

$$\%_0\Psi_{i,j}^{danificada} = 100 \times \left(\frac{\omega_i^{n\tilde{a}o-danificada} - \omega_i^{danificada}}{\omega_j^{n\tilde{a}o-danificada} - \omega_j^{danificada}} \right) \quad (3.24)$$

Uma das vantagens desse fator $\%_0\Psi_{i,j}^{danificada}$ é que a razão de frequências para as estruturas não danificadas. Messina A. e Williams (1992) propuseram o Critério de Garantia de Localização de Danos, do inglês *Damage Location Assurance Criterion* (DLAC) com base sobre as mudanças nas frequências naturais, ver equação 3.25

$$DLAC(i) = \frac{|\Delta\omega_T^A \Delta\omega_B(i)|^2}{(\Delta\omega_T^A \Delta\omega_A)(\Delta\omega_B(i)^T \Delta\omega_B(i))} \quad (3.25)$$

onde, ω_A é o vetor de mudança de frequência experimental, ω_B a mudança teórica para dano que está situado na i -ésima posição.

Os valores da DLAC variam entre zero(indica nenhuma correlação) e um (correlação exata). Neste caso, a posição é definida quando a posição de i^{th} dá altos valores para o DLAC. Para danos múltiplos Messina A. e Contursi (1998) estendeu o DLAC, criando o Critério de Garantia de Localização de Danos Múltiplo, do inglês *Multiple Damage Location Assurance Criterion* (MDLAC)(equação 3.26), o objetivo é encontrar o vetor variável δx_i que torna o MDLAC igual a um, onde

$$MDLAC(i) = \frac{|\Delta\omega_T^A S_c \delta x_i|^2}{(\Delta\omega_T^A \Delta\omega_A)((S_c \delta x_i)^T (S_c \delta x_i))} \quad (3.26)$$

onde S_c define a matriz de sensibilidade que contém as derivadas de primeira ordem de n frequências naturais em relação a m variáveis de dano x .

3.2.2 Índice de dano baseado na função de resposta em frequência

Danos estruturais podem ser detectados usando a FRF que é uma razão entre a resposta da estrutura e a força aplicada, para classificar o estado danificadas e não danificadas. Os métodos disponíveis na literatura que usam a diferença entre estruturas FRF danificadas e não danificadas para localizar ou estimar danos, são eles: FRAC, Critério de Garantia de Amplitude de Frequência, do inglês *Frequency Amplitude Assurance Criterion* (FAAC), Critério de Forma Global, do inglês *Global Shape Criterion* (GSC), Critério de Amplitude Global, do inglês *Global Amplitude Criterion* (GAC), Integração Média GSC/GAC, do inglês *Average Integration GSC/GAC* (AIGSC, AIGAC) e Índice de Danos de Monnier, do inglês *Monnier's Damage Index* (Di).

O FRAC é um índice de dano que representa a correlação entre os sinais FRF de teste e referência (SAEED Z.; BERRUTI, 2021), onde uma correlação forte é indicada por 1 (nenhum dano é encontrado), enquanto a correlação mais baixa é indicada por 0 (severidade do dano). O FRAC é definido por

$$FRAC_{ij}(\omega) = \frac{\|H_{ij}^d(\omega)(H_{ij}^u(\omega))^*\|^2}{[H_{ij}^u(\omega)(H_{ij}^u(\omega))^*][H_{ij}^d(\omega)(H_{ij}^d(\omega))^*]} \quad (3.27)$$

Outro indicador de dano que utiliza a função de correlação no domínio da frequência é o FAAC (ZANG C.; IMREGUN, 2001; POLICARPO H.; MAIA, 2013), que é uma medida de diferenças de amplitude, esta segue a mesma ideia do anterior, podendo ser denotado como

$$FAAC_{ij} = \frac{2 \|H_{ij}^d(\omega) (H_{ij}^u(\omega))^*\|}{\left[(H_{ij}^u(\omega)) (H_{ij}^u(\omega))^* \right] + \left[(H_{ij}^d(\omega)) (H_{ij}^d(\omega))^* \right]} \quad (3.28)$$

O GSC e GAC proposto por Zang C. e Imregun (2001), Zang e Imregun (2003), Zang C. e Imregun (2003) foram utilizadas como índice de danos. Tanto o GSC quanto o GAC devem retornar valores entre zero e um para todas as frequências da mesma forma que o FRAC e FAAC visto anteriormente. Os indicadores GSC e GAC são definidos pelas Eq. (3.48) e Eq. (3.49)

$$GSC(\omega) = \frac{\|H_u^*(\omega)H_d(\omega)\|^2}{[H_u^*(\omega)H_u(\omega)] [H_d^*(\omega)H_d(\omega)]} \quad (3.29)$$

$$GAC(\omega) = \frac{2 \|H_u^*(\omega)H_d(\omega)\|}{[H_u^*(\omega)H_u(\omega)] + [H_d^*(\omega)H_d(\omega)]} \quad (3.30)$$

Além de GSC e GAC, Zang C. e Imregun (2003) calcula um único valor do índice de danos

definido como Integração Média das Funções GSC e GAC, definida nas Eq. (3.50) e Eq. (3.32)

$$AIGSC(\omega) = \frac{1}{N} \sum_{i=1}^N GSC(\omega_i) \quad (3.31)$$

$$AIGAC(\omega) = \frac{1}{N} \sum_{i=1}^N GAC(\omega_i) \quad (3.32)$$

onde N é o número da faixa de frequência. Os indicadores AIGSC e AIGAC são reais constantes entre zero e um para indicar dano total ou estrutura sem dano. ODiMonnier (2006) (Eq. (3.33)) e sua versão modificada proposta por Banerjee S. e Mal (2007), Banerjee S. e Mal (2009) (Eq. (3.34)). Ambos os DIs representa a diferença normalizada nos módulos entre duas FRFs em dois estados estruturais diferentes e retornam um único valor real entre zero e a unidade para uma determinada banda de frequência de interesse. No entanto, valores mais próximos de zero representam danos menores (sem indicação de dano ou saudável) enquanto que valores mais próximos de 1 representam danos maiores (danificado).

$$DI = \frac{\sum_{i=1}^{n_c} \|H_{ij}^u(\omega) H_{ij}^d(\omega)\|}{\sum_{i=1}^{n_c} \|H_{ij}^u(\omega)\|} \quad n_c = 1, 2, 3 \dots n. \quad (3.33)$$

$$DI_s = \left\| 1 - \frac{\left(H_{ij}^d(\omega)\right)^T * H_{ij}^d(\omega)}{\left(H_{ij}^u(\omega)\right)^T * H_{ij}^u(\omega)} \right\| \quad (3.34)$$

onde, n_c é a banda de frequência capturada do espectro, T indica a transposição do vetor FRF.

3.3 ETAPAS DO APRENDIZADO DE MÁQUINA

As etapas do ML usadas para identificar e quantificar os danos, são apresentados na Figura 3.3. O processo começa com a extração do conjunto de dados, apresentada na seção 4, seguida da divisão dos dados para treinamento e teste, para este trabalho foi usado 80% e 20%, respectivamente, e aplicação do algoritmo ML para classificar e fornecer informações sobre a identificação do dano e quantificação. Toda a implementação do ML de detecção de danos usando o aprendizado de máquina foi realizado com o pacote *scikit-learn* (PEDREGOSA et al., 2011) em Python.

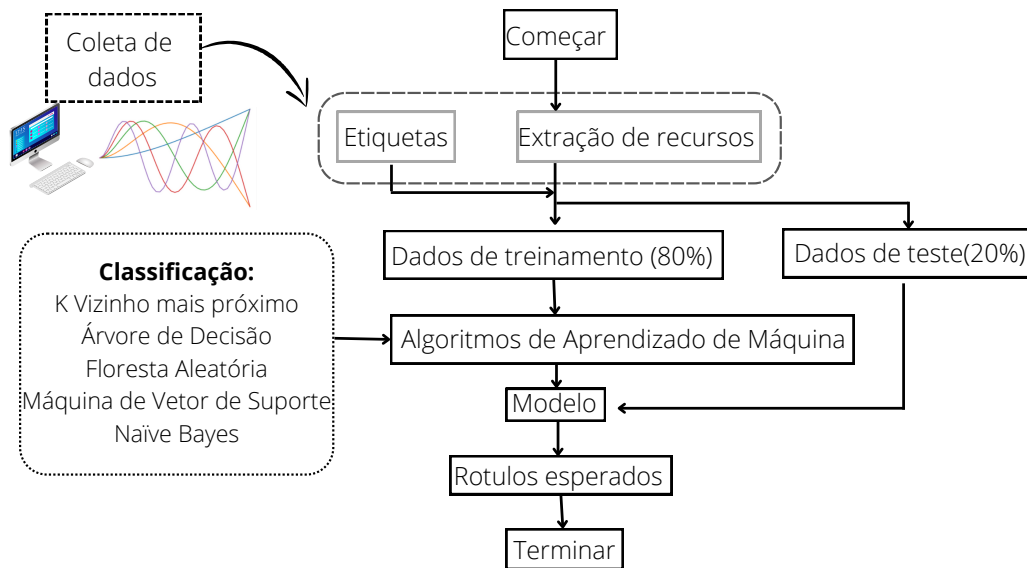


Figura 3.3. Fluxograma da utilização do algoritmo ML no processo SHM.

A ferramenta disponível no pacote *Scikit – learn* disponibiliza uma classificação binária ou multiclasse, onde está última é uma tarefa de classificação com múltiplas classes. Para o uso adequado desta ferramenta é primordial que o modelo seja selecionado corretamente, e só assim deve-se decidir qual tipo de algoritmo, supervisionado ou não supervisionado, que melhor abordará o problema. Então, escolhe-se um subconjunto de variáveis para treinar esses modelos sem nenhum ajuste de hiperparâmetro, buscando a melhor métrica, geralmente com menor tempo de treinamento (GÉRON, 2019). Nesse contexto, as métricas de performance são essenciais em várias etapas do processo de modelagem, por exemplo, na seleção do tipo de modelo, na avaliação do modelo final, no monitoramento, entre outras. Dessa forma, é necessário escolher a métrica adequada para o tipo de modelo e para o contexto.

Existem quatro métricas de avaliação, incluindo Acurácia (equação 3.35), Precisão (equação 3.36), Recall (equação 3.37) e F1-score (equação 3.38), para avaliação da performance de um modelo de classificação. Dessa forma, escolhe-se o melhor para avaliar o modelo de acordo com o contexto do problema. O *scikit – learn* apresenta algumas formas de computar as quatro métricas a partir do parâmetro *average* da função *precision, recall, f1_score, support* disponível na biblioteca. Os valores do parâmetro utilizados foram *micro*, *macro* e *none*. Com o valor *micro*, computa-se as métricas contando o verdadeiros positivos, os falsos positivos, os verdadeiros negativos e os falsos negativos de forma global sem distinguir por classe, por exemplo, anomalia e não anomalia. Por outro lado, o valor *macro* calcula as métricas para todas as classes, então, faz uma média aritmética entre os valores das classes. Por fim, o valor *none* apenas calcula as métricas para cada classe sem fazer nenhuma ponderação (PEDREGOSA et al., 2011).

$$Acuracia(y, \hat{y}) = \frac{VP + VN}{VP + FP + VN + FN} \quad (3.35)$$

$$Precisao(y, \hat{y}) = \frac{VP}{VP + FP} \quad (3.36)$$

$$Recall(y, \hat{y}) = \frac{VP}{VP + FN} \quad (3.37)$$

$$F_1 = 2 \times \frac{Precisao \times Recall}{Precisao + Recall} \quad (3.38)$$

onde y e \hat{y} representam os rótulos verdadeiros e os rótulos previstos. verdadeiros positivos (VP) e falsos positivos (FP) são o número de verdadeiros positivos e são o número de falsos positivos. verdadeiros negativos (VN) e falsos negativos (FN) são verdadeiros negativos e falsos negativos, respectivamente.

O desempenho geral do algoritmo é avaliado pela precisão, que é a proporção de condições de saúde e danos que foram classificadas corretamente. Portanto, apenas a precisão não fornece informações suficientes para diagnosticar possíveis erros cometidos pelos algoritmos. Portanto, para entender as métricas de classificação, é necessário compreender a matriz de confusão. A matriz de confusão é usada para rastrear a classificação do conjunto de dados, possui linhas e colunas que representam a previsão de classe da severidade do dano. Esta matriz permite compreender os padrões de detecção de danos e erros de classificação das técnicas de ML. Os elementos da matriz indicam as condições dos dados como VP, VN, FP e FN. A diagonal da matriz de confusão representa a taxa correta de detecção de dano. Assim, o modelo ideal possui valores altos na diagonal e valores mínimos nas demais. A Figura 3.4 apresenta um exemplo de matriz de confusão para um algoritmo.

		Valor Previsto	
		Sim	Não
Real	Não	VP	FN
	Sim	FP	VN

Figura 3.4. Matriz de confusão.

3.4 ALGORITMOS DE APRENDIZADO DE MÁQUINA

Nesta seção é apresentado os principais algoritmos de ML supervisionados, que foram estudados no trabalho, sendo eles kNN, SVM, DT, RF e NB.

3.4.1 Classificador K-vizinho mais próximo

KNN é um dos métodos de aprendizado supervisionado mais simples (CUTLER; DICKENSON, 2020a; MALEKLOO et al., 2021), é amplamente usado para reconhecimento de padrões (KURIAN; LIYANAPATHIRANA, 2020). kNN pode ser usado para classificação e regressão, onde dados com rótulos discretos geralmente usam classificação e dados com regressão de rótulos contínuos. O algoritmo k-NN, em sua versão mais simples, considera apenas exata-

mente um vizinho mais próximo, que é o ponto de dados de treinamento mais próximo do ponto que queremos prever. A previsão é então simplesmente a saída conhecida para este ponto de treinamento. Dependendo do valor de k , cada amostra é comparada para encontrar similaridade ou proximidade com k amostras vizinhas. Por exemplo, quando $k = 3$, as amostras individuais são comparadas com as três amostras mais próximas e, portanto, a amostra desconhecida é classificada de acordo com a figura 3.5. A escolha ótima do valor de k é altamente dependente dos dados, em geral, um maior suprime os efeitos do ruído, mas torna os limites de classificação menos distintos.

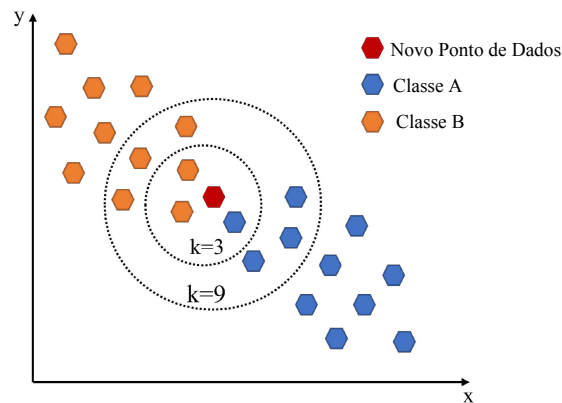


Figura 3.5. Classificador K-Vizinho Mais Próximo.

A classificação é calculada a partir de uma votação por maioria simples dos vizinhos mais próximos de cada ponto: a um ponto de consulta é atribuída a classe de dados com mais representantes dentro dos vizinhos mais próximos do ponto, e para isso, utiliza-se uma métrica entre os pontos espaços (CUTLER; DICKENSON, 2020a). As métricas mais comuns usadas na literatura são **Euclidiano**, a distância entre dois vetores, **Braycurtis**, a distância entre duas matrizes 1-D, **Manhattan**, a distância entre dois pontos é a soma das diferenças absolutas de suas coordenadas cartesianas. **Cosseno**, a métrica de distância é usada principalmente para calcular a similaridade entre dois vetores. É medido pelo cosseno do ângulo entre dois vetores e determina se dois vetores estão apontando na mesma direção.

$$\text{Euclidiano} - d(x_i, y_i) = \sqrt{\sum_{l=1}^d (x_i^l - y_i^l)^2} \quad (3.39)$$

$$\text{Braycurtis} - d(x_i, y_i) = \frac{\sum |x_i - y_i|}{\sum |x_i + y_i|} \quad (3.40)$$

$$\text{Manhattan} - d(x_i, y_i) = \sum_{i=1}^n |x_i - y_i| \quad (3.41)$$

$$\text{Cosine} - d(x_i, y_i) = \frac{\sum_i^n x_i y_i}{\sqrt{\sum_i^n x_i^2} \sqrt{\sum_i^n y_i^2}} \quad (3.42)$$

onde x_i e y_i são objetos representados por vetores no espaço \mathbb{R}^d , e x_i^l e y_i^l são elementos dos

vetores, que correspondem aos valores da coordenada l (atributos). Após identificar as k classes de dados mais próximas, o maior número de classes é determinado como a nova classe de dados. A classe a ser determinada depende do valor de k , e a precisão da classificação pode mudar de acordo com o valor de k . Assim, com o hiperparâmetro definido como ' $k=3$ ', os valores da função peso são definidos como uniformes, representando que todos os pontos em cada vizinhança são ponderados igualmente. O tamanho da planilha que afeta a construção e a velocidade da consulta é definido como 30.

3.4.2 Árvore de Decisão e Floresta Aleatória

O algoritmo supervisionado de árvore de decisão pode visar variáveis categóricas, como a classificação de uma declaração danificada ou não danificada e variáveis contínuas como regressão para comparar o sinal com o estado saudável do sistema (MALEKLOO et al., 2021). Aprender uma árvore de decisão significa aprender a sequência de perguntas se/senão que nos leva à resposta verdadeira mais rapidamente. Uma árvore contém um nó raiz representando os recursos de entrada e os nós internos com informações de dados significativas. Cada nó (também chamado de folha ou nó terminal) representa uma pergunta que contém a resposta. O processo iterativo é repetido até que o último nó (nó folha) seja alcançado de forma que o nó se torne impuro, de acordo com o esquema da figura 3.6 (CUTLER; DICKENSON, 2020b).

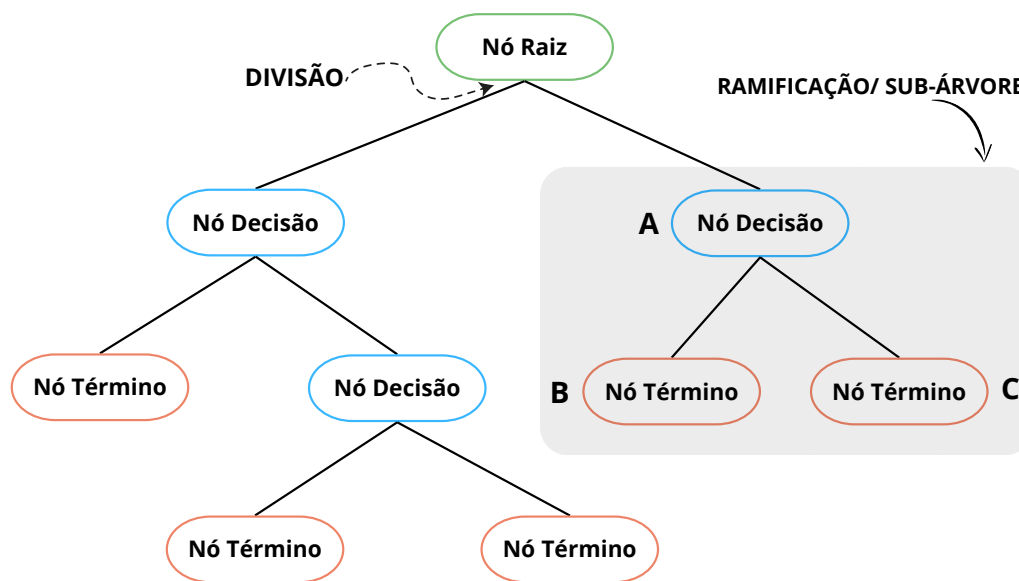


Figura 3.6. Esquema do classificador árvore de decisão.

Os dados ficam na forma de recursos binários em nosso aplicativo e um procedimento de classificação é executado. No entanto, para casos de múltiplos danos a seleção de nó raiz e nó interno não é trivial. Os resultados satisfatórios do algoritmo de aprendizado por árvore de decisão irá depender do critério de escolha dos atributos, a seleção desses critérios é feita de acordo com medidas estatísticas de seleção de atributos mais relevantes para a classificação,

tais como Entropia e Índice de Gini (MALEKLOO et al., 2021), descritas a seguir

1. **Entropia** é o ganho de informação esperada, que caracteriza a impureza de uma coleção arbitrária de exemplos. O cálculo da entropia total de um conjunto, é referente ao seu atributo que delimita a classe das amostras, sendo a classificação final, definido na equação 3.43. A equação 3.44 refere-se ao cálculo da entropia para cada atributo de decisão utilizado para classificar suas amostras.

$$info(S) = entropia(S) = - \sum_{j=1}^k \left(\frac{C_j}{S} \right) \times \log_2 \left(\frac{C_j}{S} \right) \quad (3.43)$$

$$info(S, A) = - \sum_{i=1}^m \left(\frac{S_i}{S} \right) \times info(S_i) \quad (3.44)$$

Onde:

C_j : quantidade de amostras da classe.

S : quantidade total das amostras.

S_i : quantidade de amostras para a partição.

m : quantidade de partições.

$info(S_i)$: entropia total para a partição.

2. **Índice de Gini** é uma medida bastante conhecida, proposta por Corrado Gini, em 1912. Se trata de um índice de dispersão estatística que mede a heterogeneidade dos dados. A equação 3.45 é o índice Gini, indicado para um conjunto de dados S , que contém n registros, cada um com uma classe $C - i$. Se o conjunto S for particionado em dois ou mais subconjuntos S_i , O índice Gini dos dados particionados será definido pela equação 3.46 .

$$gini(S) = i - \sum_{i=1}^K p(C_i|n)^2 \quad (3.45)$$

$$gini(S) = \sum_{i=1}^K \frac{n_i}{n} gini(S_i) \quad (3.46)$$

Onde:

p_i : probabilidade relativa da classe C_i em S .

n : número de registros no conjunto S .

K : número de classes.

n_i : número de registros no subconjunto S_i .

Quando todos os registros pertencem a mesma classe, o índice é igual a zero. Em compensação, quando o índice se aproxima de um, os registros são distribuídos entre as classes. Quando

utiliza o critério Gini, podem utilizar o menor valor do índice para a classificação, tendendo a isolar em um ramo os registros que representam a classe mais frequente. Enquanto, que o critério de entropia, balanceia-se o número de registros em cada ramo.

O algoritmo floresta aleatória é um classificador de conjunto que consiste em muitas árvores de decisão, onde a saída da classe é o nó composto por árvores individuais. O RF tem alta precisão de predição, estabilidade robusta, boa tolerância a dados ruidosos e a lei dos grandes números eles não superajustam, e tem sido usado para detecção de danos estruturais e tem mostrado um melhor desempenho (ZHOU Q.; LEI, 2013). A principal vantagem do RF em relação ao DT é que cada árvore é construída a partir de um conjunto de dados de treinamento e a divisão de nós também acontece para um subconjunto aleatório de atributos. No final, um simples a média de todas as previsões pode ser usada para encontrar a mais resultados prováveis do modelo. RF funciona melhor se as árvores não são fortemente dependentes uns dos outros e mostram um fraco correlação entre os atributos selecionados na divisão nó. Ao contrário de DT, RF não é de todo interpretável e, para grandes conjuntos de dados, eles podem levar muito tempo para treinar.

Os parâmetros desses algoritmos são caracterizados pelo número de árvores na floresta de cem e a profundidade máxima definida para três. A divisão mínima da amostra é dois, o que denota o número mínimo de amostras necessárias para dividir um nó interno. A folha de amostras mínimas representa as amostras de treinamento em cada ramificação direita e os valores da folha de amostra mínima são definidos como um. O valor máximo dos recursos é definido como 'auto', representando o número de recursos a serem considerados ao procurar a melhor divisão.

3.4.3 Máquina de Vetor de Suporte

As máquina de vetores de suportes são técnicas de aprendizado de máquina supervisionadas desenvolvidas a partir da teoria de aprendizado estatístico que podem ser usadas para a classificação e regressão de dados agrupados. No caso de classificação linear, com duas classes, seja $\{(x_i, y_i), \dots, (x_n, y_n)\}$, um conjunto de dados de treinamento com n observações, onde x_i representa o conjunto de vetores de entrada e $y_i(+1, -1)$ é o rótulo de classe de x_i , o hiperplano é uma linha reta que separa as duas classes com uma distância marginal (como visto na Fig. 3.7). O propósito de um SVM é construir um hiperplano usando uma margem, definida como a distância entre o hiperplano e os pontos mais próximos que se encontram ao longo da linha marginal denominados como vetores de suporte (OTCHERE T. O. ARBI GANAT; RIDHA, 2020).

Pode-se definir o hiperplano pela Eq. (3.47), onde temos o produto escalar entre x e w adicionado ao termo b :

$$D(x) = w^T \cdot x + b = c \quad \text{for} \quad -1 < c < 1 \quad (3.47)$$

onde x representa os pontos dentro do hiperplano, w são os pesos que determinam a orientação do hiperplano e b é o bias ou deslocamento do hiperplano. Quando $c = 0$, o hiperplano de separação está no meio dos dois hiperplanos com $c = 1$ e -1 .

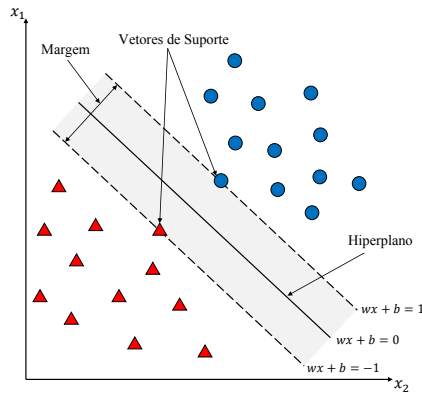


Figura 3.7. Operação do algoritmo SVM.

O objetivo de um SVM é maximizar a margem de separação de dados da minimização de $\|w\|$. Este problema de otimização pode ser obtido como o problema de programação quadrática dado pela Eq. (3.48).

$$\min \frac{\|w\|^2}{2} \quad \text{s.t.} \quad y_i(w^T \cdot x_i + b) \geq 1 \quad \text{for } i = 1, 2, \dots, n \quad (3.48)$$

onde $\|w\|$ é a norma euclidiana.

Em situações reais, os aplicativos geralmente não são separáveis linearmente, isso ocorre devido à presença de ruído nos dados ou o problema pode ser não linear. A adoção de margens suaves relaxa as restrições impostas ao problema de otimização com a introdução de variáveis de folga, permitindo que alguns dados tenham uma ou poucas instâncias mal classificadas com menos violações de margem. No SVM, para controlar a minimização de erros e a maximização da margem de classificação, é usado o parâmetro C , chamado de penalidade ou regularização. O valor de C controla a margem, o número de vetores de suporte e os erros de treinamento e teste, tendo grande influência no desempenho de classificação do SVM. Pequenos valores de C maximizam a margem que pode levar ao underfitting e um grande valor de C minimiza a margem que pode levar ao overfitting (THARWAT, 2019).

O SVM pode ser aplicado a problemas de classificação não linear usando funções kernel, onde projeta o espaço amostral em um espaço dimensional superior onde os dados são linearmente separáveis. Os núcleos mais usados são Polinomial (Eq.3.49) e Função de base radial Gaussiana (RBF) (Eq.3.50) (THARWAT, 2019),

$$M(x_i, y_i) = ((x_i^T y_i) + 1)^d \quad (3.49)$$

onde x_i e y_i são vetores no espaço de entrada, e d é o grau do núcleo polinomial.

$$M(x_i, y_i) = e^{-\gamma \|x_i - y_i\|^2} \quad (3.50)$$

onde γ é um parâmetro positivo para controlar a influência de novos recursos no limite de decisão, e $\|x_i - y_i\|^2$ é a distância euclidiana entre x_i e y_i .

Os hiperparâmetros de configuração deste algoritmo usaram a função de kernel linear, rbf e poly, e uma pesquisa de grade para determinar o $C=100$, que é um parâmetro de penalidade. A estratégia multiclasse utilizada foi um contra um.

3.4.4 Bayes Ingênuo

Os métodos Bayes Ingênuo são um conjunto de algoritmos de ML, sendo um método de classificação probabilístico baseado no teorema de Bayes com a suposição de independência entre atributos, considerada uma técnica simples para construção de classificadores com modelos que atribuem rótulos de classes a instâncias do problema, representadas como vetores de valores de atributos, onde os rótulos de classes são desenhados de algum conjunto finito. O teorema de Bayes estabelece a seguinte relação, dada a variável de classe y e vetor de característica dependente através x_1, x_n (ZHANG, 2004).

$$P(y|x_1, \dots, x_n) = \frac{P(y)P(x_1, \dots, x_n|y)}{P(x_1, \dots, x_n)} \quad (3.51)$$

Os classificadores Bayes Ingênuo funcionam muito bem em muitas situações reais, pois ele requer uma pequena quantidade de dados de treinamento para estimar os parâmetros necessários. Além de serem extremamente rápidos em comparação com métodos mais sofisticados. Foi escolhido três classes de Bayes Ingênuo no *scikitlearn*, Gaussian-NB, Multinomial-NB e Bernoulli-NB (FLACH; LACHICHE, 2004). Em seguida, cada classe foi descrita detalhadamente:

1. **Gaussiano-NB** implementa o algoritmo Gaussian Bayes Ingênuo para classificação, assumindo uma distribuição gaussiana, equação 3.52

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (3.52)$$

Os parâmetros σ_y e μ_y são estimados usando a máxima verossimilhança.

2. **Multinomial-NB** implementa o algoritmo para dados distribuídos multinomialmente, pode ser usada para classificar textos. A distribuição é parametrizada por vetores $\theta_y = (\theta_{y1}, \dots, \theta_{yn})$, onde n é o número de recursos e θ_{yi} é a probabilidade $P(x_i|y)$ de característica aparecendo em uma amostra pertencente à classe. Os parâmetros θ_y é estimado por uma versão suavizada de máxima verossimilhança, ou seja, contagem de frequência relativa (MCCALLUM; NIGAM, 1998).

$$\hat{\theta}_{yi} = \frac{N_{yi} + \alpha}{N_y + \alpha n} \quad (3.53)$$

onde $N_{yi} = \sum_{x \in T} x_i$ é o número de vezes que o recurso i aparece em uma amostra de classe y no conjunto de treinamento T , e $N_y = \sum_{i=1}^n N_{yi}$ é a contagem total de todos os recursos para a classe y . $\alpha \geq 0$ é considerado piores de suavização, $\alpha = 1$ é chamado

de alisamento de Laplace, enquanto $\alpha < 1$ é chamado de alisamento de Lidstone.

3. **Bernoulli-NB** implementa os algoritmos com distribuições multivariadas de Bernoulli, isto significa, que pode haver vários recursos, mas cada um é considerado uma variável de valor binário (Bernoulli, booleano)(MCCALLUM; NIGAM, 1998). BernoulliNB pode funcionar melhor em alguns conjuntos de dados, especialmente aqueles com documentos mais curtos. É aconselhável avaliar ambos os modelos, se o tempo permitir. A seguir está a equação 3.54

$$P(x_i|y) = P(x_i = 1|y)x_i + (1 - P(x_i = 1|y))(1 - x_i) \quad (3.54)$$

Os classificadores Bayes Ingênuo são altamente escaláveis, exigindo um número de parâmetros lineares no número de variáveis em um problema de aprendizado. O treinamento de máxima verossimilhança pode ser feito avaliando uma expressão de forma fechada, ou seja, pode-se trabalhar com o modelo ingênuo de Bayes sem aceitar a probabilidade bayesiana ou usar qualquer método bayesiano. Uma vantagem do Bayes Ingênuo é poder treinar um modelo com um pequeno número de amostras (RUSSELL S., 2003).

4 RESULTADOS SIMULAÇÃO NUMÉRICA

Os dados são essenciais para ciência e aprendizado de máquina, por essa razão precisam ser os mais confiáveis possíveis. É recomendado que as amostras de dados sejam maiores de que 50 elementos, ou seja, quanto mais dados, a amostra é considerada mais significativa em relação a todo o conjunto de elementos. Gerar um conjunto de dados confiáveis começa pela definição e identificação de um problema, definido no capítulo 1. O problema se baseia em alcançar o nível 3 do SHM em vigas metálica engastada, a partir disso, os dados são extraídos da estrutura usando parâmetros modais e posterior normalização dos dados usando alguns índices de dano, detalhados na seção 2 do capítulo 3. O processo de normalização se dá por alterar a escala para que o menor valor seja 0(zero) e maior valor 1(um). Isso não altera a relação entre os dados, mas influencia no estudo, pois alguns algoritmos não funcionam bem se os valores máximo ou mínimos não estiverem normalizados. Desde modo, percebe-se a importância de tratar e preparar os dados para a escolha certa do algoritmo. Neste capítulo é mostrado o tratamento dos dados da simulação numérica e o resultado do monitoramento estrutural via algoritmos de ML.

4.1 CONJUNTO DE DADOS

Os métodos de detecção de danos foram aplicados para identificar e quantificar danos estruturais por meio de alterações na assinatura do comportamento dinâmico do sistema. Quando uma trinca se propaga em uma estrutura, ela modifica a rigidez local, o amortecimento e a massa, alterando a resposta dinâmica e os parâmetros modais do sistema. Portanto, essas mudanças nas características dinâmicas podem ser usadas como indicadores de danos quando comparados ao sinal original. Assim, os índices de danos baseados na frequência natural das vigas e na FRF são usados para detecção de danos neste trabalho.

O sistema simulado é uma viga em balanço modelada pelo método dos elementos espectrais, brevemente descrito na seção 1 do Capítulo 3. A viga é excitada com uma força unitária aplicada na extremidade livre, e a resposta é obtida no mesmo ponto. A viga tem comprimento $L = 1m$, largura de 0,01 m e altura de 0,03 m. A trinca localiza-se em $L_1 = 0,5L$, e a profundidade da trinca varia de 5 a 35% da seção transversal da viga. As propriedades do material são módulo de Young de 2,1 GPa e densidade de massa de 7800 kg/m³. A trinca estrutural reduz a rigidez do sistema induzindo uma mudança nas frequências de ressonância, que podem afetar diferentes formas modais dependendo da localização da trinca. A Figura 4.1 demonstra o efeito de uma trinca com diferentes graus de severidade na resposta dinâmica

da viga, sendo que neste caso as formas quarto, quinto e sexto modo foram as mais afetadas pelo dano. Além disso, os FRFs e as frequências naturais, estimados a partir da resposta dinâmica, são empregados para calcular os DIs.

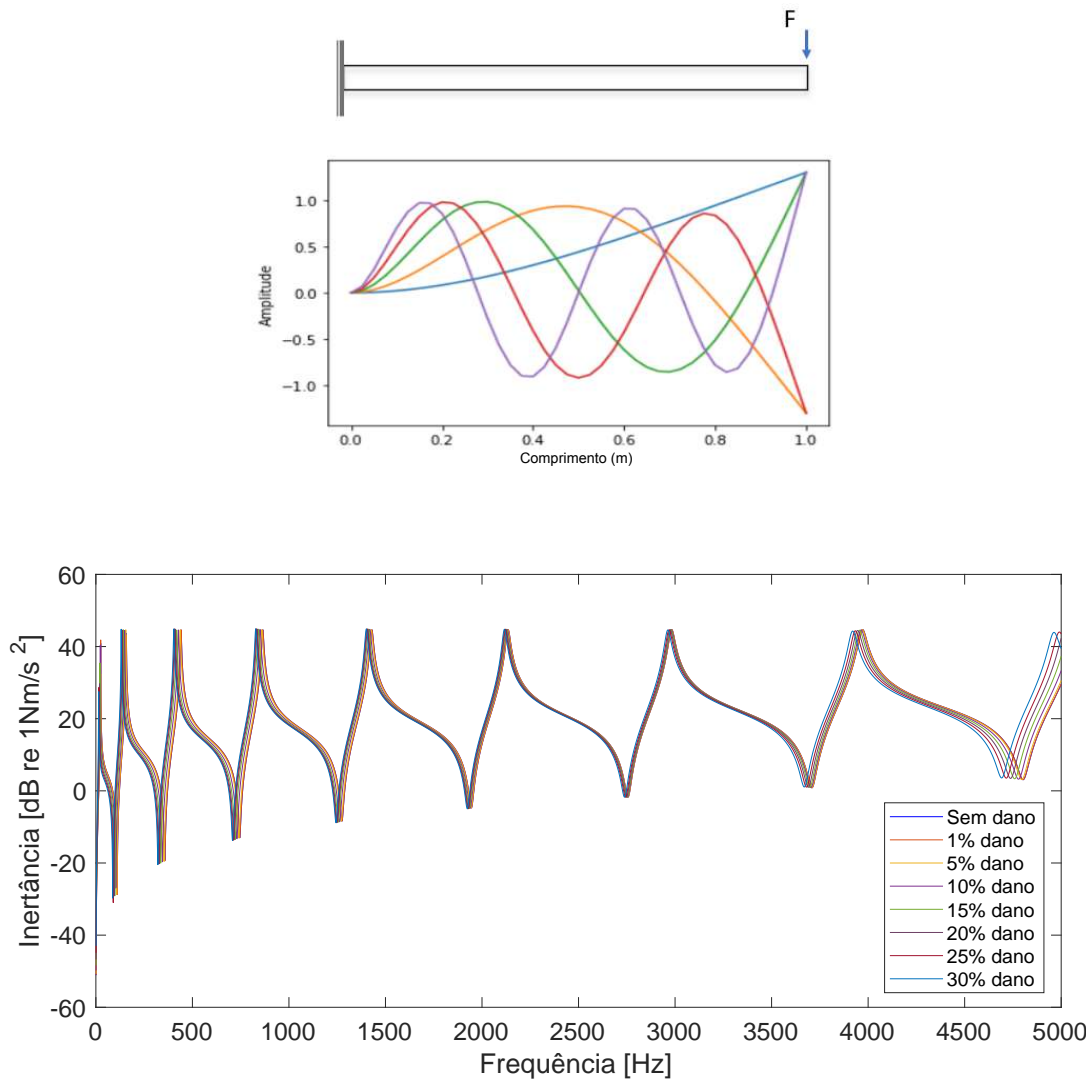


Figura 4.1. Projeto esquemático da viga em balanço, a forma modal e as FRFs de inércia para diferentes níveis de profundidade de fissura.

O Índice de dano (DI) é formulado comparando-se um sinal de referência, geralmente derivado do sistema considerado sem danos ou com assinatura saudável, ao fornecido pelo sistema na presença de descontinuidade ou dano (BARRETO et al., 2021). Várias abordagens do DI foram desenvolvidas para extrair características de sinal em diferentes domínios visando a identificação de dano estrutural com base em um indicador que descreve o dano, detalhados na seção 2 do capítulo 3. Os DIs estão associados às técnicas de estimativa para quantificação de danos e revelam informações importantes sobre o estado de saúde estrutural. Portanto, a DI se apresenta em valores entre zero à um, onde a um não acusa nenhum dano. Um valor menor até zero indica a presença de uma trinca e sua severidade dentro do cenário de análise. Este trabalho utiliza o DI como informação de estrutura para os dados de

treinamento e teste nos algoritmos multiclasse de ML. A trinca na estrutura reduz sua rigidez induzindo uma mudança nas frequências de ressonância, que podem afetar diferentes formas modais dependendo da localização da trinca.

4.1.1 Conjunto de dados 1: DI estimado a partir da frequência natural

Numerosos métodos consideraram mudanças de frequência natural para detectar anomalias e danos estruturais. Danos estruturais reduzem sua rigidez local e induzem uma mudança de frequência natural (MACHADO M. R.; SANTOS, 2018). Uma maneira de formular o DI a partir da normalização da frequência natural é descrita por (SINOUE, 2009), que relaciona a frequência natural do sistema não danificado com o estado sob dano. Assim é empregado para criar um indicador para classificar a integridade da estrutura, visto na equação 3.23 do capítulo 3.

O conjunto de dados foi construído usando três frequências naturais da viga metálica engastada, que para o estado não danificado são $\omega_4 = 865$ Hz, $\omega_5 = 1430$ Hz e $\omega_6 = 2136$ Hz, relacionado às formas do quarto, quinto e sexto modo. Na elaboração do conjunto de dados, valores aleatórios de DIs foram gerados para o treinamento e teste de algoritmos de ML em um total de 200 amostras. A flexibilidade da fissura empregada para modelar a trinca foi considerada como variável aleatória modelada com distribuição normal e coeficiente de variação de 10%. Table 4.1 lista as frequências naturais da viga danificada com uma profundidade de trinca de 5, 10, 15, 20, 25, 30 e 35% e seus respectivos DIs.

Tabela 4.1. Obtenção das frequências naturais saudáveis e danificadas e cálculo do índice de dano

Profundidade da fissura	Frequência Natural(ω)(Hz)			Índice de Dano(DI)		
	ω_4	ω_5	ω_6	DI(ω_4)	DI(ω_5)	DI(ω_6)
Sem Dano	865	1430	2136	1	1	1
5%	863	1429	2132	0.997	0.999	0.998
10%	860	1426	2124	0.994	0.997	0.994
15%	852	1421	2104	0.985	0.994	0.985
20%	849	1419	2099	0.981	0.992	0.983
25%	841	1412	2080	0.972	0.987	0.973
30%	816	1389	2025	0.943	0.971	0.948
35%	803	1377	2000	0.928	0.963	0.936

O conjunto de dados consiste em três frequências naturais ($\omega_4, \omega_5, \omega_6$) para a viga intacta e danificada considerando toda a profundidade da trinca, três clusters de DI ($DI_{1,2,3}$), e a classificação dos múltiplos diz respeito à severidade do dano. A Figura 4.2 mostra um gráfico de dispersão do cluster de conjuntos de dados correlacionados de DIs para as trincas de tamanho 5, 10, 15 e 20%. Particularmente, as Figs. 4.2a e 4.2c apresentam a correlação entre DI_1 e DI_2 , Figs. 4.2b e 4.2d correlacionam DI_3 e DI_2 , todos calculados para as formas quarto e quinto modo. Dos pontos de nuvem, não é claro a classificação da severidade da trinca em até 10%. Para profundidade de trinca de 15 e 20%, temos os pontos espalhados pela

faixa de DIs. Portanto, não está claro, a priori, se o algoritmo ML pode classificar corretamente a severidade do dano. DI entre 1 a 0,98 é considerado um estado saudável da estrutura, e valores de DI mais baixos indicam uma condição danificada.

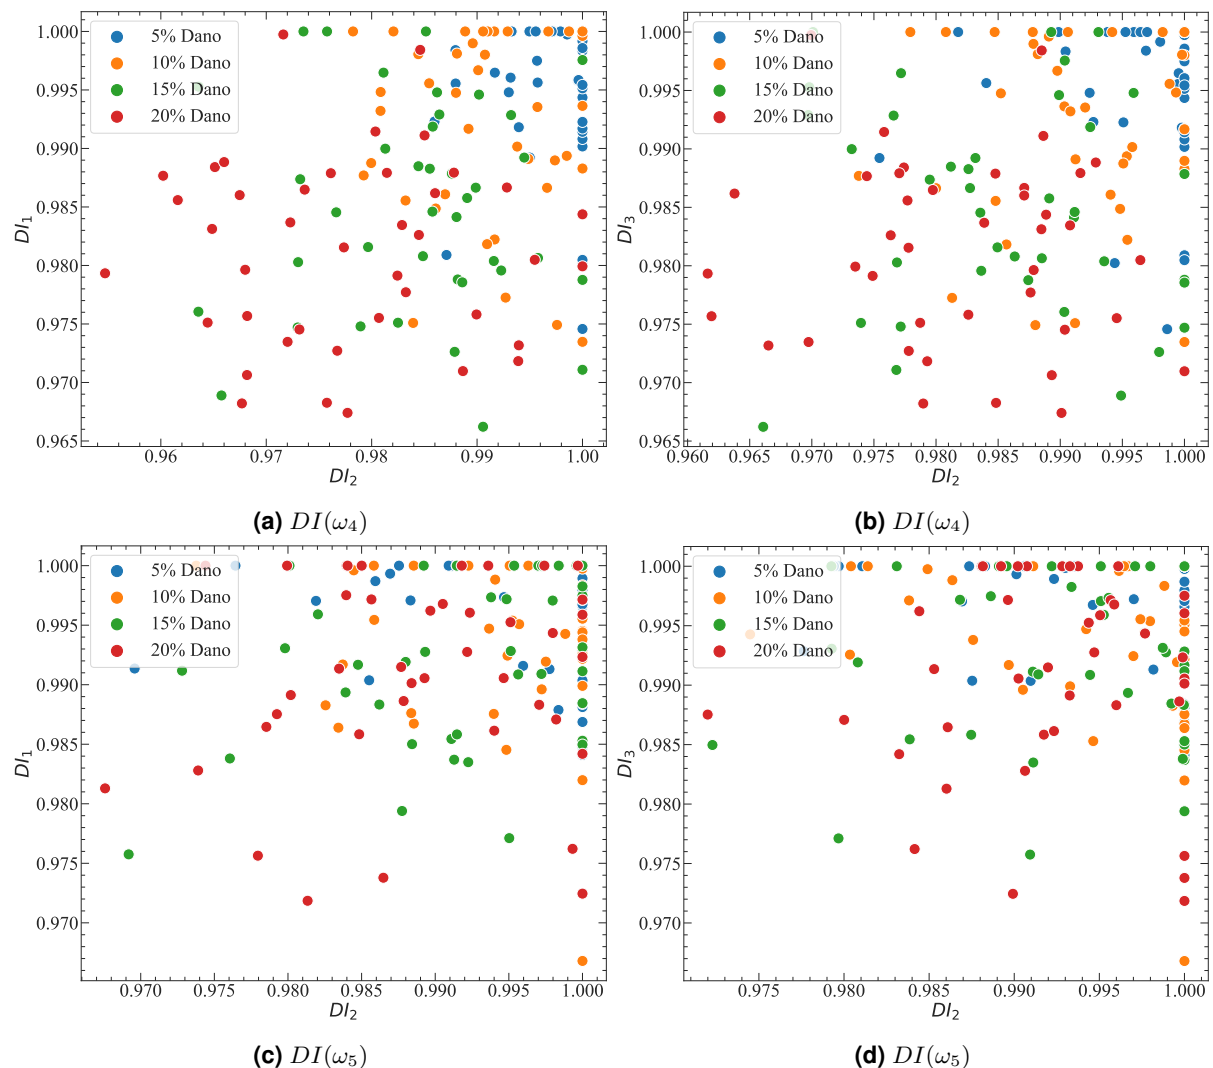


Figura 4.2. Correlações de DIs para profundidade de trinca de 5, 10, 15 e 20% estimadas com ω_4 e ω_5 .

A Figura 4.3 mostra um gráfico de dispersão do conjunto de dados correlacionado obtido para a viga danificada com profundidade da trinca de 25, 30 e 35%. Figure 4.3a exibe a correlação DI_1 e DI_2 calculada com a quarta frequência natural, Fig 4.3b com a quinta frequência natural e Fig 4.3c com a sexta frequência natural. Nas profundidades de trincas de 25, 30 e 35%, os DIs tendem a se reunir em torno de 0,97, 0,95 e 0,92, respectivamente. Ainda assim, uma estimativa falso positiva pode acontecer no processo de prognósticos devido à alta correlação de pontos para todas as frequências naturais. A partir de então, seguindo os valores de DI, o conjunto de dados foi rotulado em quatro classes de integridade, 25-Dano, 30-Dano e 35-Dano. DI superior a 0,98, compreendendo a severidade da trinca entre 1 a 20%, foi assumida condição de saudável da estrutura.

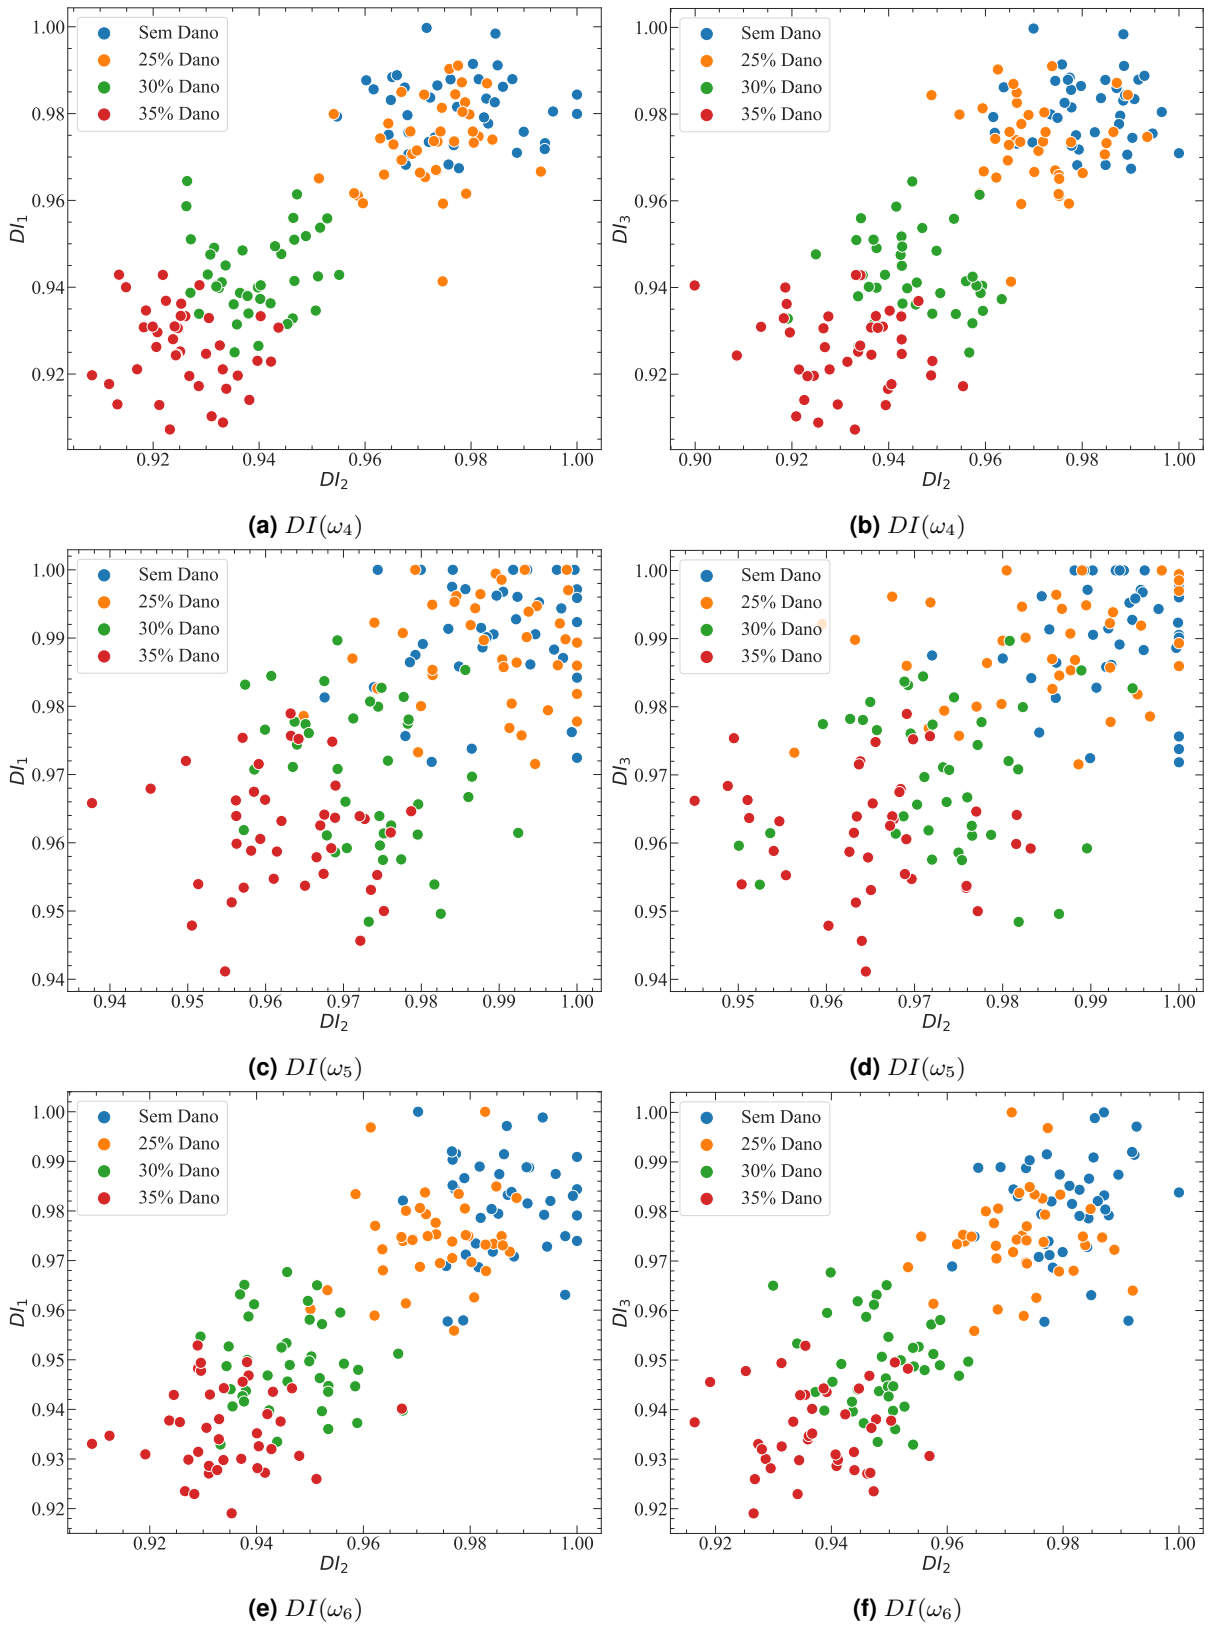


Figura 4.3. Correlações de DIs para profundidade de trinca de 25, 30, 35% estimadas com ω_4 , ω_5 e ω_6 .

4.1.2 Conjunto de dados 2: DI estimado a partir do FRF

A função de resposta também tem sido usada para detectar danos estruturais e calcular índices de danos. O FRAC (HEYLEN; LAMMENS, 1996a) é usado neste trabalho. FRAC é um índice de dano que correlaciona sinais da FRF, onde uma forte correlação é indicada por uma unidade, o que representa estado sem dano. Em contraste, a menor correlação, tendendo a zero significa condição de dano e sua severidade. A equação (3.27) formula o FRAC que compara o sinal FRF da viga trincada (H_{ij}^d) e da viga íntegra indicada por (H_{ij}^u). Como uma trinca influencia diretamente a vibração do sistema, o DI pode detectar e quantificar o dano. O índice compara os FRFs da viga em condição trincada e intacta, portanto, toda as informações de resposta de energia do espectro é incorporado no FRAC.

Os FRAC DIs foram calculados usando o FRF da viga em condições intactas e danificadas para o dimensionamento da trinca da viga 10, 15, 20, 25 e 30% da seção transversal da viga. Nesta simulação, 3% e 5% de ruído branco foi incorporado nas FRFs para investigar a robustez do algoritmo ML na detecção de danos. A Figura 4.4(a-f) mostra a correlação entre FRAC DI_2 e $DI_{1,3}$ obtida com o conjunto de dados contendo 150 amostras para cada severidade da trinca. Ao contrário das frequências naturais DI, o FRAC DI obteve uma melhor classificação dos pontos de nuvens em relação à severidade da trinca e DI. A partir dos pontos da nuvem, os DIs associado a severidade da trinca seguem uma tendência ao redor da faixa de dano correspondente. Portanto, espera-se que o algoritmo ML classifique corretamente a severidade do dano, onde DI entre 1 a 0,98 é considerado um estado saudável da estrutura, profundidade de trinca de 10, 15, 20, 25 e 30% estão associados a 0,0 0,95, 0,8, 0,7, 0,6 e 0,5, respectivamente. A partir de então, seguindo os valores DI, o conjunto de dados multiclasse foi rotulado como integridade, 10-Dano, 15-Dano, 20-Dano, 25-Dano e 30-Dano.

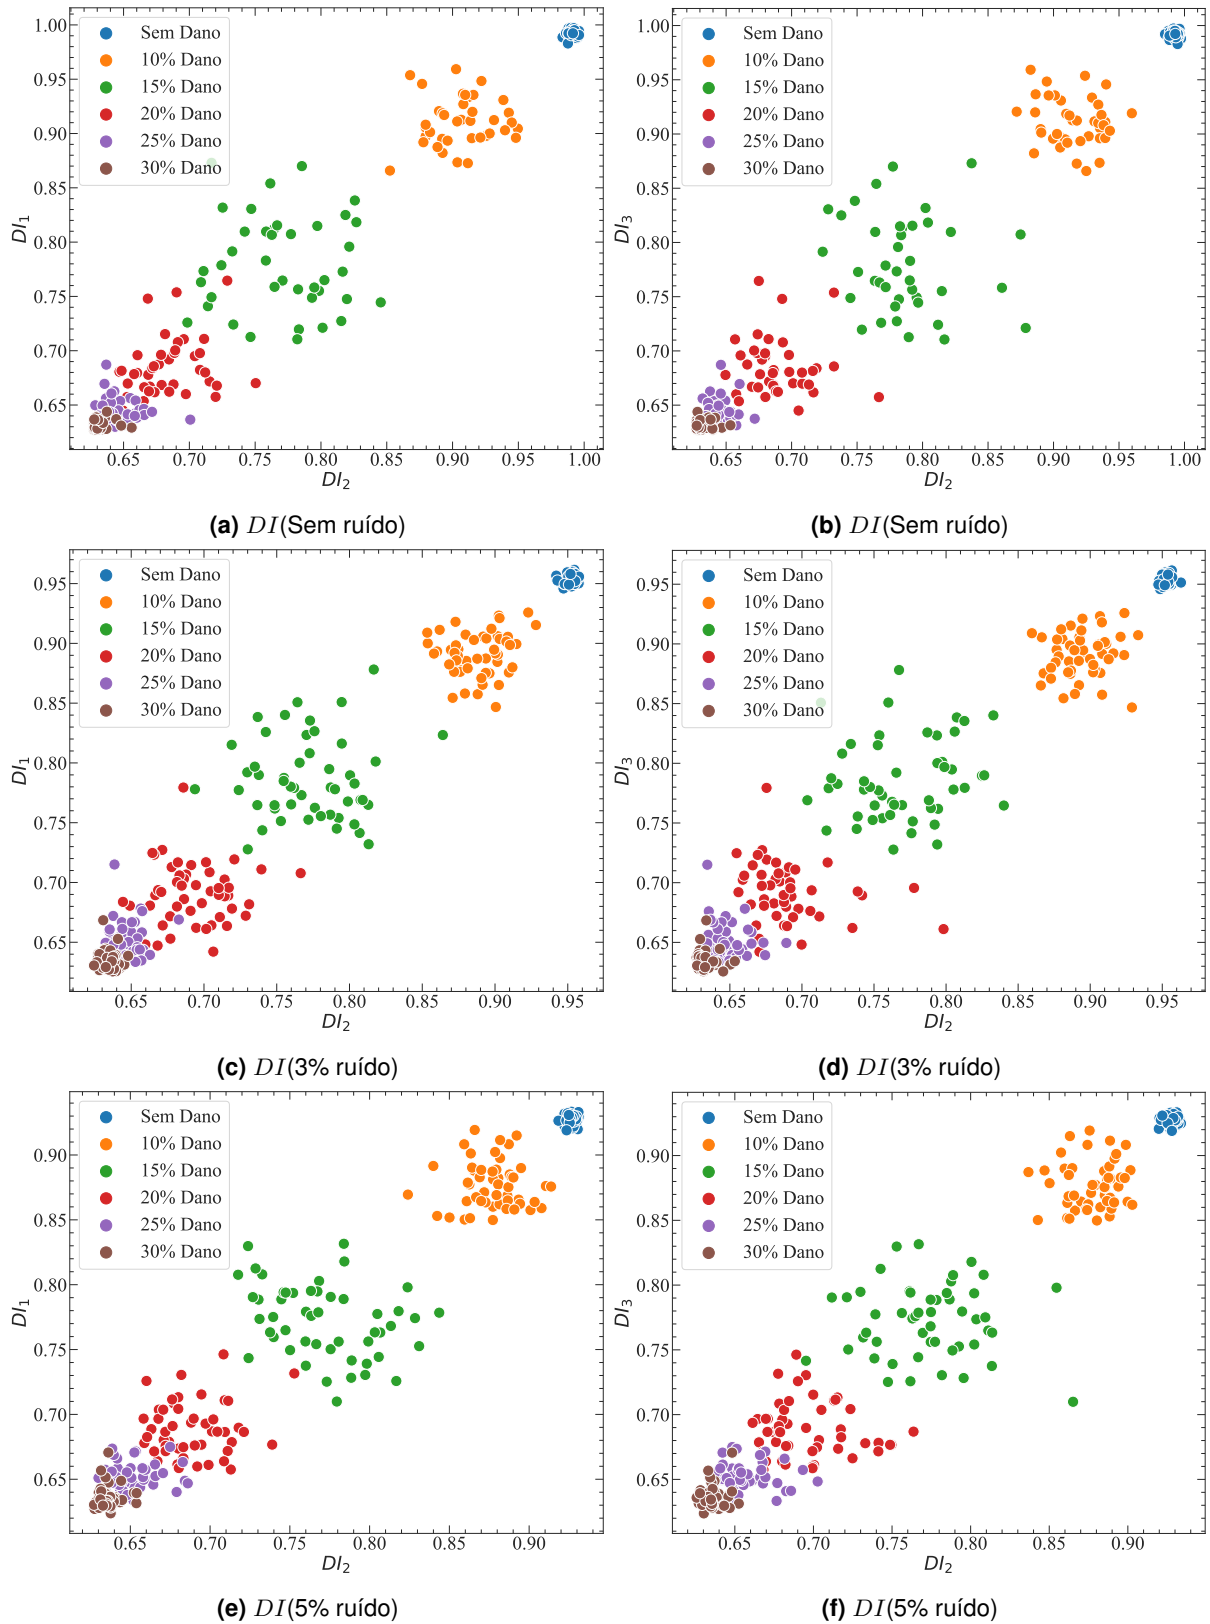


Figura 4.4. Correlações FRAC DIs para profundidade de trinca de 0, 10, 15, 20, 25 e 30% estimadas com FRFs sem ruído e com ruído.

4.2 AVALIAÇÃO DO DANO UTILIZANDO DADOS DE SIMULAÇÃO NUMÉRICA

Cada algoritmo possui hiperparâmetros que devem ser configurados e testados para seu desempenho ideal nos casos de aplicação. No caso SVM, a função de kernel linear, rbf e poly foi usada e uma pesquisa de grade foi usada para determinar os parâmetros de penalidade como $C=100$. A estratégia multiclasse utilizada foi um contra um. A tolerância para o critério de parada é definida como $1e^{-3}$, suficiente para satisfazer o critério de erro. Para o KNN, o número de vizinhos é definido como $k=3$ e a métrica é definida como euclidiana, braycurtis, manhattan e cosine. O valor dos pesos da função é definido como uniforme, o que significa que todos os pontos em cada vizinhança são ponderados igualmente e o tamanho da folha que afeta a construção e a velocidade da consulta é definido como 30. No RF e DT, o número de árvores na floresta é 100 e a profundidade máxima é definida como 3. A divisão mínima da amostra é definida como 2, que denota o número mínimo de amostras necessárias para dividir um nó interno. A folha de amostra mínima representa as amostras de treinamento em cada uma das ramificações certas e os valores mínimos de folha de amostra são definidos como 1. O valor máximo de recursos é definido como 'auto', representando o número de recursos a serem considerados ao procurar a melhor divisão, e foi utilizado o critério índice de Gini e Entropia. Na classe Bayes Ingênuo, o caso Gaussiano-NB, Bernoulli-NB e Multinomial-NB foram definidos.

4.2.1 Detecção de dano usando frequência natural-DI

A quantificação do dano usando a frequência natural-DI considerou a viga em condição intacta e danificada com severidade da trinca de 25, 30 e 35%, incluindo, portanto, quatro classes na identificação do dano. A tabela 4.2 detalha a comparação da acurácia de detecção de dano, os algoritmos foram avaliados segundo as configurações,

O resultado da classificação do algoritmo definido para dados de teste é avaliado pelo critérios métricos Acurácia, Precisão, Recall e F1 score, o valor de acurácia está mostrado na Tabela 4.2, no gráfico 4.5, 4.6 e 4.7 são mostrados os valores de Precisão, Recall e F1 score. A precisão métrica representa quão bem o modelo adivinhou corretamente todas as classificações de classes positivas. A recall representa o número de classes positivas previsões feitas de todos os exemplos positivos no conjunto de dados, e o F1-score é a média entre a precisão e o recall. A comparação da acurácia da estimativa de detecção de danos varia entre 15% a 85% entre os algoritmos de ML para as frequências naturais dos três DIs, ω_4 , ω_5 e ω_6 . No caso das métricas(kernel) de SVM, Linear, alcançou maior acurácia com 88%, 55% e 68% para $DI(\omega_4)$, $DI(\omega_5)$, $DI(\omega_6)$, respectivamente. A métrica de maior acurácia no KNN foi a euclidiana com 70% para as três frequências naturais de DIs. Nos algoritmos de RF e DT, a melhor métrica foi de Entropia variando de 62% a 85%. Dentre todos os algoritmos o que teve maior robustez foi NB Gaussiano, com 90%, 62% e 73% para $DI(\omega_4)$, $DI(\omega_5)$, $DI(\omega_6)$. As métricas precisão, recall e F1-score seguiram o resultados de acurácia, validando a estimativa de dano do algoritmo.

Tabela 4.2. Resultado da comparação de acurácia entre as métricas de cada algoritmo de ML proposto, usando frequência natural DI.

Algoritmos de ML	Métricas	Acurácia(%)		
		DI(ω_4)	DI(ω_5)	DI(ω_6)
SVM	Linear	88	55	68
	Poly	85	62	73
	Rbf	85	65	70
KNN	Euclidiano	70	70	70
	Braycurtis	68	68	68
	Manhattan	68	68	68
	Cosine	28	40	28
NB	Gaussiano	90	62	73
	Bernoulli	15	15	15
	Multinomial	15	15	15
RF	Gini	85	65	73
	Entropia	85	68	73
DT	Gini	78	65	62
	Entropia	80	65	62




Figura 4.5. Correlação de precisão para as frequências naturais de DIs.




Figura 4.6. Correlação de recall para as frequências naturais de DIs.





Figura 4.7. Correlação de F1-score para as frequências naturais de DIs.

Os resultados de acurácia estão diretamente ligados ao conjunto de dados, desta forma como visto na figura 4.3, a correlação dos dados do $DI(\omega_4)$, mostra uma melhor classificação dos


pontos de nuvens em relação à severidade da trinca e DI. Portanto, os algoritmos SVM Linear, KNN Euclidiano, NB Gaussiano, RF Entropia e DT Entropia se mostraram robustos e eficazes para esta aplicação.

Portanto, apenas essas métricas não fornecem informações suficientes para diagnosticar possíveis erros associados a estimação feita pelos algoritmos. Assim, a matriz de confusão também é usada para rastrear a classificação do conjunto de dados. Neste caso, foi mostrada a matriz de confusão dos algoritmos considerados mais robustos no estudos, SVM Linear, kNN Euclidiano, NB Gaussiano, RF Entropia e DT Entropia. As Figuras 4.8, 4.9 e 4.10 mostram as matrizes de confusão contendo valores e porcentagens preditas pelos algoritmos de ML. Onde, as Figuras 4.8(a, c, e) são estimadas pelo SVM, Figuras 4.8(b, d, f) pelo KNN, Figuras 4.9(a, c, e) com Bayes Ingênuo, Figuras 4.9(b, d, f) usando RF, e Figuras 4.10(a-c) pela árvore de decisão.


A acurácia do algoritmo da SVM Linear para $DI(\omega_4)$ atingiu 88% devido a dois erros de classificação na amostra para a condição de 25 danos, com quatro amostras assumida como sem dano e uma amostra sem dano classificada como 25 danos. Para kNN Euclidiano, a acurácia foi de 70% no $DI(\omega_4)$, $DI(\omega_5)$ e $DI(\omega_6)$ devido a erros de classificação em todas as amostra, para a condição de 25 danos, com três amostras assumida como sem dano e uma amostra classificada como 30 danos, para a condição de 30 danos, com uma amostra assumida como 35 dano, para a condição de 35 danos, com uma amostra assumida como 30 dano e para condição de sem danos, com uma amostra assumida como 25 dano, analisando a matriz de confusão da Figura 4.8(b). No algoritmo NB Gaussiano, RF Entropia e DT Entropia as acurácias foram de 90%, 85% e 80%, respectivamente devido a erros de classificação na amostra para a condição de 25 danos e para condição sem dano. Portanto, as melhores acurácias foram alcançadas nos dados de classificação da amostra $DI(\omega_4)$, o algoritmo NB Gaussiano foi considerado mais robusto, em comparação com os outros algoritmos estudados.




(a) SVM- DI(ω_4)




(b) KNN- DI(ω_4)




(c) SVM- DI(ω_5)



(d) KNN- DI (ω_5)

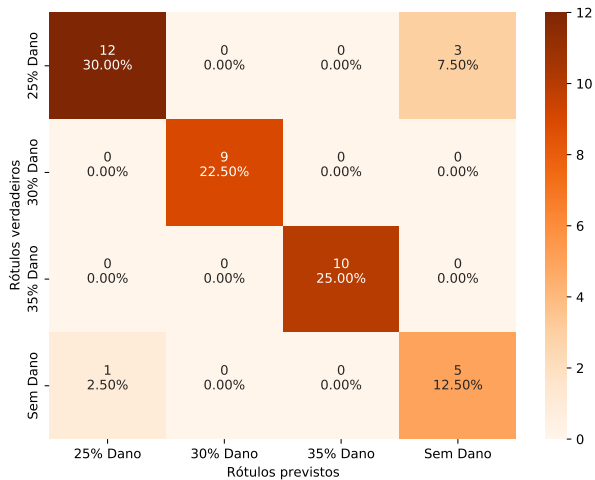


(e) SVM- DI (ω_6)




(f) KNN-DI(ω_6)


Figura 4.8. Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a, c, e) SVM, b, d, f) KNN




(a) Bayes Ingênuo-DI(ω_4)




(b) RF-DI(ω_4)




(c) Bayes Ingênuo-DI(ω_5)



(d) RF-DI(ω_5)




(e) Bayes Ingênuo-DI(ω_6)




(f) RF-DI(ω_6)

Figura 4.9. Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a, c, e) Bayes Ingênuo, b, d, f) RF.



(a) Árvore de Decisão-DI(ω_4)

(b) Árvore de Decisão-DI(ω_5)



(c) Árvore de Decisão-DI(ω_6)

Figura 4.10. Matriz de confusão da classificação multiclasse classificação de danos da frequência natural DI usando a-c) Árvore de Decisão.

4.2.2 Quantificação da severidade do dano usando FRAC-DI

A avaliação do dano pelo FRAC-DI considerou a viga intacta e danificada com severidade de fissura de 10, 15, 20, 25 e 30%, totalizando seis classes para a identificação do dano. De acordo, com a tabela 4.3, as melhores métricas de cada algoritmos são SVM Poly, kNN Euclidiano com 95%, 97% e 98% para sem ruído, 3% ruído e 5% ruído, respectivamente. RF Gini e DT Gini variando 88% a 97% e NB Gaussiano com 95%, 93% e 90% para sem ruído, 3% ruído e 5% ruído, respectivamente. Todas as técnicas de ML alcançaram boa detecção e quantificação de danos, com alta precisão quando os dados são afetados por ruído e quando não são afetados. No entanto, os resultados indicam que SVM Poly e kNN Euclidiano podem detectar eficientemente o dano, incluindo sua severidade, com e sem ruído. As métricas precisão, recall e F1-score seguiram o resultados de acurácia, validando a estimativa de dano do algoritmo, mostrados nos gráficos 4.11, 4.12 e 4.13. Os algoritmos SVM Poly, kNN Euclidiano, NB Gaussiano, RF Gini e DT Gini são considerados mais robustos, pelo fato dos

dados na figura 4.4 seguirem uma tendência ao redor da faixa de DI correspondente, sendo melhor classificado nos pontos de nuvens em relação à severidade da trinca.

Tabela 4.3. Resultado da comparação entre as métricas de cada algoritmo de ML proposto, usando FRAC DI.

Algoritmos de ML	Métricas	Acurácia(%)		
		Sem ruído	3% ruído	5% ruído
SVM	Linear	97	97	90
	Poly	95	97	98
	Rbf	93	97	92
KNN	Euclideano	95	97	98
	Braycurtis	95	97	95
	Manhattan	95	97	95
	Cosine	38	40	35
NB	Gaussiano	95	93	90
	Bernoulli	12	12	12
	Multinomial	12	12	12
RF	Gini	95	98	95
	Entropia	93	97	95
DT	Gini	83	93	93
	Entropia	87	93	95




Figura 4.11. Correlação de precisão, usando FRAC DI.




Figura 4.12. Correlação de recall, usando FRAC DI.




Figura 4.13. Correlação de F1-score, usando FRAC DI.

A matriz de confusão fornece informações detalhadas sobre o desempenho dos classificadores ML em rotular a condição estrutural da viga. As Figuras 4.14, 4.15 e 4.16 mostram as matrizes de confusão multiclasse do conjunto de dados da viga sem ruído e contaminado com ruído de 3% e 5%. Onde Figuras 4.14(a, c, e) são estimados com SVM, Figuras 4.15(b, d, f) de kNN, Figuras 4.16(a, c, e) com Bayes Ingênuo, Figuras 4.9(b, d, f) usando RF, e Figuras 4.16(a-c) Árvore de decisão. A matriz diagonal representa os valores corretos, então a acurácia de SVM Poly, kNN Euclideano, NB Gaussiano e RF Gini para os dados sem dados são 95% devido a um erro de classificação na amostra para a condição de 30 danos, com três amostras assumida como 25 danos. Portanto, todos os algoritmos são considerados robustos para ambos os conjuntos de dados com e sem ruído. Mas os algoritmos SVM Linear e kNN

Euclideano, alcançaram resultados melhores em relação aos outros algoritmos.

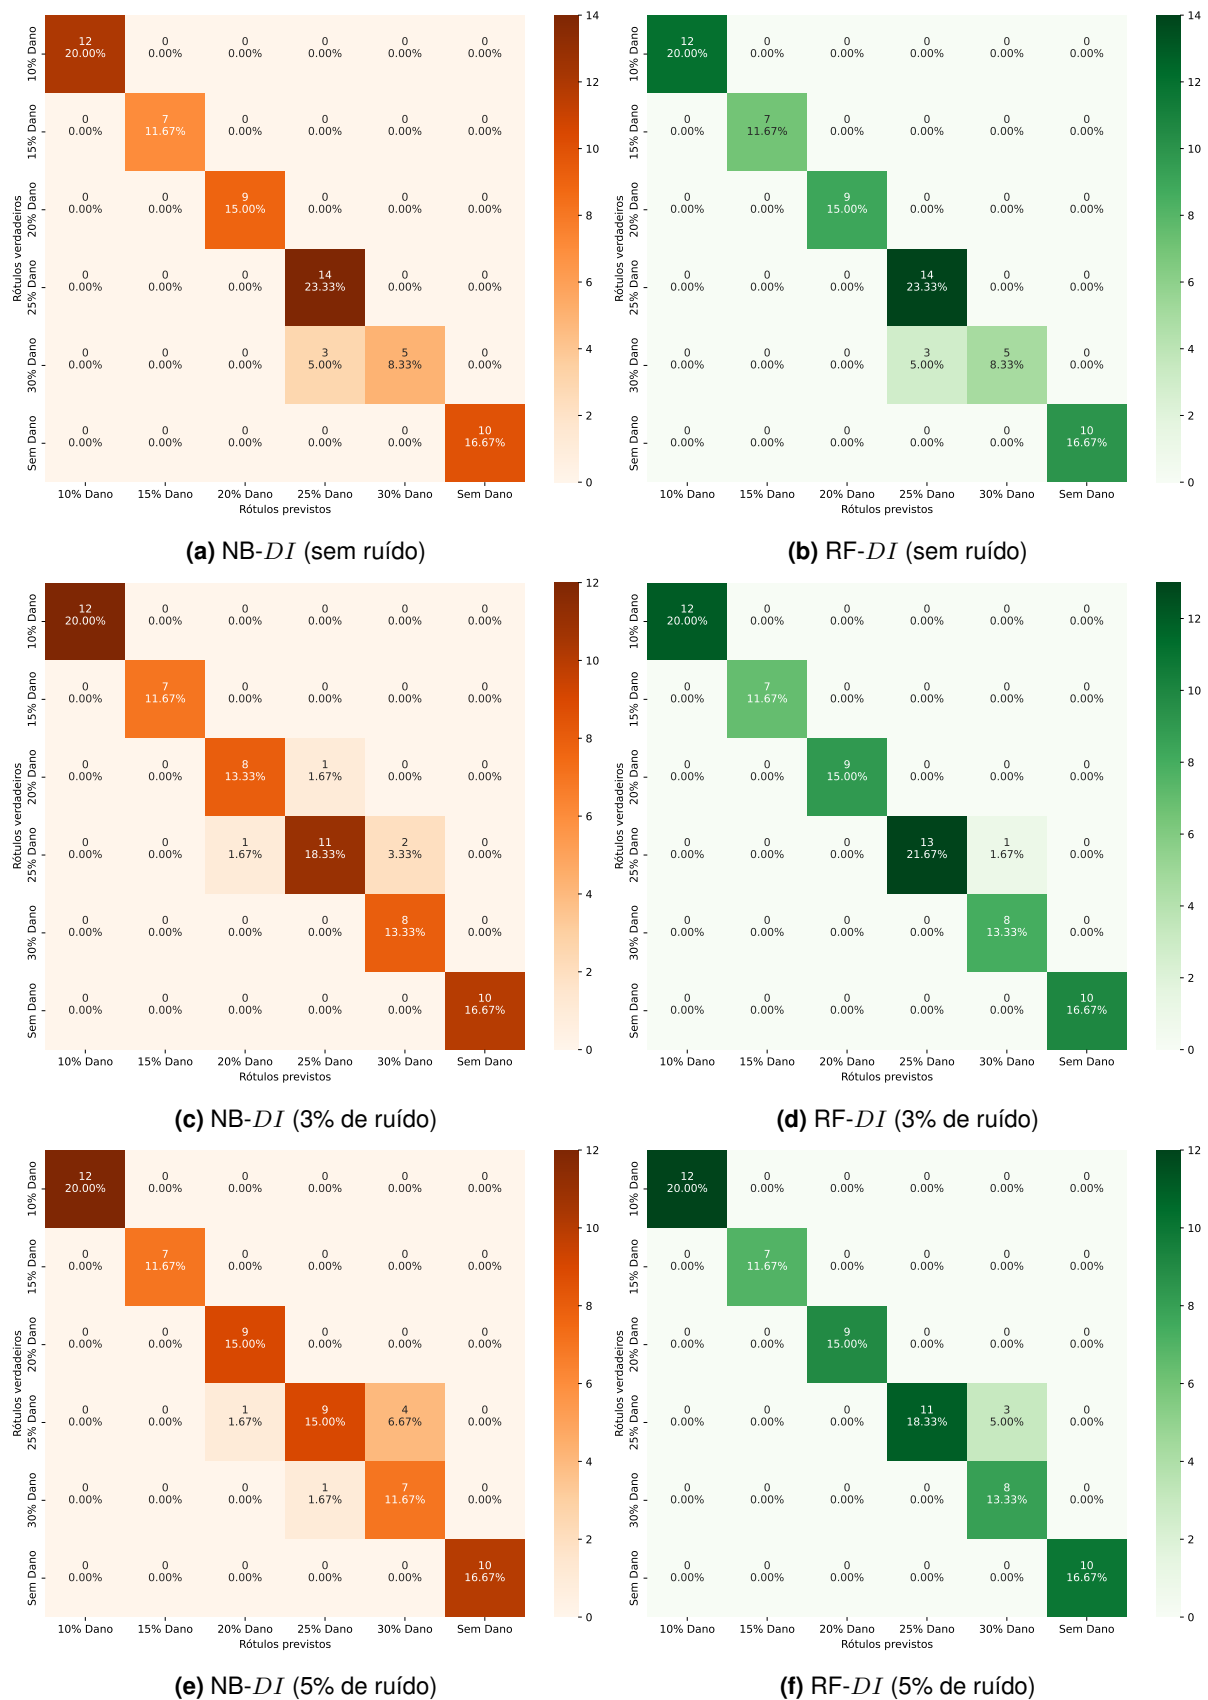





Figura 4.15. Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a, c, e) Bayes Ingênuo, b, d, f) RF.




(a) SVM-DI (sem ruído)




(b) k-NN-DI (sem ruído)




(c) SVM-DI (3% de ruído)



(d) k-NN-DI (3% de ruído)




(e) SVM-DI (5% de ruído)




(f) k-NN-DI (5% de ruído)

Figura 4.14. Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a, c, e) SVM, b, d, f) KNN.



(a) DT-DI (sem ruído)

(b) DT-DI (3% de ruído)



(c) DT-DI (5% ruído)

Figura 4.16. Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI com e sem ruído usando a-c) Árvore de Decisão.

5 RESULTADOS DO ENSAIO EXPERIMENTAL

Este capítulo apresenta todo procedimento experimental referente a uma viga em balanço reforçada com massa. O objetivo do experimento é analisar o comportamento dinâmico do sistema ao retirar certa quantidade de massa. Essa perda de massa é considerado dano estrutural. Os ensaios experimentais, tem o intuito de obter as características da resposta do sistema, dados pela FRF. O sistema foi excitado usando martelo de impacto. O martelo de impacto produz uma excitação do tipo transiente, imposta manualmente. Com o sistema de aquisição, contendo pelo menos dois canais de entrada, um medindo a resposta de vibração, geralmente com um acelerômetro, e outro com a força de impacto de entrada, obtendo assim uma FRF. As FRFs obtidas nas diversas aquisições de dados são submetidas ao processo de averaging (média), pois este procedimento permite reduzir o nível de ruído presente nos dados (LIMA, 2006). Uma vez coletada as FRFs os DIs são estimados a base de dados montada, para então alimentar os algoritmos de ML e prosseguir com o monitoramento da estrutura.

5.1 APARATO EXPERIMENTAL

O ensaio experimental foi realizado em uma barra chata laminada em balanço, realizado no Laboratório de Vibrações do Departamento de Engenharia Mecânica da Universidade de Brasília. A configuração experimental é mostrada na figura 5.1, a qual consiste em uma viga de aço em balanço de comprimento $L = 0,38m$, largura de 0,0254 m e altura de 0,00475 m. As propriedades do material são módulo de Young de 2,1 GPa e densidade de massa de 7800 kg/m³.




Figura 5.1. Viga física anexada com massas (topo). Amostras de localização de massas aleatórias para cada massa anexada (inferior).

As massas de reforço é constituída de seis ímãs de nióbio que compreende 10,41% da massa total da viga reforçada, que pesa 429,37g. A viga é excitada perto da borda engastada com um martelo de impacto (PCB 086CO3), e a resposta de aceleração é adquirido na borda livre da viga por um acelerômetro (PCB 353B03). O sistema de aquisição é o PolytecSoft que fornece as FRFs de inércia. O dano na estrutura é considerado pela perda da massa do reforço. Duzentas e oito medições foram realizadas na viga, considerando estado saudável e danificado. Em cada medição, as seis massas são posicionadas em locais diferentes ao longo da viga, conforme mostra a figura 5.1(Inferior). A posição das massas é considerada uma variável aleatória de distribuição uniforme. O valor médio é o valor determinístico das posições das massas mostrado na figura 5.2a, e o coeficiente de variação é assumido como sendo 10%.

A Figura 5.2 mostra a estrutura intacta e os três estados danificados da viga com armaduras considerando a perda de massa do reforço. A figura 5.2a mostra a representação esquemática do experimento quando a viga está em boas condições. As seis massas estão localizadas em posições com distâncias iniciais de 5cm da aresta fixada. Assim, as massas 1, 2, 3, 4, 5 e 6 estão localizadas nas posições determinísticas de $L_1 = 5\text{cm}$, $L_2 = 10\text{cm}$, $L_3 = 15\text{cm}$, $L_4 = 20\text{cm}$, $L_5 = 25\text{cm}$, $L_6 = 30\text{cm}$, respectivamente. A Figura 5.2a mostra a condição da primeira viga danificada com uma perda de massa de 2,96% da massa total, onde a massa da posição 1 foi removida. A Figura 5.2b mostra uma segunda condição de viga danificada com uma perda de massa de 5,92% da massa total. Neste caso, as massas das posições 1 e 3 foram retiradas. A Figura 5.2c mostra a condição da terceira viga danificada com uma perda de massa de 8,84% da massa total. As massas das posições 1, 3 e 5 foram retiradas. Um total de 280 amostras de FRFs foram medidas considerando todas as condições do viga.

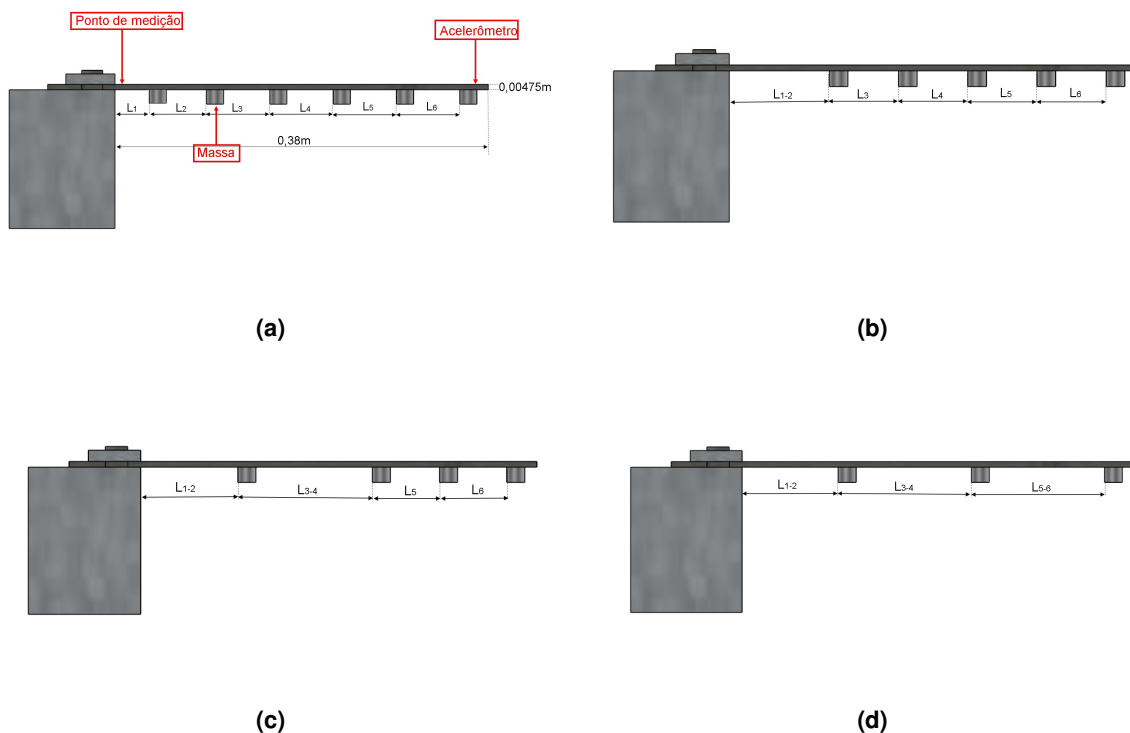


Figura 5.2. Representação gráfica dos testes realizados no experimento. (a) Viga intacta com massas reforçada; (b) Viga danificada com perda de massa de 2,96% da massa total; (c) Viga danificada com perda de massa de 5,92% da massa total; (d) Viga danificada com perda de massa de 8,84% da massa total.

A perda de massa reforçada com viga reduz sua rigidez e massa, induzindo mudanças nas frequências de ressonância e afetando a resposta dinâmica. A Figura 5.3 mostra o efeito da perda gradual de massa na resposta de inércia da viga considerando a massa em uma posição aleatória. A Figura 5.3a mostra as FRFs de inércia das vigas em condição não danificada, Fig. 5.3b para a viga danificada com perda de massa de 2,96% da massa total, Fig. 5.3c para a viga danificada com perda de massa de 5,92%, e Fig 5.3d para a viga danificada com perda de massa de 8,84%. Da mesma forma que o caso numérico, o dano influencia a resposta dinâmica de vigas físicos em faixas de frequência mais altas. Assim, para o cálculo do DI, utilizamos uma faixa de frequência que compreende as formas de segundo, terceiro e quarto modo mais impactadas pelo dano estrutural.

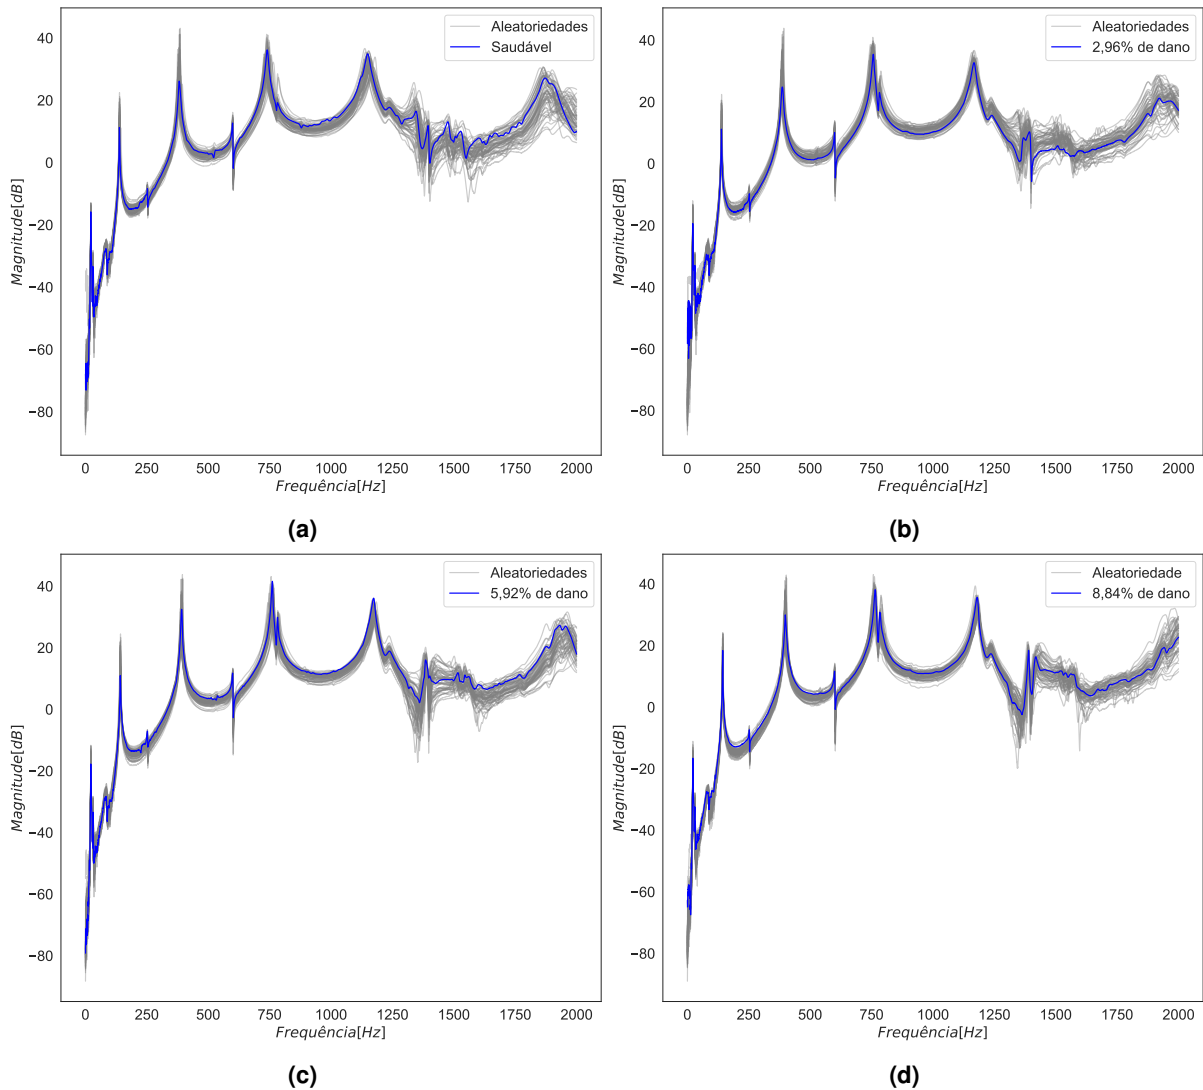


Figura 5.3. Viga medida experimental com FRFs de inércia de massa reforçada, em azul a curva é a posição determinística das massas e a curva em cinza considerando a aleatoriedade na posição da massa. (a) FRFs de viga não danificados; (b) FRFs de viga danificada com perda de massa de 2,96% da massa total; (c) FRFs de vigas danificadas com perda de massa de 5,92% da massa total; e (d) FRFs de vigas danificadas com perda de massa de 8,84% da massa total.

5.2 CONJUNTO DE DIs EXTRAÍDO DE DADOS EXPERIMENTAIS

A mudança nas características dinâmicas da viga reforçada com massas pode ser usada como indicador de dano. No estudo numérico, o FRAC (Eq 3.27) mostra-se um melhor indicador de danos porque usa a energia do espectro para todo o sinal de resposta. Portanto, apenas o FRAC calcula os DIs usando o conjunto de dados experimental. Os DIs são estimados correlacionando as condições de vigas intactas e danificadas das FRFs com a remoção de 2,96, 5,92 e 8,84% da massa total da viga. O FRF das posições não danificadas com massas determinísticas é considerado o sinal de referência, correlacionado com as FRFs das posições não danificadas e danificadas com uma localização de massa aleatória.

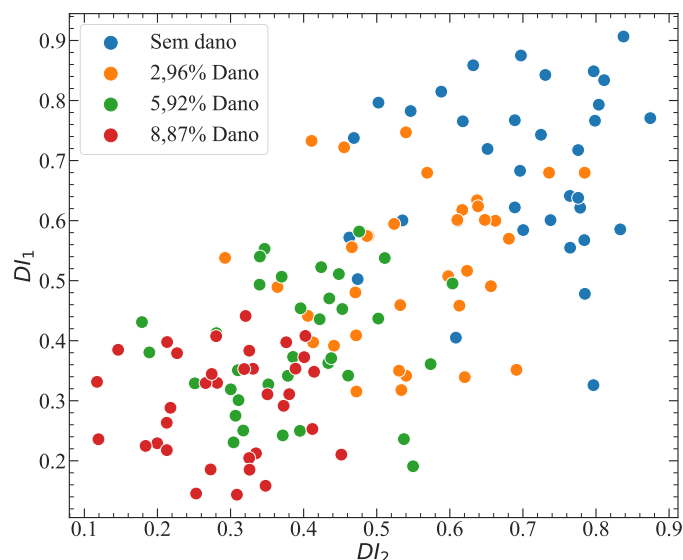


Figura 5.4. Gráfico de dispersão correlacionando o conjunto de dados de amostras de grupos de FRAC DIs obtido para a viga com massas armadas para diferentes perdas de massa.

A Figura 5.4 mostra o gráfico de dispersão da correlação entre FRAC DI_1 e FRAC DI_2 obtido com o conjunto de dados contendo 280 amostras. Os valores dos DIs agrupam-se em torno de 0,1 e 0,9, demonstrando que os valores dos dados de DI possuem alta correlação entre si e podem indicar a geração de estimativas falsas positivas ao utilizar o algoritmo ML. Os valores DI do conjunto de dados multiclasse foram rotulados como sem danos, 2,96 danos, 5,92 danos e 8,84 danos, que é a entrada de dados dos algoritmos de ML.

5.3 AVALIAÇÃO EXPERIMENTAL DE DANO USANDO VIGA REFORÇADA COM MASSA

A quantificação do dano experimental pelo FRAC DI considerou a viga intacta e danificada com perda de massa de 2,96, 5,92 e 8,84% da massa total da viga. Quatro classes na identificação do dano foram ligadas a cada condição de viga. A tabela 5.1 detalha a comparação das acurácias de detecção de danos. As melhores métricas de cada algoritmos são SVM Poly, KNN Euclideano e RF Entropia com 64% de acurácia e NB Gaussiano e DT Entropia com 61% de acurácia. Neste caso, os algoritmos não foram considerados robustos. As métricas precisão, recall e F1-score seguiram o resultados de acurácia, validando a estimativa de dano do algoritmo. No gráfico 5.5, os algoritmos SVM Poly, kNN Euclideano, NB Gaussiano, RF Entropia e DT Entropia tem melhores métricas em relação as outras algoritmos. Portanto, as métricas de avaliação atingiram mais de 60 % de precisão para todos os algoritmos, o que é considerado um bom valor para o conjunto de dados do teste experimental.

Tabela 5.1. Resultado da comparação entre as métricas de cada algoritmo de ML proposto, usando FRAC DI para ensaio experimental.

Algoritmos de ML	Métricas	Acurácia(%)
SVM	Linear	54
	Poly	64
	Rbf	61
KNN	Euclideano	64
	Braycurtis	64
	Manhattan	64
	Cosine	14
NB	Gaussiano	61
	Bernoulli	14
	Multinomial	14
RF	Gini	61
	Entropia	64
DT	Gini	61
	Entropia	57




Figura 5.5. Correlação de acurácias para as três frequências naturais de DIs

A Figura 5.6 mostra as matrizes de confusão contendo valores e porcentagens preditas pelas

técnicas de ML. Onde Figura 5.6(a, b, c, d, e) são estimados com SVM Linear, KNN Euclidiano, NB Gaussiano, RF Entropia e DT Entropia. Os resultados mostram que mais amostras foram classificadas erroneamente, exceto para o algoritmo SVM Linear, KNN Euclidiano e RF Entropia teve a melhor acuraria, de 64%, devido a cinco erros de classificação na amostra para a condição de 8,87 danos, com três amostras assumida como 5,92 danos. Para a condição de 5,92 danos, com uma amostra assumida como 8,87 danos e duas amostras assumindo 2,96 dano. Para a condição de 2,96 danos, com duas amostras assumindo 5,92 dano E para a condição de sem danos, com duas amostras assumindo 5,92 dano. Portanto, para dados gerados experimentalmente os algoritmos não são classificados corretamente, devido a presença de ruído.

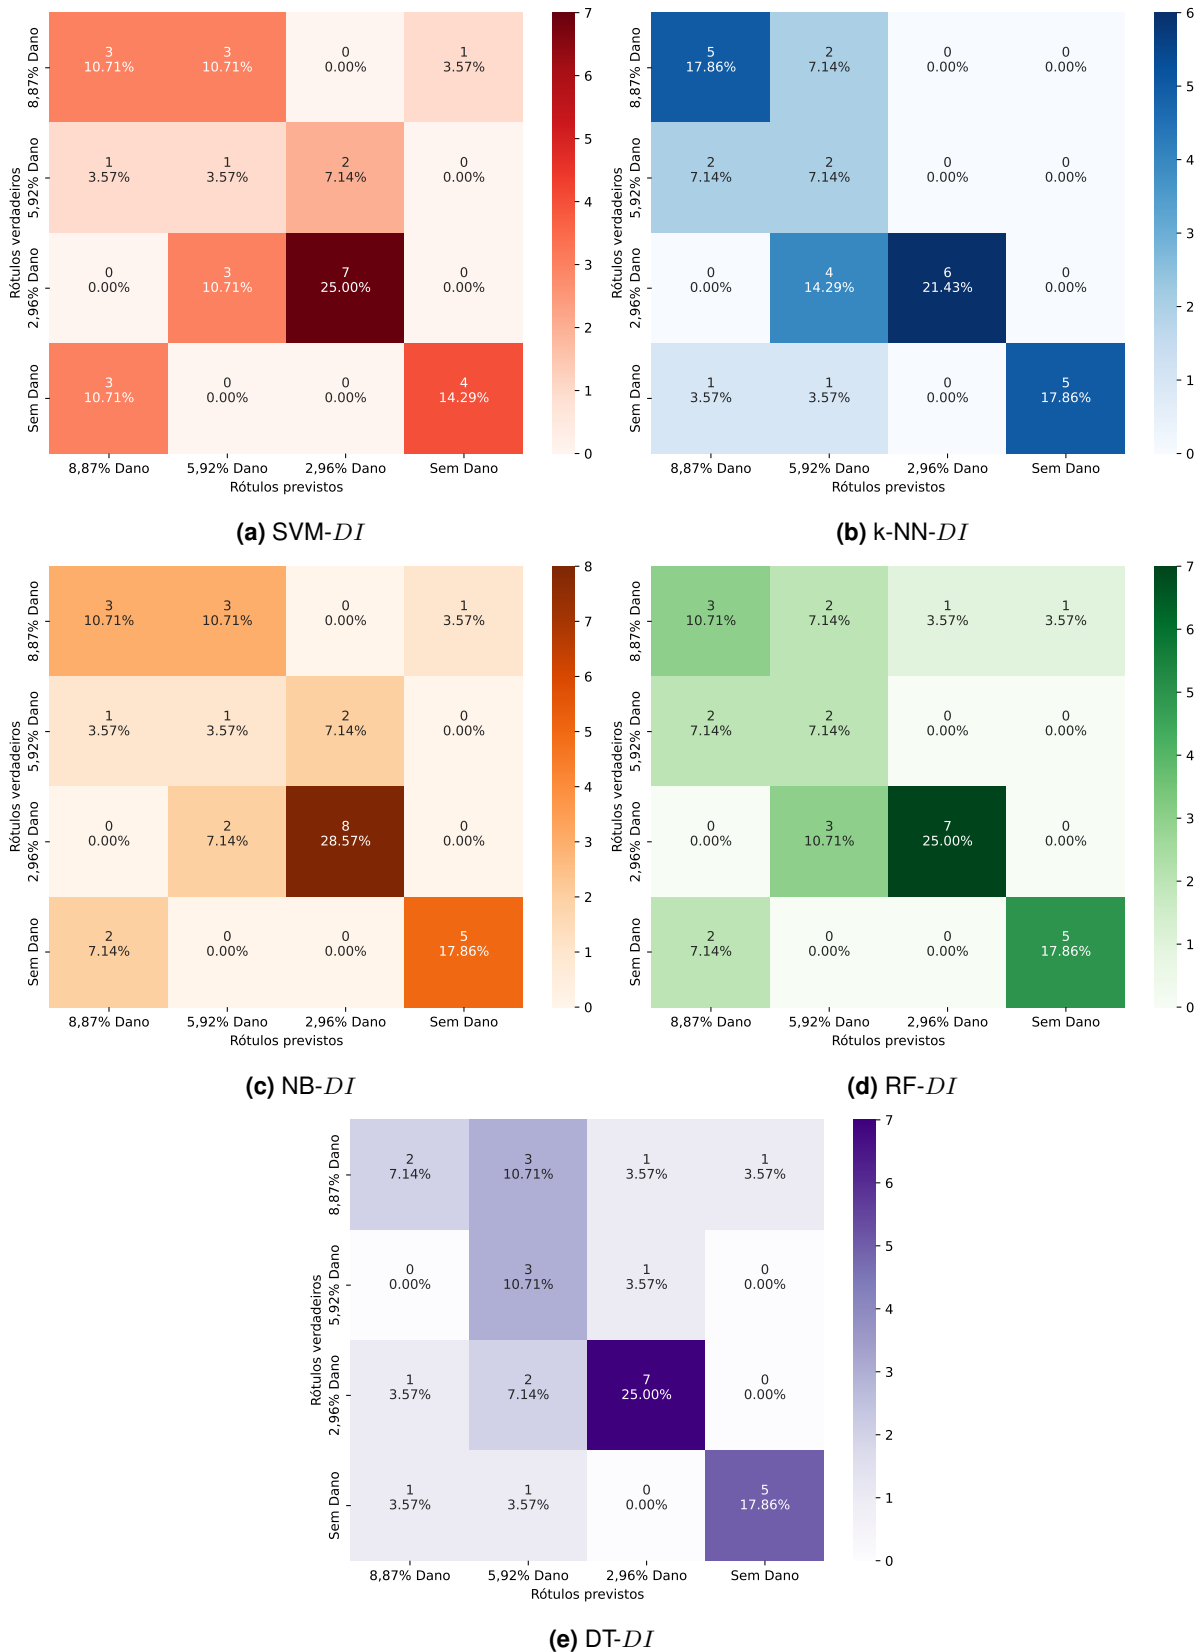


Figura 5.6. Matriz de confusão da classificação de dano de classificação multiclasse de FRAC DI a) SVM, b) k-NN, c) NB, d) RF e f) DT.

A utilização da FRF na identificação dos danos se mostrou eficaz pois incorporam toda ener-

gia do espectro na construção do DI, o que por sua vez carrega uma maior sensibilidade que quando usado somente valores de frequência natural. Os algoritmos utilizados para o monitoramento estrutural das vigas com diferentes tipos de dano foram capazes de identificar e quantificar as anomalias. Tais ferramentas se mostraram com grande potencial e acurácia para aplicação em SHM. Um grande desafio é a aquisição e obtenção de dados, pois em um processo de SHM a quantidade de dados serão na ordem de centenas, o que para alguns casos podem ser insuficientes para o treinamento e testes quando escolhido um monitoramento estrutural utilizando algoritmos de ML.

6 CONCLUSÃO

Este trabalho investiga seis técnicas de ML supervisionadas (k-NN, SVM, NB, RF e DT), avaliando as métricas que existem dentro de cada algoritmo de ML, para detectar dano em uma viga em balanço para simulação numérica para diferentes níveis de fissura e uma avaliação experimental com viga reforçada em balanço com massa, usando duas assinaturas baseadas em vibração, a frequência natural e FRF. Os métodos de vibração foram calculados usando o método do elemento espectral para simulação numérica os índices de dano foram usados na estimativa, DI frequência natural e FRAC. Os algoritmos ML foram treinados e avaliados através do conjunto de dados para determinar a condição estrutural da viga. A análise dos algoritmos de ML inclui a acurácia e a matriz de confusão na avaliação da detecção de danos. Os resultados numéricos demonstram que o FRAC DI realizou a classificação do conjunto de dados melhor do que a frequência natural DI, para simulação numérica, devido esse preceito o FRAC foi usado para normalizar os dados do experimento. Para o primeiro tipo de dano, o algoritmo NB Gaussiano, detecta e quantifica com precisão os dados aplicados a frequência DI Já SVM Poly e KNN Euclideano detecta com precisão dados com e sem ruído, aplicando o FRAC DI. Embora o valor de precisão tenha atingido mais de 60% para os testes experimentais, deve-se notar que esse valor pode ser afetado pelo pequeno número de amostras, o que pode resultar em algoritmos não gerando um padrão de dados. No geral, os resultados sugerem que a combinação de técnicas de ML e assinaturas baseadas em vibração pode efetivamente detectar danos na estrutura analisada. Estudos futuros com tamanhos de amostra maiores podem ajudar a melhorar a precisão das métricas de ML ao usar dados experimentais, como otimizar os hiperparâmetros dos algoritmos.

6.1 PROPOSTAS PARA TRABALHOS FUTUROS

Este estudo pode ser utilizado como base para contínuos trabalhos nesta linha, de Monitoramento da Integridade Estrutural utilizando Aprendizado de Máquina. Ideias que surgiram ao longo deste trabalho e passam a ser sugestões para os próximos trabalhos são:

- Aplicar ferramenta digital twin para gerar mais dados;
- Modelar numericamente a viga reforçada alterando posicionamento da massa de reforço da estrutura;
- Localizar dano usando os algoritmos de ML;
- Aplicar para diferentes tipos de danos, para gerar uma padronização;

- Aplicar as técnicas de ML em outras estruturas;
- Aplicar algoritmos supervisionado de regressão;
- Avaliar o dano utilizando redes neurais.

LISTA DE REFERÊNCIAS

- ABDELJABER, O. et al. 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data. *Neurocomputing*, v. 275, p. 1308–1317, 2018. ISSN 18728286.
- AIRCRAFT. Aircraft accident report, aloha airlines flight 243, boeing 737-100, n73711, near maui, hawaii. *NTSB/AAR-89/03*, 1988.
- APETRE, N. et al. A wave-based damage index for the analysis of the filtered response of damaged beams. *Journal of Mechanics of Materials and Structures*, p. 1605–1623, 2008.
- ASHIGBI, D. M. et al. Vibration response based crack diagnosis in beam-like structures using fuzzy inference system. *Scientific African*, v. 14, 2021. ISSN 24682276.
- AVCI, O. et al. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical Systems and Signal Processing*, The Authors, v. 147, p. 107077, 2021. ISSN 10961216. Disponível em: (<https://doi.org/10.1016/j.ymssp.2020.107077>).
- BANERJEE S., R. F. M. E.; MAL, A. A wave propagation and vibration-based approach for damage identification in structural components. *Journal of Sound and Vibration*, v. 322, p. 167–183, 2009.
- BANERJEE S., R. F. M. E. L. L.; MAL, A. Autonomous impact damage monitoring in a stiffened composite panel. *Journal of Intelligent Material Systems and Structures*, v. 18, p. 623–633, 2007.
- BARRETO, L. S. et al. Damage indices evaluation for one-dimensional guided wave-based structural health monitoring. *Latin American Journal of Solids and Structures*, v. 18, n. 2, p. 1–17, 2021. ISSN 16797825.
- BULL, L. A. et al. Probabilistic active learning: An online framework for structural health monitoring. *Mechanical Systems and Signal Processing*, The Authors, v. 134, p. 106294, 2019. ISSN 10961216. Disponível em: (<https://doi.org/10.1016/j.ymssp.2019.106294>).
- CHEUNG, A. et al. The application of statistical pattern recognition methods for damage detection to field data. *Smart Materials and Structures*, v. 17, n. 6, 2008. ISSN 09641726.
- COELHO, C. K.; DAS, S.; CHATTOPADHYAY, A. A hierarchical classification scheme for computationally efficient damage classification. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, v. 223, n. 5, p. 497–505, 2009. ISSN 09544100.
- CUONG-LE, T. et al. An efficient approach for damage identification based on improved machine learning using PSO-SVM. *Engineering with Computers*, n. 0123456789, 2021. ISSN 14355663.

- CUTLER, J.; DICKENSON, M. *Introduction to Machine Learning with Python*. [S.l.: s.n.], 2020. 129–142 p. ISBN 9781449369415.
- CUTLER, J.; DICKENSON, M. *Introduction to Machine Learning with Python*. [S.l.: s.n.], 2020. 129–142 p. ISBN 9781449369415.
- DANESHVAR, M. H.; SARMADI, H. Unsupervised learning-based damage assessment of full-scale civil structures under long-term and short-term monitoring. *Engineering Structures*, v. 256, n. January, 2022. ISSN 18737323.
- DANG MOHSIN RAZA, T. V. N. T. B.-T. H. X. N. H. V. Deep learning-based detection of structural damage using time-series data. *Structure and Infrastructure Engineering*, p. 1474–1493, 2021. ISSN 17413168.
- De Lautour, O. R.; OMENZETTER, P. Nearest neighbor and learning vector quantization classification for damage detection using time series analysis. *Structural Control and Health Monitoring*, v. 17, n. 6, p. 614–631, 2010. ISSN 15452255.
- DELUCA, A. et al. Guided wave shm system for damage detection in complex composite structure. *Theoretical and Applied Fracture Mechanics*, v. 105, 2020.
- DOYLE, J. F. Wave propagation in structures: spectral analysis using fast discrete fourier transforms. *Mechanical engineering, Springer-Verlag New York*, v. 105, 1997.
- DUTKIEWICZ, M.; MACHADO, M. Spectral approach in vibrations of overhead transmission lines. *IOP Conference Series: Materials Science and Engineering*, 2019.
- EBRAHIMKHANLOU, A.; SALAMONE, S. Single-sensor acoustic emission source localization in plate-like structures using deep learning. *Aerospace*, v. 5, n. 2, 2018. ISSN 22264310.
- ENSSLIN L., E. S.; PACHECO, G. Um estudo sobre segurança em estádios de futebol baseado na análise bibliométrica da literatura internacional. *Perspectivas em Ciência da Informação*, v. 17, n. 22, p. 71–91, 2012.
- ENSSLIN L., E. S. L. R.; TASCA, J. Processo de Seleção de Portfólio Bibliográfico. *Processo Técnico com Patente de Registro Pendente Junto ao INPI.*, 2010.
- ENSSLIN S.R., E. L. M. A.; PEREIRA, V. Evidenciação do estado da arte da avaliação da segurança do trabalho em empreendimentos da construção civil. *Interciencia*, v. 39, p. 16–23, 2014.
- FACELI K., L. A. C. G. J. e. C. A. C. P. L. F. d. Inteligência Artificial : Uma Abordagem de Aprendizado de Máquina. *Rio de Janeiro: LTC*, 2011.
- FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. *Phil. Trans. R. Soc. A.*, 2006.
- FARRAR, C. R.; WORDEN, K. SHM- ML Perspective - Operational Evaluation. *Structural health monitoring: a machine learning perspective*, p. 55–63, 2013. Disponível em: <http://linkinghub.elsevier.com/retrieve/pii/B9780121676322500101>.
- FARRAR C. R.; DOEBLING, S. W. Damage detection ii: field applications to large structures. *Dordrecht: Kluwer Academic Publishers (Modal Analysis and Testing, Nato Science Series)*, 1999.
- FARRAR C.R., W. K. An introduction to structural health monitoring. *Philos. Trans. R. Soc.*, p. 303–315, 2007.

Fathalizadeh Najib, M.; Salehzadeh Nobari, A. An efficient technique for extraction of nonlinear dynamic features in a model-based feature extraction scheme for machine learning-based structural health monitoring. *JVC/Journal of Vibration and Control*, v. 27, n. 7-8, p. 865–878, 2021. ISSN 17412986.

FLACH, P. A.; LACHICHE, N. Naive Bayesian classification of structured data. *Machine Learning*, v. 57, n. 3, p. 233–269, 2004. ISSN 08856125.

FLYNN, E. B. et al. Enhanced detection through low-order stochastic modeling for guided-wave structural health monitoring. *Structural Health Monitoring*, 2012.

GHADIMI, S.; KOUREHLI, S. S. Crack detection of structures using modified extreme learning machine (MELM). *Inverse Problems in Science and Engineering*, v. 25, n. 7, p. 995–1013, 2017. ISSN 17415985.

GHAFFARZADEH, H. et al. Study on meshfree hermite radial point interpolation method for flexural wave propagation modeling and damage quantification. *Latin American Journal of Solids and Structures*, 2016.

GILLICH N.; TUFISI, C. S. C. R. C. G. G.-R. P. Z.-I. A. M. Beam Damage Assessment Using Natural Frequency Shift and Machine Learning. *Sensors*, v. 22, n. 22, 2022. Disponível em: <https://doi.org/10.3390/s22031118>.

GIURGIUTIU, V. Chapter 1 - introduction. In: GIURGIUTIU, V. (Ed.). *Structural Health Monitoring with Piezoelectric Wafer Active Sensors (Second Edition)*. Second edition. Oxford: Academic Press, 2014. p. 1–19. ISBN 978-0-12-418691-0. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780124186910000010>.

GIURGIUTIU, V. Structural health monitoring with piezoelectric wafer active sensors. *Elsevier Inc, Academic Press, 2nd edition*, 2014.

GIURGIUTIU, V.; ROGES, C. A. Recent advancements in the electromechanical (e/m) impedance method for structural health monitoring and nde. in: *Smart Structures and Materials 1998: Smart Structures and Integrated Systems, International Society for Optics and Photonics*, v. 3329, p. 536–548, 1998.

GÉRON, A. Hands-on machine learning with scikit-learn, keras, and tensorflow: Concepts, tools, and techniques to build intelligent systems. [S.l.]: "O'Reilly Media, Inc.", 2019.

HE, Y. et al. *A framework of structural damage detection for civil structures using fast fourier transform and deep convolutional neural networks*. 2021.

HEARN, G.; TESTA, R. Modal analysis for damage detection in structures. *Journal of Structural Engineering*, v. 117, p. 3042–3062, 1991.

HEYLEN, W.; LAMMENS, S. Frac : a consistent way of comparing frequency response functions. *Identification in Engineering systems*, p. 48–57, 1996.

HEYLEN, W.; LAMMENS, S. Frac: a consistent way of comparing frequency response functions. In: . [S.l.: s.n.], 1996.

HO, Y.; EWINS, D. Numerical evaluation of the damage index. *Structural Health Monitoring*, p. 995–1011, 2000.

INMAN, D. J. Smart strutures: Examples and new problems. *Proceedings, 16th Brazilian Congress of Mechanical Engineering (COBEM 2001)*, v. 12, p. 4–13, 2001.

- IYER, S. et al. Structural health monitoring of railway tracks using IoT-based multi-robot system. *Neural Computing and Applications*, v. 33, n. 11, p. 5897–5915, 2021. ISSN 14333058.
- KIN, J.; STUBBS, N. Crack detection in beam-type structure using frequency data. *Journal of Sound and Vibration*, v. 259(1), p. 145–160, 2003.
- KRAWCZUK, M.; PALACZ, M.; OSTACHOWICS, W. The dynamic analysis of a cracked timoshenko beam by the spectral element method. *Journal of Sound and Vibration*, p. 1139–1153, 2002.
- KURIAN, B.; LIYANAPATHIRANA, R. *Machine Learning Techniques for Structural Health Monitoring*. Springer Singapore, 2020. 3–24 p. ISSN 21954364. ISBN 9789811383304. Disponível em: (http://dx.doi.org/10.1007/978-981-13-8331-1_1).
- LEE, B.; STASZEWSKI, W. Modelling of lamb waves for damage detection in metallic structures: part ii. wave interactions with damage. *Smart Materials and Structures*, 2003.
- LEE, U. Spectral element method in structural dynamics. *John Wiley Sons.*, 2009.
- LIFSHITZ, J.; ROTEM, A. Determination of reinforcement unbonding of composites by a vibration technique. *Journal of Composite Materials*, v. 3, p. 412–423, 1969.
- LIMA, M. N. A. Testes modais utilizando martelo instrumentado em estruturas de baixas frequências naturais. *UFPB/CT/PPGEM*, 2006.
- LIU, L.; MENG, G. Localization of Damage in Beam-like Structures by Using Support Vector Machine. p. 919–924, 2005.
- LÉORNAD, F. et al. Free-vibration behaviour of a cracked cantilever beam and crack detection. *Mechanical Systems and Signal Processing*, v. 15, n. 3, p. 529–548, 2001.
- MACHADO, M.; ADHIKARI, S.; SANTOS, J. D. A spectral approach for damage quantification in stochastic dynamic systems. *Mechanical Systems and Signal Processing*, v. 88, p. 253–273, 2017.
- MACHADO, M.; ADHIKARI, S.; SANTOS, J. M. C. D. A spectral approach for damage quantification in stochastic dynamic systems. *Mechanical Systems and Signal Processing*, p. 253–273, 2017.
- MACHADO, M.; ADHIKARI, S.; SANTOS, J. M. C. D. Spectral element-based method for a onedimensional damaged structure with distributed random properties. *Journal of Brazilian Society of Mechanical Sciences and Engineering*, p. 214–226, 2018.
- MACHADO, M.; APPERT, A.; KHALIJ, L. Spectral formulated modelling of an electrodynamic shaker. *Mechanics Research Communications*, p. 70–78, 2019.
- MACHADO, M. R. et al. Bandgap manipulation of single and multi-frequency smart metastructures with random impedance disorder. *Smart Materials and Structures*, v. 31, n. 10, 2022. ISSN 1361665X.
- MACHADO, M. R.; SANTOS, J. M. C. D. Reliability analysis of damaged beam spectral element with parameter uncertainties. *Shock and Vibration*, 2015.
- MACHADO M. R., A. S.; SANTOS, J. M. C. D. Spectral element-based method for a one-dimensional damaged structure with distributed random properties. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 1, p. 1–16, 2018. Disponível em: (<https://doi.org/10.1007/s40430-018-1330-2>).

- MACHADO M.R.; DOS SANTOS, J. Effect and identification of parametric distributed uncertainties in longitudinal wave propagation. *Applied Mathematical Modelling*, v. 1, 2021.
- MACHADO M.R., M. B. D. S. M. T. Bandgap manipulation of single and multi-frequency smart metastructures with random impedance disorder. *Smart Materials and Structures*, v. 1, 2022.
- MAIA J. M. M. SILVA, E. A. R. S. N. Damage detection in structures: from mode shape to frequency response function methods. *Mechanical Systems and Signal Processing*, v. 17(3), p. 489–498, 2003.
- MAIA N.M.M., A. R. U. A. S. R. Mechanical systems and signal processing. *Smart Materials and Structures*, v. 25(7), p. 2475–248, 2011.
- MALEKLOO, A. et al. *Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights*. [S.l.: s.n.], 2021. v. 0. 1–50 p. ISSN 17413168. ISBN 1475921721.
- Manjurul Islam, M. M.; KIM, J. M. Vision-based autonomous crack detection of concrete structures using a fully convolutional encoder–decoder network. *Sensors (Switzerland)*, v. 19, n. 19, p. 1–12, 2019. ISSN 14248220.
- Mansouri Nejad, N. et al. A damage detection procedure using two major signal processing techniques with the artificial neural network on a scaled jacket offshore platform. *Advances in Structural Engineering*, v. 24, n. 8, p. 1655–1667, 2021. ISSN 20484011.
- MARQUI, C. R. Modelagem de estruturas piezelétricas para aplicação em localização de falhas. *Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira*, 2007.
- MCCALLUM, A.; NIGAM, K. A comparison of event models for naive bayes text classification. *Proc. AAAI/ICML-98 Workshop on Learning for Text Categorization*, 1998.
- MEHTA P., B. M. W. C.-H. D. A. G.-R. C. F.-C. K. e. S. D. J. A high-bias, low-variance introduction to machine learning for physicists. *Physics Reports*, v. 810, p. 1–124, 2019.
- MESSINA A., J. I.; WILLIAMS, E. Damage detection and localization using natural frequency changes. *In Proceedings of the 1st Conference on Identification, Cambridge, England, UK*, v. 1, p. 67–76., 1992.
- MESSINA A., W. E.; CONTURSI, T. Structural damage detection by a sensitivity and statistical-based method. *Journal of Sound and Vibration*, v. 216(5), p. 791–808, 1998.
- MOHAMMED M., K. M. B. B.-E. B. M. *Machine Learning Algorithms and Applications*. [S.l.: s.n.], 2017.
- MONNIER, T. Lamb waves-based impact damage monitoring of a stiffened aircraft panel using piezoelectric transducers. *Journal of Intelligent Material Systems and Structures*, v. 17, p. 411–421, 2006.
- MOURA B.B., M. M. M. T.-D. S. Dynamic and wave propagation analysis of periodic smart beams coupled with resonant shunt circuits: passive property modulation. *European Physical Journal-Special Topics*, p. 1–17, 2022.
- NELLI, F. Python data analytics. *Nova York: Apress. Springer Science + Business*, 2015.
- NG, C.; VEIDT, M.; LAM, H. Probabilistic damage characterisation in beams using guided waves. *Procedia Engineering*, p. 490–497, 2011.

- NICK W., A. K. B. G.-E. A. S. M. A study of machine learning techniques for detecting and classifying structural damage. *Int. J. Mach. Learn. Comput.*, p. 313–338, 2015.
- NUNES, L. A. et al. A hybrid learning strategy for structural damage detection. *Structural Health Monitoring*, v. 20, n. 4, p. 2143–2160, 2021. ISSN 17413168.
- OSTACHOWICZ, W. M. Damage detection of structures using spectral finite element method. *Computers Structures*, p. 454–462, 2008.
- OTCHERE T. O. ARBI GANAT, R. G. D. A.; RIDHA, S. Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ann and svm models. *Journal of Petroleum Science and Engineering*, v. 200, p. 48—58, 2020.
- OWOLABI G.; SWAMIDAS, A.; SESHADRI, R. Crack detection in beams using changes in frequencies and amplitudes of frequency response functions. *Journal of Sound and Vibration*, v. 265(1), p. 1–22, 2003.
- PALACZ, M. Spectral methods for modelling of wave propagation in structures in terms of damage detection: a review. *Applied Sciences*, p. 1809–1816, 2018.
- PALACZ, M.; KRAWCZUK, M. Analysis of longitudinal wave propagation in a cracked rod by the spectral element method. *Computers structures*, p. 1809–1816, 2002.
- PARK, S.; YUN, C.; ROH, Y. Pzt-based active damage detection techniques for steel bridge components. *Smart Materials and Structures*, 2006.
- PASCUAL, R.; GOLINVAL, J. a. R. M. On-line damage assessment using operating deflection shapes. *In: SEM-IMAC-XV-17th*, p. 813–827, 1999.
- PASCUAL R.; GOLINVAL, J.; RAZETO, M. A frequency domain correlation technique for model correlation and updating. *In: SEM-IMAC-XV-15th*, p. 813–827, 1997.
- PATHIRAGE, C. S. N. et al. Structural damage identification based on autoencoder neural networks and deep learning. *Engineering Structures*, v. 172, p. 13–28, 2018.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- PERRY, B. J.; GUO, Y.; MAHMOUD, H. N. Automated site-specific assessment of steel structures through integrating machine learning and fracture mechanics. *Automation in Construction*, Elsevier B.V., v. 133, n. September 2021, p. 104022, 2022. ISSN 09265805. Disponível em: (<https://doi.org/10.1016/j.autcon.2021.104022>).
- POLICARPO H., N. M. M.; MAIA, N. M. M. A simple method for the determination of the complex modulus of resilient materials using a longitudinally vibrating three-layer specimen. *Journal of Sound and Vibration*, v. 332, p. 246–263, 2013.
- PRATICO, F. G. et al. Detection and monitoring of bottom-up cracks in road pavement using a machine-learning approach. *Algorithms*, v. 13, n. 4, p. 1–16, 2020. ISSN 19994893.
- RATHOD, V. T.; MUKHERJEE, S.; DENG, Y. Machine learning enabled damage classification in composite laminated beams using mode conversion quantification. n. May 2020, p. 11, 2020. ISSN 1996756X.
- RELATÓRIO-UNB. Relatório técnico- departamento enc/unb 001. Brasília, 26.02.2018. 2018.

RIZZO, P.; LANZA, F. Feature extraction for defect detection in strands by guided ultrasonic waves. *Structural Health Monitoring*, 2006.

RUSSELL S., N. P. Artificial intelligence: A modern approach(2nd ed.). *Prentice Hall*, 2003.

RYTTER, A. *Vibrational Based Inspection of Civil Engineering Structures*. Tese (Doutorado), Denmark, 1993. Ph.D.-Thesis defended publicly at the University of Aalborg, April 20, 1993 PDF for print: 206 pp.

SAEED Z., F. C. M.; BERRUTI, T. M. Joint identification through hybrid models improved by correlations. *Journal of Sound and Vibration*, v. 494, 2021.

SALEHI, H. et al. A methodology for structural health diagnosis and assessment using machine learning with noisy and incomplete data from self-powered wireless sensors. n. March 2018, p. 31, 2018. ISSN 1996756X.

SANTOS E. FIGUEIREDO, M. S. C. S. J. C. A. Machine learning algorithms for damage detection: Kernel-based approaches. *J. Sound Vib*, v. 363, p. 584–599, 2016.

SHARMA, V.; RUZZENE, M.; HANAGUD, S. Damage index estimation in beams and plates using laser vibrometry. 2006.

SILVA, M. F. M. d. *MACHINE LEARNING ALGORITHMS FOR DAMAGE DETECTION IN STRUCTURES UNDER CHANGING NORMAL CONDITIONS*. Tese (Dissertação de Mestrado) — Graduate Program in Electrical Engineering of the UFPA, 2017. Disponível em: <http://repositorio.ufpa.br:8080/jspui/handle/2011/8993>.

SINOUE, J.; LEES, A. W. Influence of cracks in rotating shafts. *Journal of Sound and Vibration*, v. 285(4-5), p. 1015–1037, 2005.

SINOUE, J.-J. Numerical investigations of a robust identification of crack location and size in beams using only changes in ratio pulsations of the cracked beams. *Structural Engineering Mechanics*, v. 25(6), p. 691–716, 2007.

SINOUE, J. J. A review of damage detection and health monitoring of mechanical systems from changes in the measurement of linear and non-linear vibrations. *Mechanical Vibrations: Measurement, Effects and Control*, n. June, p. 643–702, 2009.

SOARES Y.M.F, M. M. D. M. The spectral approach of love and mindlin-herrmann theory in the dynamical simulations of the tower-cable interactions under the wind and rain loads. *Energies*, p. 7725, 2022.

STAWIARSKI, A.; MUC, A. On transducers localisation in damage detection by wave propagation method. *Sensors MDPI*, 2019.

SU, Z.; YE, L. Identification of damage using lamb waves: from fundamentals to applications. *Springer Science Business Media.*, v. 48, 2009.

SUN, Z.; SANTOS, J.; CAETANO, E. Vision and Support Vector Machine–Based Train Classification Using Weigh-in-Motion Data. *Journal of Bridge Engineering*, v. 27, n. 6, p. 1–8, 2022. ISSN 1084-0702.

SUN, Z.; SANTOS, J.; CAETANO, E. Vision and Support Vector Machine–Based Train Classification Using Weigh-in-Motion Data. *Journal of Bridge Engineering*, v. 27, n. 6, p. 1–8, 2022. ISSN 1084-0702.

TADA H.; PARIS, P. C. I. G. R. The stress analysis of cracks. *Handbook, Del Research Corporation*, 1973.

- THARWAT, A. Parameter investigation of support vector machine classifier with kernel functions. *Knowledge and Information Systems*, Springer London, v. 61, n. 3, p. 1269–1302, 2019. Disponível em: <https://doi.org/10.1007/s10115-019-01335-4>.
- TIBADUIZA, D. et al. A Damage Classification Approach for Structural Health Monitoring Using Machine Learning. *Complexity*, v. 2018, 2018. ISSN 10990526.
- TSENG, K. K.; NAIDU, A. Non-parametric damage detection and characterization using smart piezoceramic material. *Smart Materials and Structures*, v. 11 (3), p. 371, 2002.
- TSUCHIMOTO K., W. N.; KITAGAWA, Y. DIAGNOSTIC ASSESSMENT SYSTEM FOR STRUCTURAL SEISMIC SAFETY - DAMAGE IDENTIFICATION BASED ON NEURAL NETWORKS AND TORSION. n. 1842, 2004.
- VITOLA, J. et al. A sensor data fusion system based on k-nearest neighbor pattern classification for structural health monitoring applications. *Sensors (Switzerland)*, v. 17, n. 2, 2017. ISSN 14248220.
- WANG, L.; LIE, S. T.; ZHANG, Y. Damage detection using frequency shift path. *Mechanical Systems and Signal Processing*, Elsevier, v. 66-67, p. 298–313, 2016. ISSN 10961216. Disponível em: <http://dx.doi.org/10.1016/j.ymssp.2015.06.028>.
- YUAN, F.-G. et al. Machine learning for structural health monitoring: challenges and opportunities. v. 1137903, n. April 2020, p. 2, 2020. ISSN 1996756X.
- ZANATTA F. BARCHI, A. B. A. B. D. B. L.; ACQUAVIVA, A. Damage detection in structural health monitoring with spiking neural networks. *IEEE International Workshop on Metrology for Industry 4.0 IoT (MetroInd4.0 IoT)*, p. 105–110, 2021.
- ZANG, C.; IMREGUN, M. Structural damage detection and localization using frf-based model updating approach. *Key Engineering Materials*, p. 191–200, 2003.
- ZANG C., F. M. I.; IMREGUN, M. Structural health monitoring and damage assessment using measured frfs from multiple sensors, part i: The indicator of correlation criteria. *Key Engineering Materials*, v. 1, p. 131–140, 2003.
- ZANG C., G. H.; IMREGUN, M. Frequency-domain criteria for correlating and updating dynamic finite element models. *Mechanical Systems and Signal Processing*, v. 15, p. 139–155, 2001.
- ZHANG, H. A otimização de naive bayes. *Proc. FLAIRS.*, 2004.
- ZHANG, H. et al. Non-destructive ultrasonic testing in rod structure with a novel numerical laplace based wavelet finite element method. *Latin American Journal of Solids and Structures*, p. 2606–262, 2018.
- ZHANG, Y.; LIE, S. T.; XIANG, Z. Damage detection method based on operating deflection shape curvature extracted from dynamic response of a passing vehicle. *Mechanical Systems and Signal Processing*, Elsevier, v. 35, n. 1-2, p. 238–254, 2013. Disponível em: <http://dx.doi.org/10.1016/j.ymssp.2012.10.002>.
- ZHOU Q., N. Y. Z. Q. L. L.; LEI, J. Structural damage detection method based on random forests and data fusion. *Structural Health Monitoring*, v. 12, p. 48—58, 2013. Disponível em: <https://doi.org/10.1177/1475921712464572>.