

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

BRUNO ZANELLI VIEIRA

**IDENTIFICAÇÃO DE DANOS EM PAINÉIS METÁLICOS BASEADA
EM VIBRAÇÕES EM CONJUNTO COM ALGORITMOS DE
MACHINE LEARNING**

SÃO CARLOS
2025

BRUNO ZANELLI VIEIRA

**IDENTIFICAÇÃO DE DANOS EM PAINÉIS METÁLICOS BASEADA
EM VIBRAÇÕES EM CONJUNTO COM ALGORITMOS DE
MACHINE LEARNING**

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Mecânica da Universidade Federal de São Carlos, como requisito parcial para obtenção do título de Bacharel em Engenharia Mecânica.

Orientador: Prof. Dr. Alexandre Tácito Malavolta
Coorientador: Prof. Dr. Vitor Ramos Franco

SÃO CARLOS
2025



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS

COORDENAÇÃO DO CURSO DE ENGENHARIA MECÂNICA - CCEMec/CCET/R

Rod. Washington Luís km 235 - SP-310, s/n - Bairro Monjolinho, São Carlos/SP, CEP 13565-905

Telefone: (16) 33519703 - <http://www.ufscar.br>

DP-TCC-FA nº 42/2025/CCEMec/CCET/R

Graduação: Defesa Pública de Trabalho de Conclusão de Curso

Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

BRUNO ZANELLI VIEIRA

IDENTIFICAÇÃO DE DANOS EM PAINÉIS METÁLICOS BASEADA EM VIBRAÇÕES EM CONJUNTO COM ALGORITMOS DE MACHINE LEARNING

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 08 de dezembro de 2025

ASSINATURAS E CIÊNCIAS

Cargo/Função	Nome Completo
Orientador	Alexandre Tácito Malavolta
Membro da Banca 1	Vitor Ramos Franco
Membro da Banca 2	Sidney Bruce Shiki



Documento assinado eletronicamente por **Alexandre Tácito Malavolta, Docente**, em 08/12/2025, às 18:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sidney Bruce Shiki, Docente**, em 08/12/2025, às 18:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Vitor Ramos Franco, Docente**, em 08/12/2025, às 18:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufscar.br/autenticacao>, informando o código verificador **2083890** e o código CRC **D68B94F1**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.038834/2025-92

SEI nº 2083890

RESUMO

O monitoramento de danos em estruturas civis e mecânicas é essencial para garantir a segurança e a funcionalidade ao longo de sua vida útil, processo conhecido como Monitoramento da Integridade Estrutural (SHM). O SHM utiliza sensores, técnicas de monitoramento e algoritmos de análise para detectar danos, fadiga e degradação. Entre as técnicas experimentais, destaca-se o SHM baseado em vibrações, que correlaciona parâmetros modais e físicos para monitorar estruturas por meio de sensores como pastilhas piezoelétricas. Nos últimos anos, a aprendizagem de máquina (Machine Learning — ML) passou a ser empregada para aprimorar a detecção e o prognóstico de danos estruturais no SHM, demonstrando grande potencial para melhorar a eficiência e a precisão. Este trabalho tem como objetivo utilizar SHM baseado em vibrações e algoritmos supervisionados de ML para identificar danos em painéis metálicos, empregando um setup experimental com uma placa metálica. A placa, em sua configuração inicial sem danos, foi testada, e sua função resposta em frequência (FRF) foi coletada experimentalmente por meio de teste via martelo de impacto e pastilhas piezoelétricas utilizadas como sensores. Em seguida, um modelo em elementos finitos da placa foi desenvolvido e ajustado com os dados experimentais, de modo que simulações para a geração de novas FRFs numéricas puderam ser realizadas, considerando diferentes danos na estrutura. Os resultados do modelo serviram como base de dados para alimentar e treinar algoritmos supervisionados de classificação de Machine Learning. Na etapa de validação, os modelos apresentaram capacidade de detecção e localização do dano, com acurácias entre 30% e 60% para a identificação da zona afetada e entre 40% e 80% para a classificação da intensidade do dano, com destaque para o SVM e para as bases construídas com o índice RMSD. Dessa forma, o projeto permitiu desenvolver uma metodologia de detecção de danos que integra dados experimentais, modelos computacionais e algoritmos de ML, evidenciando o potencial dessa abordagem para aplicações em SHM.

Palavras-chave: Monitoramento da integridade estrutural. *Machine Learning*. Modelo de elemento finitos. Análise Modal.

ABSTRACT

Structural damage monitoring in civil and mechanical structures is essential to ensure safety and functionality throughout their service life, a process known as Structural Health Monitoring (SHM). SHM employs sensors, monitoring techniques, and analysis algorithms to detect damage, fatigue, and degradation. Among experimental approaches, vibration-based SHM stands out for correlating modal and physical parameters to monitor structures using sensors such as piezoelectric patches. In recent years, Machine Learning (ML) has increasingly been applied to enhance damage detection and prognosis in SHM, demonstrating strong potential to improve efficiency and accuracy. This work aims to employ vibration-based SHM and supervised ML algorithms to identify damage in metallic panels, using an experimental setup with a metallic plate. In its initial undamaged configuration, the plate was tested, and its Frequency Response Function (FRF) was experimentally obtained through impact hammer testing and piezoelectric sensors. A finite element model of the plate was then developed and calibrated using the experimental data, enabling simulations to generate new numerical FRFs under different damage scenarios. The results from this model were used to build databases for training supervised ML classification algorithms. In the validation stage, the models demonstrated the ability to detect and locate damage, with accuracies ranging from 30% to 60% for identifying the damaged zone and from 40% to 80% for classifying damage intensity, with the best performance observed for the SVM and for datasets constructed using the RMSD index. Thus, the project enabled the development of a damage detection methodology that integrates experimental data, computational modeling, and ML algorithms, highlighting the potential of this approach for SHM applications.

Keywords: Structural Health Monitoring. Machine Learning. Finite Element Method. Modal Analysis.

LISTA DE FIGURAS

Figura 1 – Pastilha Piezoelétrica	13
Figura 2 – Processo de construção de um modelo de aprendizado de máquina . . .	15
Figura 3 – Fluxograma esquemático da metodologia utilizada.	20
Figura 4 – <i>Setup</i> do teste experimental de impacto	21
Figura 5 – Distribuição das pastilhas piezoelétricas na placa	22
Figura 6 – Desenho esquemático das zonas e posições	22
Figura 7 – Teste experimental da placa — <i>baseline</i>	24
Figura 8 – Teste experimental da placa com dano	24
Figura 9 – Malha com dano na zona 6	25
Figura 10 – Estrutura principal do <i>software</i> Orange Data Mining	27
Figura 11 – FRF experimental da placa engastada	31
Figura 12 – Comparação FRF experimental e modelo MEF	32
Figura 13 – Comparação FRFs MEF — primeiro e segundo ajuste	32
Figura 14 – Comparação FRFs MEF — PZT 1	33
Figura 15 – Comparação das frequências de ressonância — Zonas 1 a 3	34
Figura 16 – Comparação das frequências de ressonância — Zonas 4 a 6	34
Figura 17 – Comparação das frequências de ressonância — Zonas 7 a 9	35
Figura 18 – Confronto da localização das zonas com os deslocamentos para o (a) primeiro e (b) segundo modo de vibrar da placa	36
Figura 19 – Desempenho de treinamento <i>databases</i> I a IV - Zona	38
Figura 20 – Desempenho de validação <i>databases</i> I a IV - Zona	38
Figura 21 – Desempenho de treinamento <i>databases</i> I a IV — Intensidade	39
Figura 22 – Desempenho de validação <i>databases</i> I a IV — Intensidade	40
Figura 23 – Desempenho de treinamento <i>databases</i> V a VIII — Zona	41
Figura 24 – Desempenho de validação <i>databases</i> V a VIII — Zona	42
Figura 25 – Desempenho de treinamento <i>databases</i> V a VIII — Intensidade	43
Figura 26 – Desempenho de validação <i>databases</i> V a VIII — Intensidade	44

LISTA DE TABELAS

Tabela 1 – Casos de dano testados experimentalmente.	23
Tabela 2 – Quantidade de elementos — modelo MEF	25
Tabela 3 – Propriedades PZT	26
Tabela 4 – Rigidez do engaste no modelo MEF	26
Tabela 5 – Amortecimento estrutural MEF — Primeiro ajuste	26
Tabela 6 – Amortecimento estrutural MEF — Segundo ajuste	26
Tabela 7 – Parâmetros da Rede Neural	28
Tabela 8 – Parâmetros do SVM	28
Tabela 9 – Parâmetros da Floresta Aleatória	28
Tabela 10 – Exemplo de rótulos e atributos dos <i>databases</i> I, II, III e IV	29
Tabela 11 – Exemplo de rótulos e atributos dos <i>databases</i> V, VI, VII e VIII	30
Tabela 12 – Matriz de confusão - Rede Neural - <i>database</i> VIII	36
Tabela 13 – Matriz de confusão - Rede Neural - <i>database</i> I	37

SUMÁRIO

1 – INTRODUÇÃO	9
1.1 Objetivos	10
2 – REVISÃO BIBLIOGRÁFICA	11
2.1 Introdução ao SHM e motivação	11
2.2 Sensores piezoelétricos (PZT) no SHM	12
2.3 <i>Machine Learning</i> em SHM	14
2.3.1 Modelos de classificação e critérios de desempenho	16
2.4 Integração entre dados numéricos e experimentais em SHM	18
3 – MATERIAIS E MÉTODOS	20
3.1 Testes e equipamentos	21
3.2 Modelo de elementos finitos	23
3.3 Modelos de <i>Machine Learning</i>	26
3.4 Plano de estudos	29
3.4.1 Magnitude das FRFs nas regiões de ressonância	29
3.4.2 Índice RMSD nas regiões de ressonância	29
4 – RESULTADOS	31
4.1 FRFs experimentais e numéricas	31
4.2 Desempenho dos algoritmos de classificação	36
5 – CONSIDERAÇÕES FINAIS E CONCLUSÃO	46
REFERÊNCIAS	48
Apêndices	50
APÊNDICE A – Bases de dados completas	51

1 INTRODUÇÃO

Nas últimas décadas, o desenvolvimento de tecnologias voltadas à segurança e à confiabilidade estrutural tornou-se uma das principais preocupações em diversos setores da engenharia, como o aeronáutico, automotivo, civil e mecânico. Estruturas metálicas e compósitas estiveram constantemente sujeitas a condições adversas de operação — vibrações, impactos, fadiga e variações térmicas — que podiam gerar danos progressivos e comprometer seu desempenho. A detecção precoce desses danos foi essencial para evitar falhas catastróficas, reduzir custos de manutenção e prolongar a vida útil de equipamentos e componentes (KOT et al., 2021).

Nesse contexto, o *Structural Health Monitoring* (SHM), ou Monitoramento da Integridade Estrutural, surgiu como uma ferramenta promissora para acompanhar o estado real das estruturas em operação. Por meio de sensores e métodos de aquisição de dados, o SHM permitiu identificar alterações no comportamento dinâmico de um sistema e, assim, inferir a presença de falhas ou degradações (FRANCO, 2009). Entre as diferentes abordagens existentes, o SHM baseado em vibrações se destacou por sua natureza não destrutiva e pela possibilidade de realizar medições contínuas sem a necessidade de interromper o funcionamento do equipamento.

Apesar de seu potencial, a aplicação prática dessa técnica ainda enfrentou desafios. A quantidade de dados coletados em testes experimentais é elevada e, muitas vezes, de difícil interpretação manual. Pequenas variações nas medições — causadas por ruídos, temperatura ou imperfeições na montagem — podem mascarar indícios de dano ou gerar falsos alarmes. Nesse cenário, tornou-se indispensável o uso de ferramentas computacionais capazes de lidar com grandes volumes de informação e reconhecer padrões complexos de forma automática (MALEKLOO et al., 2022).

Foi nesse ponto que as técnicas de *Machine Learning* (Aprendizado de Máquina) ganharam relevância dentro do campo do SHM. A integração entre essas áreas permitiu o desenvolvimento de sistemas inteligentes de diagnóstico estrutural, capazes de aprender com dados experimentais e prever (ou predizer) o estado de integridade de uma estrutura com alta precisão. O uso de modelos supervisionados de classificação, por exemplo, possibilitam não somente indicar a existência de um dano, mas também identificar sua localização e intensidade, favorecendo ações corretivas direcionadas (BAO et al., 2025).

A crescente demanda por sistemas estruturais mais seguros, leves e duráveis reforçou a importância de métodos de monitoramento eficientes e automatizados. Nesse sentido, o desenvolvimento de soluções que integrassem o SHM com técnicas de *Machine Learning* é fundamental para viabilizar a manutenção preditiva de estruturas, reduzindo custos operacionais e evitando paradas não planejadas (THAI, 2022).

Além disso, o estudo de painéis metálicos instrumentados com sensores inteligentes,

como os materiais piezoelétricos, contribuiu diretamente para o avanço das pesquisas na área de materiais inteligentes e engenharia estrutural aplicada, alinhando-se às tendências de digitalização e automação da indústria moderna. Os ensaios experimentais desenvolvidos neste trabalho, realizados em laboratório, permitiram validar a aplicação prática da metodologia proposta e gerar dados consistentes para o treinamento dos modelos de aprendizado de máquina (FREITAS; BAPTISTA, 2016).

A presente pesquisa deu continuidade a estudos anteriores desenvolvidos (VIEIRA; FRANCO; MALAVOLTA, 2024; VIEIRA; FRANCO; MALAVOLTA, 2025; VIEIRA et al., 2025), ampliando a compreensão do comportamento dinâmico de estruturas danificadas e a aplicação de modelos preditivos no diagnóstico de integridade. Dessa forma, este trabalho reforçou o compromisso com o desenvolvimento científico e tecnológico voltado à segurança estrutural, oferecendo contribuições relevantes tanto no âmbito acadêmico quanto prático.

O presente trabalho se insere nesse contexto de avanço tecnológico e buscou contribuir para a consolidação de metodologias híbridas que unissem experimentação, modelagem numérica e inteligência artificial. A proposta foi empregar o SHM baseado em vibrações, aliado a algoritmos de *Machine Learning*, para a previsão de danos em painéis metálicos, explorando a correlação entre os parâmetros modais medidos experimentalmente e as respostas obtidas por simulações em elementos finitos. Essa abordagem representou um passo importante rumo à automatização do diagnóstico estrutural, com potencial aplicação em componentes aeronáuticos, civis e industriais (YANG; ZHANG; TAN, 2021).

1.1 Objetivos

O presente trabalho teve como objetivo geral utilizar a técnica SHM baseada em vibrações em conjunto com algoritmos supervisionados de classificação de *Machine Learning* (ML) para identificar e localizar danos em painéis metálicos. Desta forma, o projeto permitiu desenvolver uma metodologia de detecção de danos que utilize a combinação de dados experimentais e de modelos computacionais com algoritmos de *Machine Learning*.

Como objetivos específicos, podem ser citados:

- Coletar experimentalmente as Funções Resposta em Frequência (FRFs) da placa metálica utilizando martelo de impacto e sensores piezoelétricos.
- Desenvolver e calibrar um modelo em elementos finitos da placa com base nas FRFs experimentais, possibilitando a simulação de diferentes cenários de dano.
- Construir bases de dados contendo atributos derivados das FRFs (magnitude espectral e índice RMSD) para representação dos diferentes danos simulados.
- Treinar e validar algoritmos supervisionados de *Machine Learning* (SVM, Floresta Aleatória e Rede Neural) para a detecção, localização e quantificação do dano.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta os principais conceitos, técnicas e estudos relacionados ao Monitoramento da Integridade Estrutural (SHM) e ao uso de algoritmos de *Machine Learning* para detecção de danos. São discutidos os fundamentos do SHM baseado em vibrações, os métodos empregados para aquisição e análise de FRFs, bem como as abordagens recentes que combinam modelagem numérica e aprendizagem de máquina. Essa revisão tem como objetivo fornecer a base teórica necessária para compreender a metodologia desenvolvida neste trabalho.

2.1 Introdução ao SHM e motivação

O monitoramento da integridade estrutural, conhecido como *Structural Health Monitoring* (SHM), tem se consolidado como uma das abordagens mais promissoras para assegurar a segurança, a funcionalidade e a durabilidade de sistemas de engenharia complexos. A técnica baseia-se na aquisição e análise contínua de dados provenientes de sensores instalados em pontos estratégicos de uma estrutura, visando identificar danos, degradações ou alterações em seu comportamento dinâmico ao longo do tempo (FRANCO, 2009). Em comparação a métodos tradicionais de inspeção visual e medições pontuais, o SHM permite a detecção precoce de falhas e uma avaliação automatizada do estado estrutural, reduzindo custos de manutenção e aumentando a confiabilidade operacional (KOT et al., 2021).

Nos últimos anos, a aplicação do SHM tem se expandido significativamente em áreas como a engenharia civil, aeronáutica e mecânica, acompanhando o avanço dos sensores inteligentes e das técnicas de processamento de dados. O SHM representa uma das ferramentas mais diretas e avançadas para compreender a evolução de estruturas sob diferentes condições de carregamento e ambiente, permitindo não somente a detecção de danos, mas também a previsão de sua propagação (MALEKLOO et al., 2022; DIAO et al., 2018). A essência da técnica está na correlação entre os dados de monitoramento e o estado de integridade estrutural, transformando grandes volumes de medições em informações diagnósticas úteis.

O desenvolvimento de sistemas embarcados e de sensores piezoelétricos, especialmente os de titanato-zirconato de chumbo (PZT), contribuiu para tornar o SHM uma solução viável em tempo real. Esses sensores são amplamente empregados devido à sua alta sensibilidade e dupla capacidade de atuar como atuadores e receptores de ondas ultrassônicas, possibilitando a análise do comportamento vibracional da estrutura com elevada resolução temporal. Essa combinação de instrumentação inteligente e métodos de análise computacional permite a transição de um monitoramento reativo para uma

abordagem preditiva, na qual algoritmos de aprendizado de máquina extraem padrões dos dados coletados e identificam anomalias associadas a danos estruturais.

No contexto do SHM, a identificação de danos em estruturas pode ser organizada em diferentes níveis de complexidade, conforme amplamente discutido na literatura. O nível 1 corresponde à detecção, cujo objetivo é indicar se há ou não a presença de dano na estrutura. O nível 2 refere-se à localização, isto é, identificar em que região ou componente o dano está situado. Já o nível 3 trata da quantificação, envolvendo a estimativa da severidade ou extensão do dano, normalmente associada à perda de rigidez, variação de massa ou alteração das propriedades mecânicas. Alguns autores ainda incluem um nível 4, referente à prognose, no qual se busca estimar a evolução do dano ao longo do tempo e sua influência na vida útil estrutural. Esses níveis fornecem um arcabouço sistemático para a avaliação do desempenho de técnicas experimentais, numéricas e baseadas em Inteligência Artificial, permitindo situar claramente o objetivo e o alcance de cada metodologia empregada no SHM (RYTTER, 1993; WORDEN; DULIEU-BARTON, 2004).

Entretanto, o crescente volume e a complexidade dos dados adquiridos pelo SHM impuseram novos desafios de processamento e interpretação. Métodos convencionais de análise de sinais e modelagem física, embora fundamentais, muitas vezes se mostram insuficientes para lidar com a alta dimensionalidade, a presença de ruídos e a variabilidade ambiental. Nesse contexto, técnicas de *Machine Learning* (ML) vêm sendo incorporadas como ferramentas eficazes para a extração automática de características, a classificação de padrões e a predição de danos. Conforme destacado por Thai (2022), a integração entre SHM e ML inaugura uma fase do monitoramento estrutural — mais autônoma, adaptável e orientada por dados — capaz de ampliar substancialmente a eficiência e a confiabilidade dos diagnósticos.


Dessa forma, o estudo e o aprimoramento de métodos de monitoramento estruturais baseados em *Machine Learning* tornam-se fundamentais para o avanço das tecnologias de diagnóstico e previsão de danos. O presente trabalho se insere nesse contexto, buscando explorar a combinação entre sensores piezoelétricos e algoritmos de aprendizado de máquina na detecção e previsão de danos em painéis metálicos, contribuindo para o desenvolvimento de abordagens inteligentes e economicamente viáveis para aplicações de SHM.

2.2 Sensores piezoelétricos (PZT) no SHM

O desempenho de um sistema de monitoramento estrutural depende diretamente da qualidade dos sensores utilizados para adquirir as respostas dinâmicas da estrutura. Entre as tecnologias mais empregadas, os sensores piezoelétricos — particularmente os de titanato-zirconato de chumbo (PZT, *lead zirconate titanate*) — destacam-se pela alta sensibilidade, baixo custo e ampla faixa de frequência de operação. Esses materiais exibem a propriedade de gerar carga elétrica quando submetidos a esforços mecânicos (efeito piezoelétrico direto) e, de forma recíproca, deformar-se mecanicamente quando excitados

por um campo elétrico (efeito piezoelétrico inverso) (MCCONNELL; VAROTO, 2008; RAO, 2008). Tal característica possibilita que um mesmo elemento PZT atue tanto como atuador quanto como sensor, permitindo a excitação e a detecção de ondas ultrassônicas na estrutura monitorada. Na Figura 1 é apresentada uma pastilha PZT.

Figura 1 – Pastilha Piezoelétrica



Fonte: <<https://www.makehero.com/categoria/componentes-eletronicos/piezoeltricos>>

O uso de PZTs em SHM é particularmente vantajoso por possibilitar a detecção de danos mesmo em estágios iniciais, já que as ondas ultrassônicas propagadas pelo material são sensíveis a pequenas variações de rigidez ou trincas. Assim, a análise das alterações nas respostas de frequência ou de fase captadas pelos sensores permite inferir a existência e a localização de descontinuidades estruturais. Além disso, por serem elementos compactos, de fácil fixação e com boa resposta em altas frequências, os PZTs são adequados tanto para aplicações em escala laboratorial quanto em estruturas reais de grande porte, como pontes, aeronaves e painéis metálicos.

Entretanto, embora sua aplicação seja amplamente consolidada, a confiabilidade dos sensores PZT também depende de sua integridade física. Estudos recentes evidenciam que danos superficiais ou sub-superficiais no próprio sensor podem comprometer a precisão das medições e, conseqüentemente, o diagnóstico estrutural. Abhinav et al. (2026) propuseram uma abordagem baseada na transformação *Wavelet Scattering* (WST) para detecção e localização de defeitos internos em sensores PZT, utilizando imagens de campos ultrassônicos processadas por algoritmos de aprendizado de máquina. O método apresentou resultados promissores, permitindo a identificação de anomalias internas sem a necessidade de sinais de referência provenientes de sensores não danificados (*reference-free detection*). Essa contribuição demonstra que, além de monitorarem a estrutura, os PZTs podem ser objeto de autodiagnóstico, garantindo maior robustez e confiabilidade aos sistemas SHM.

Outro aspecto relevante está na integração dos sensores piezoelétricos a sistemas inteligentes de aquisição de dados, como os *Wireless Sensor Networks* (WSN) e as plata-

formas de Internet das Coisas (IoT), que viabilizam a coleta e transmissão contínua das informações em tempo real. Mahdi, Gharghan e Mutlag (2026) destacam que a combinação de sensores PZT, redes sem fio e processamento em nuvem permite a implementação de sistemas de monitoramento remoto e autônomo, reduzindo significativamente a necessidade de inspeções presenciais e possibilitando a detecção automática de anomalias por meio de algoritmos de regressão e classificação.

Dessa forma, os sensores PZT representam o elo físico entre a estrutura e os algoritmos de diagnóstico baseados em *Machine Learning*. Sua capacidade de gerar dados de alta resolução, aliada à possibilidade de excitação controlada e monitoramento contínuo, fornece uma base sólida para o desenvolvimento de metodologias preditivas de detecção de danos. Nos tópicos seguintes, são discutidas as principais técnicas de aprendizado de máquina aplicadas ao SHM e como elas podem ser utilizadas para extrair, classificar e correlacionar informações provenientes desses sensores, aprimorando o processo de previsão de danos em estruturas metálicas.

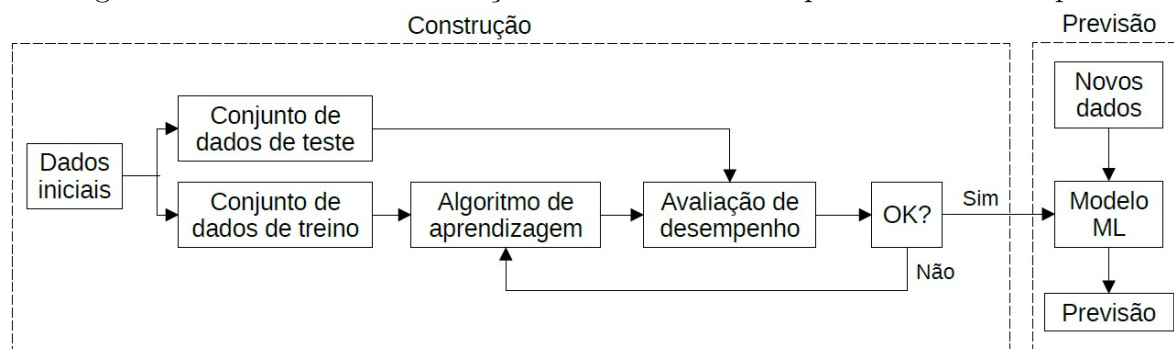
2.3 *Machine Learning* em SHM

Com o avanço dos métodos computacionais e o aumento da quantidade de dados coletados por sensores, o *Machine Learning* (ML) consolidou-se como uma ferramenta fundamental para aprimorar o desempenho dos sistemas de *Structural Health Monitoring* (SHM). Essa integração possibilita a extração automática de padrões complexos nos sinais estruturais, permitindo que o processo de diagnóstico e previsão de danos se torne mais rápido, autônomo e preciso. Segundo Bao et al. (2025), o uso do aprendizado de máquina no contexto de SHM representa uma mudança de paradigma — de uma abordagem puramente física e analítica para uma abordagem orientada por dados (*data-driven*), capaz de lidar com a alta dimensionalidade e a variabilidade dos sinais estruturais.

De forma geral, o desenvolvimento de modelos de aprendizado de máquina segue um fluxo composto pelas etapas de aquisição e preparação dos dados, extração de características relevantes, treinamento e validação do modelo, e posterior teste e avaliação de desempenho. Esse processo é representado de forma esquemática na Figura 2, a qual ilustra as etapas típicas envolvidas na construção de modelos supervisionados aplicados ao monitoramento estrutural.

Tradicionalmente, o diagnóstico de danos em estruturas era realizado por meio de comparações diretas entre medições e modelos analíticos ou de elementos finitos. Embora eficazes em condições controladas, essas metodologias apresentam limitações quando aplicadas a sistemas reais, devido à influência de ruídos, variações ambientais e incertezas de modelagem. Nesse contexto, os algoritmos de ML oferecem uma alternativa robusta, ao aprenderem diretamente dos dados de medição e poderem identificar relações não lineares entre parâmetros modais, respostas dinâmicas e condições estruturais (YANG; ZHANG; TAN, 2021). Além disso, técnicas como *Deep Learning* vêm permitindo o reconhecimento

Figura 2 – Processo de construção de um modelo de aprendizado de máquina



Fonte: elaborado pelo autor (2025)

automático de padrões de dano a partir de grandes bancos de dados experimentais e numéricos, sem necessidade de extração manual de características (*feature engineering*).

Os métodos de aprendizado supervisionado são amplamente empregados para problemas de detecção e classificação de danos. Modelos como Máquinas de Vetores de Suporte (*Support Vector Machines* — SVM), Florestas Aleatórias (*Random Forest* — RF), Redes Neurais Artificiais (*Artificial Neural Networks* — ANN) e *k-Nearest Neighbors* (KNN) têm sido utilizados com bons resultados na identificação de danos em vigas, placas e painéis metálicos (TOH; PARK, 2020). Esses algoritmos conseguem classificar o estado estrutural com base em variáveis extraídas de medições vibracionais, tais como frequências naturais, modos de vibração ou funções resposta em frequência (FRFs) (FANG et al., 2023). Por outro lado, técnicas de aprendizado não supervisionado, como *k-means* e *Principal Component Analysis* (PCA), têm sido aplicadas para agrupar estados estruturais e detectar anomalias sem a necessidade de rótulos pré-definidos, oferecendo vantagens em cenários com escassez de dados rotulados.

De acordo com Bao e Li (2021), a combinação entre aprendizado de máquina e tecnologias de aquisição de dados em tempo real — como sistemas IoT e redes de sensores sem fio — permite implementar estratégias de detecção de anomalias de forma contínua, com processamento local ou em nuvem. Em seu estudo, os autores desenvolveram um sistema de detecção de anomalias baseado em regressão linear múltipla e filtragem de sinais, capaz de estimar a severidade de danos em tempo real. Essa tendência reflete o crescente movimento em direção a sistemas SHM inteligentes, capazes não somente de identificar falhas, mas também de avaliar a sua progressão e prever o comportamento futuro da estrutura.

O emprego de ML no SHM também se estende à identificação modal e à correlação entre dados experimentais e numéricos. Bao et al. (2025) destacam que redes neurais convolucionais (*Convolutional Neural Networks* — CNNs) e *autoencoders* vêm sendo aplicados com sucesso na identificação automática de modos de vibração, na detecção de ruídos e na reconstrução de dados ausentes em medições experimentais. Essas técnicas

possibilitam criar modelos híbridos, nos quais dados de simulação e medições reais são combinados para aumentar a robustez e a generalização das previsões. A integração entre os domínios experimental e numérico, mediada por modelos de aprendizado, é uma das principais tendências atuais da área, ao permitir reduzir o tempo de calibração e aumentar a confiabilidade das análises de dano (MALEKLOO et al., 2022).

Em síntese, o uso de *Machine Learning* em SHM representa um avanço significativo em direção à automação e à predição de falhas estruturais. Por meio da análise inteligente dos dados provenientes de sensores — como os PZTs —, os algoritmos de aprendizado podem classificar o estado de integridade, estimar a localização e a severidade de danos e até mesmo prever sua evolução ao longo do tempo. No próximo tópico, são detalhados os principais modelos de classificação empregados em SHM e os critérios de desempenho utilizados para avaliar a eficácia dessas técnicas.

2.3.1 Modelos de classificação e critérios de desempenho

No contexto de *Machine Learning* aplicado ao *Structural Health Monitoring* (SHM), os algoritmos de classificação desempenham um papel central na identificação e previsão do estado de integridade estrutural. O objetivo principal desses modelos é associar um conjunto de variáveis de entrada — geralmente extraídas de medições vibracionais ou sinais ultrassônicos — a uma categoria de saída que representa o estado da estrutura, como “sem dano”, “dano ameno”, “dano moderado” ou “dano severo”. Essa abordagem supervisionada permite automatizar o processo de diagnóstico, reduzindo a dependência de análises visuais ou empíricas (YANG; ZHANG; TAN, 2021).

Entre os modelos mais utilizados em SHM destacam-se a *Support Vector Machine* (SVM), a *Random Forest* (RF), as *Artificial Neural Networks* (ANN) e os métodos baseados em *k-Nearest Neighbors* (KNN). A SVM é amplamente aplicada pela sua capacidade de separar classes por meio de hiperplanos que maximizam a margem entre os dados, apresentando bom desempenho mesmo em bases de dados de pequena dimensão e com ruído (YANG; ZHANG; TAN, 2021). Já a RF, composta por um conjunto de árvores de decisão treinadas sobre subconjuntos aleatórios de dados, oferece maior robustez e generalização, sendo eficiente em problemas não lineares e de alta dimensionalidade (TOH; PARK, 2020). As redes neurais artificiais, por sua vez, destacam-se pela capacidade de modelar relações complexas e não lineares entre as variáveis de entrada, adaptando-se bem a cenários com grande volume de dados e múltiplas características correlacionadas. Mais recentemente, arquiteturas profundas (*Deep Neural Networks* — DNNs e *Convolutional Neural Networks* — CNNs) têm sido exploradas para reconhecimento automático de padrões de dano a partir de respostas de frequência e de modos de vibração (BAO et al., 2025).

A seleção do modelo de classificação mais adequado depende de fatores como o tamanho e a variabilidade do conjunto de dados, a complexidade do problema e o custo computacional de treinamento. Em muitos estudos, adota-se uma análise comparativa entre

diferentes algoritmos, avaliando-se seu desempenho por meio de métricas padronizadas. Esses indicadores são essenciais para avaliar a capacidade do modelo de distinguir entre estruturas íntegras e danificadas. Dentre as métricas mais empregadas em SHM destacam-se a acurácia, a precisão, a revocação e o *F1-score*, as quais fornecem uma medida quantitativa da capacidade do modelo em identificar corretamente as diferentes classes de dano (MAHDI; GHARGHAN; MUTLAG, 2026).

A matriz de confusão é uma ferramenta fundamental para a análise de desempenho de modelos de classificação, pois permite avaliar detalhadamente como o classificador se comporta em cada classe prevista. Em sua forma básica, trata-se de uma tabela que cruza as classes reais com as classes previstas, organizando os resultados em quatro categorias: verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). Diferentemente de métricas globais, que podem mascarar erros específicos, a matriz de confusão oferece uma visão estruturada sobre o tipo e a frequência das classificações corretas e incorretas, possibilitando identificar vieses, desbalanceamentos e limitações do modelo. Em problemas de SHM, essa abordagem é particularmente valiosa, pois diferentes erros têm implicações distintas sobre a segurança estrutural: um FN pode ocultar um dano real, enquanto um FP pode gerar alarmes desnecessários. Com base na matriz de confusão derivam-se as principais métricas utilizadas neste trabalho que quantificam o desempenho do modelo sob diferentes perspectivas e permitem avaliar não somente a taxa global de acertos, mas também sua capacidade de distinguir corretamente cada classe de dano.

A acurácia (A_{cc}) representa a proporção total de classificações corretas em relação ao número total de amostras, calculada por:

$$A_{cc} = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

Embora útil para uma visão geral do desempenho do modelo, a acurácia pode ser enganosa em bases de dados desbalanceadas, nas quais uma classe é mais frequente que as demais.

Para lidar com esse problema, outras métricas mais específicas são utilizadas. A precisão (P) indica a proporção de previsões positivas que são realmente corretas:

$$P = \frac{VP}{VP + FP} \quad (2)$$

Já a revocação (R), também chamada de sensibilidade, mede a proporção de instâncias positivas corretamente identificadas pelo modelo:

$$R = \frac{VP}{VP + FN} \quad (3)$$

Por fim, o *F1-score* combina precisão e revocação em uma média harmônica, expressando o equilíbrio entre ambas as métricas:

$$F1 = 2 * \frac{P \times R}{P + R} \quad (4)$$

Esses critérios são amplamente adotados em estudos de SHM baseados em aprendizado de máquina, ao permitirem avaliar detalhadamente a capacidade do algoritmo em distinguir entre estados estruturais diferentes, especialmente em situações onde há sobreposição de classes ou ruído experimental (BAO et al., 2025). Além disso, outras métricas como o erro quadrático médio (RMSD) e o coeficiente de determinação (R^2) também podem ser utilizadas, principalmente em tarefas de regressão associadas à estimativa da severidade de dano (MAHDI; GHARGHAN; MUTLAG, 2026).

A escolha e interpretação adequada dessas métricas são fundamentais para validar a confiabilidade dos modelos propostos e orientar a seleção da arquitetura mais eficiente. Assim, o processo de avaliação de desempenho não somente quantifica a eficácia dos algoritmos, mas também auxilia na compreensão de seus limites e potenciais melhorias. No contexto do presente trabalho, tais critérios foram utilizados para comparar diferentes classificadores na tarefa de previsão da localização e severidade de danos em painéis metálicos, a partir de dados simulados e experimentais obtidos por sensores piezoelétricos.

2.4 Integração entre dados numéricos e experimentais em SHM

A eficácia das técnicas de *Structural Health Monitoring* (SHM) baseadas em *Machine Learning* depende fortemente da qualidade e diversidade dos dados utilizados no treinamento e validação dos modelos. Nesse contexto, a integração entre dados numéricos e experimentais tem se mostrado uma estratégia essencial para o desenvolvimento de sistemas de diagnóstico mais precisos e generalizáveis. Essa combinação permite explorar o potencial dos modelos de elementos finitos (MEF) — capazes de simular condições de dano controladas e variáveis ambientais — juntamente com os dados adquiridos por sensores reais, como os piezoelétricos (PZT), que representam o comportamento físico da estrutura sob condições reais de operação (BAO et al., 2025).

As simulações numéricas oferecem a vantagem de gerar bases de dados amplas e parametrizadas, nas quais diferentes cenários de dano, geometrias e propriedades materiais podem ser modelados de forma sistemática. Isso é particularmente útil em situações onde a obtenção de dados experimentais é limitada por custo, tempo ou dificuldade de induzir danos reais em estruturas complexas. Por outro lado, os dados experimentais garantem a fidelidade física do modelo e permitem capturar efeitos não modelados — como ruídos de medição, imperfeições de montagem e variações ambientais. Assim, a integração entre ambos os domínios busca equilibrar a exatidão física dos experimentos com a flexibilidade paramétrica das simulações (MAHDI; GHARGHAN; MUTLAG, 2026).

Diversos estudos recentes têm explorado metodologias para essa integração. Jamshed et al. (2026) propuseram um arcabouço híbrido de *Digital Image Correlation*

(DIC) combinado a redes neurais profundas para estimar deformações e monitorar danos em aeronaves. O modelo foi treinado a partir de dados sintéticos gerados numericamente e ajustado com medições experimentais, resultando em maior robustez frente a ruídos e variações de iluminação. De forma análoga, Bao et al. (2025) destacam o uso crescente de técnicas de *transfer learning* e *data fusion* em SHM, nas quais um modelo treinado com dados simulados é posteriormente refinado com dados reais, reduzindo a necessidade de grandes volumes de ensaios experimentais.

No contexto dos sensores piezoelétricos, essa integração se torna ainda mais relevante. Os sinais adquiridos por PZTs podem ser simulados numericamente a partir de análises harmônicas ou transitórias no domínio da frequência, permitindo a criação de *databases* sintéticos que reproduzem o comportamento das respostas estruturais. A correlação entre as respostas medidas e simuladas possibilita a calibração de parâmetros do modelo numérico, como rigidez, amortecimento e condições de contorno, além de auxiliar na identificação de padrões de dano que servem como entrada para os algoritmos de classificação (ABHINAV et al., 2026). Dessa forma, o modelo de elementos finitos não somente complementa os experimentos, mas atua como um gerador de conhecimento, enriquecendo o conjunto de dados de treinamento para os modelos de aprendizado de máquina.

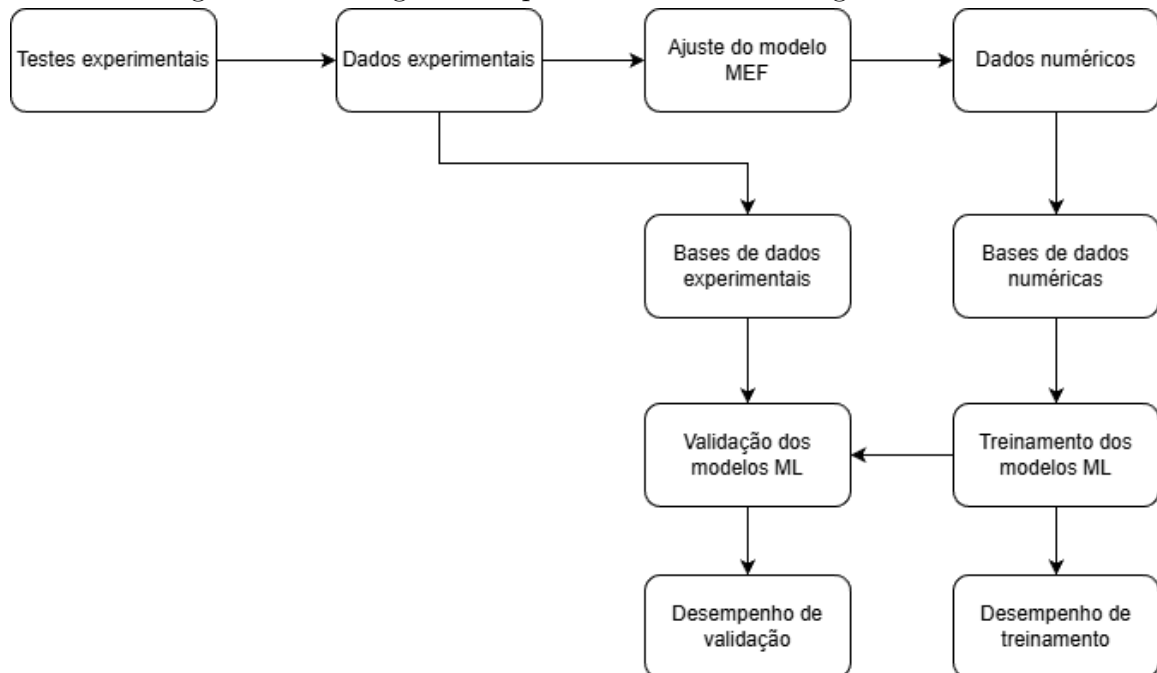
Entretanto, a integração entre domínios numéricos e experimentais também apresenta desafios. Diferenças inerentes entre as condições simuladas e as reais — como simplificações geométricas, incertezas materiais e limitações de discretização — podem introduzir desvios nas previsões do modelo. Técnicas recentes, como o ajuste de modelo baseado em aprendizado (*learning-based model updating*) e o uso de redes neurais inversas, vêm sendo empregadas para reduzir essas discrepâncias, ajustando iterativamente o modelo numérico com base nos dados experimentais (YANG; ZHANG; TAN, 2021). O resultado é um sistema SHM mais robusto e adaptável, capaz de combinar o rigor da modelagem física com a flexibilidade do aprendizado estatístico.

Portanto, a correlação entre dados numéricos e experimentais representa uma etapa-chave na evolução das metodologias de SHM, viabilizando o desenvolvimento de modelos de previsão de danos mais confiáveis e aplicáveis a diferentes condições estruturais. No presente trabalho, essa integração é explorada para aprimorar a capacidade de generalização dos algoritmos de *Machine Learning* utilizados na previsão da localização e severidade de danos em painéis metálicos monitorados por sensores PZT, combinando o poder descritivo das simulações com a representatividade física dos dados experimentais.

3 MATERIAIS E MÉTODOS

A metodologia empregada neste trabalho segue uma sequência integrada de etapas experimentais, numéricas e computacionais, sintetizadas no fluxograma da Figura 3. Inicialmente, foram realizados os testes experimentais na placa, a partir dos quais são obtidos os sinais de resposta utilizados para compor a base de dados experimental. Paralelamente, o modelo de elementos finitos (MEF) é ajustado de modo a reproduzir adequadamente o comportamento dinâmico da estrutura, gerando os dados numéricos correspondentes. As duas fontes de dados — experimental e numérica — são então organizadas em bases de treinamento e validação para aplicação dos algoritmos de *Machine Learning*. Em seguida, os modelos são treinados utilizando os dados numéricos e posteriormente validados com os dados experimentais, permitindo avaliar sua capacidade de generalização. Por fim, são obtidos os desempenhos de treinamento e validação, que servem como métricas para comparar a eficácia dos métodos de classificação utilizados na identificação do dano.

Figura 3 – Fluxograma esquemático da metodologia utilizada.



Fonte: elaborado pelo autor (2025)

É importante destacar que a metodologia adotada baseia-se em algumas premissas inerentes às técnicas utilizadas. Entre elas, assume-se que as condições de contorno da estrutura permanecem constantes ao longo das medições e que as variações observadas nas FRFs são predominantemente atribuídas à presença ou à evolução de danos. Além disso, os modelos de classificação considerados pressupõem que as características extraídas são representativas dos diferentes estados estruturais e que o conjunto de treinamento


é estatisticamente compatível com os dados de validação. Como limitação, ressalta-se que a abordagem depende da qualidade dos sinais experimentais e da fidelidade do modelo numérico, podendo apresentar redução de desempenho em cenários com elevada variabilidade operacional ou forte desbalanceamento entre as classes de dano. Ainda assim, o método demonstra capacidade de generalização adequada dentro das condições avaliadas.

3.1 Testes e equipamentos

A parte experimental deste trabalho, envolvendo os testes de impacto com a placa metálica, foi realizada anteriormente como parte de um projeto prévio, cujos dados foram reaproveitados para as análises computacionais e de *Machine Learning*.

O teste experimental de impacto (*Impact Hammer Modal Testing*) da placa *clamped-free-free-free*, em sua configuração sem dano, é esquematizado nas Figuras 4 e 5. O *setup* de teste foi montado no Laboratório de Projeto Integrado do Departamento de Engenharia Mecânica da UFSCar e foi composto por uma placa com formato de uma chapa chata de alumínio comercial com dimensões da seção transversal de 150 x 1,5 [mm] e comprimento do trecho em balanço com 195 [mm]. A placa foi engastada em um dos lados com auxílio de duas chapas de aço 1020, fixas com parafusos M10 e com torque de 40 Nm em cada um, e por uma prensa hidráulica com 3 toneladas de pressão, utilizada exclusivamente para garantir a fixação rígida da chapa e minimizar vibrações indesejadas durante os testes, da marca *Marcon*, modelo MPH-30.


Figura 4 – *Setup* do teste experimental de impacto



Fonte: elaborado pelo autor (2025)

Para a excitação da placa, foi utilizado um martelo de impacto da marca *PCB Piezotronics*, modelo 086C03, com sensibilidade de 2,25mV/N, o qual permite a medição da força aplicada. Já a resposta da estrutura foi medida por meio de 4 transdutores PZT

Figura 5 – Distribuição das pastilhas piezoelétricas na placa

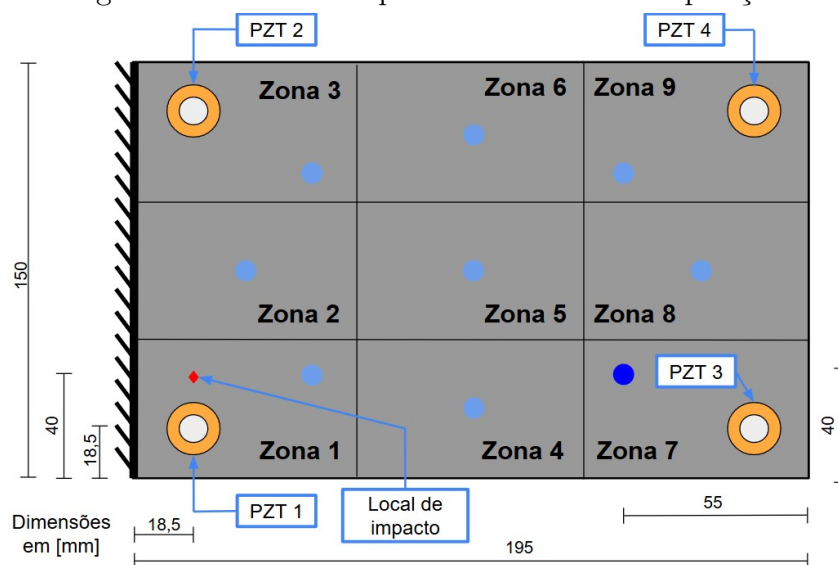


Fonte: elaborado pelo autor (2025)

de modelo 7BB-27-4 da marca *Murata*. Os dados de força e tensão elétrica foram coletados por uma placa de aquisição de dados da marca *National Instruments*, modelo NI-9201. A aquisição de dados foi feita a uma taxa de 12800 Hz com 38400 de amostras durante 3 segundos. Foram realizadas 10 medidas para a placa na condição *baseline* e 5 para cada condições com dano, extraindo, então, a média das curvas medidas. A partir da força de entrada e da tensão elétrica medida como saída, foi possível estimar a Função de Resposta em Frequência para cada um dos testes realizados utilizando-se de comandos disponíveis no *software* MatLab.

Também foram realizados testes experimentais de impacto na placa em um dos lados em sua configuração danificada. Para isso, a superfície foi dividida em nove zonas de igual dimensão, conforme ilustrado na Figura 6.

Figura 6 – Desenho esquemático das zonas e posições



Fonte: elaborado pelo autor (2025)

Os danos foram representados por meio da adição de ímãs – em pares – acoplados em um ponto específico da superfície da placa, representando o acréscimo de massa ao sistema estrutural. Cada ímã possui massa de 2,378 [g], sendo utilizados pares de ímãs em cada caso de dano. Assim, as condições de dano foram rotuladas como D1 = 4,756 [g], D2 = 9,512 [g] e D3 = 14,268 [g]. As condições de dano da placa que foram testadas – além da condição *baseline* – e coletadas pelas pastilhas piezoelétricas são apresentadas na Tabela 1.

Tabela 1 – Casos de dano testados experimentalmente.


Zona	Intensidade	Dano
Z1	Ameno	D1
Z1	Ameno	D2
Z1	Médio	D3
Z2	Ameno	D1
Z2	Ameno	D2
Z2	Médio	D3
Z4	Ameno	D1
Z4	Ameno	D2
Z4	Médio	D3
Z5	Ameno	D1
Z5	Ameno	D2
Z5	Médio	D3
Z8	Ameno	D1
Z8	Ameno	D2
Z8	Médio	D3

Fonte: elaborado pelo autor (2025)

Nos testes da placa em condição *baseline*, foi utilizado um acelerômetro acoplado à estrutura para validação dos sensores piezoelétrico, conforme mostrado na Figura 7. Uma vez validado o uso do piezo, o acelerômetro foi suprimido dos experimentos, conforme apresentado na Figura 8. Tal diferença impacta diretamente no comportamento dinâmico da estrutura, tornando necessária a adoção de dois ajustes distintos de amortecimento para cada pastilha piezoelétrica.


3.2 Modelo de elementos finitos

O modelo de elementos finitos foi desenvolvido utilizando o módulo de simulação de resposta em frequência do *software* NX12 para simular a solitação dinâmica da placa sem dano. A placa foi modelada com elementos do tipo casca (*shell*) e o engaste com elementos de conexão denominados CBUSH os quais permitem a edição e ajustes de rigidez em todos os graus de liberdade. Os transdutores PZT foram modelados utilizando elementos do tipo casca tanto para o disco de latão quanto para a região cerâmica. Em seguida, o modelo de elementos finitos teve os valores de rigidez do engaste e amortecimento ajustados até a obtenção de uma boa correlação com a FRF experimental, adotando como qualidade do

Figura 7 – Teste experimental da placa — *baseline*

Fonte: elaborado pelo autor (2025)

Figura 8 – Teste experimental da placa com dano




Fonte: elaborado pelo autor (2025)

ajuste o erro relativo entre os dados numérico e experimental calculado via norma H2. A solução utilizada no *software* NX12 foi a denominada SOL 111 *Modal Frequency Response* e frequência de amostragem utilizada foi de 0,5 Hz.

Após a calibração do modelo de elementos finitos, novas simulações foram realizadas considerando danos com a adição de massa com 6 valores diferentes ($D1 = 4,756$ [g]; $D2 = 9,512$ [g]; $D3 = 14,268$ [g]; $D4 = 19,024$ [g]; $D5 = 23,78$ [g]; $D6 = 28,536$ [g]), utilizando elementos 0D denominado CONM2 para representar a massa e elementos de conexões denominados RBE2 para sua conexão, distribuídos entre 9 zonas conforme determinado previamente, totalizando 54 casos de dano. Na Tabela 2, é apresentada a quantidade de

elementos utilizados para cada tipo. Para cada possível posição (zona) e intensidade (massa) do dano foi realizada uma simulação e obtida a sua FRF correspondente considerando sempre os mesmos pontos de excitação e de medição utilizados na geração da FRF de base do teste da placa. Na Figura 9, é apresentada uma malha típica com dano na zona 6.

Figura 9 – Malha com dano na zona 6



Fonte: elaborado pelo autor (2025)

Tabela 2 – Quantidade de elementos — modelo MEF

Tipo de elemento	Nº de elementos
QUAD4	2208
CBUSH	25
CONM2	1
RBE2	1

Fonte: elaborado pelo autor (2025)

Para a calibração do modelo, adotaram-se as propriedades dos transdutores PZT segundo Freitas e Baptista (2016). A rigidez no engaste foi definida conforme apresentado na Figura 4. Para um melhor ajuste das regiões dos picos de ressonância foram utilizados, para cada curva FRF, um fator de correção F_c que, para cada caso, variou entre 2 e 5.

Para o amortecimento estrutural do modelo, foram utilizados oito ajustes distintos: um para cada PZT do modelo *baseline*, conforme apresentado na Tabela 5, e outro para os testes com dano, conforme mostrado na Tabela 6. Essa abordagem foi necessária devido à diferença nas condições experimentais.

Tabela 3 – Propriedades PZT

Propriedade	Valor
d_{31} (pm/V)	-207
S_{11}^E (10^{-12} m ² /N)	15,8
$\varepsilon_{33}^T/\varepsilon_0$	2100

Fonte: elaborado pelo autor (2025)

Tabela 4 – Rigidez do engaste no modelo MEF

Rigidez	Valor [N/mm]
Translação em X	10000
Translação em Y	10000
Translação em Z	200000
Rotação em X por radiano	100000
Rotação em Y por radiano	200000
Rotação em Z por radiano	10000

Fonte: elaborado pelo autor (2025)

Tabela 5 – Amortecimento estrutural MEF — Primeiro ajuste

Frequência [Hz]	PZT1	PZT2	PZT3	PZT4
33	0,055	0,054	0,08	0,075
94	0,03	0,04	0,05	0,045

Fonte: elaborado pelo autor (2025)

Tabela 6 – Amortecimento estrutural MEF — Segundo ajuste

Frequência [Hz]	PZT1	PZT2	PZT3	PZT4
33	0,006	0,009	0,03	0,027
94	0,0022	0,0033	0,004	0,004

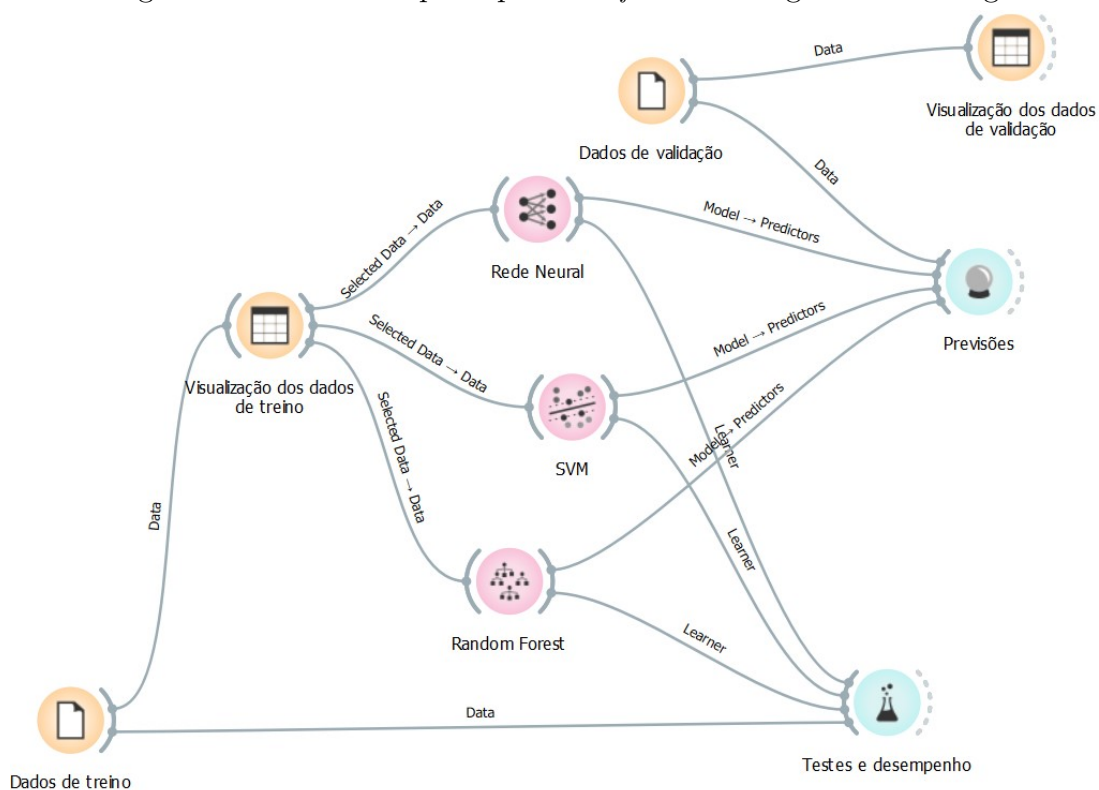
Fonte: elaborado pelo autor (2025)

3.3 Modelos de *Machine Learning*

Os modelos de *Machine Learning* para classificação foram feitos no *software* Orange Data Mining. Os modelos de estudo para este projeto foram Rede Neural (*Neural Network*), SVM (*Support Vector Machine*) e Floresta Aleatória (*Random Forest*). A estrutura do fluxo de dados, conforme a Figura 10, pode ser dividida em 5 partes principais:

- Entrada e separação dos dados de treino;
- Ajuste dos parâmetros de cada modelo;
- Treino e análise dos critérios de desempenho;
- Entrada e separação dos dados de validação;
- Validação e análise de desempenho dos modelos.

Os dados de treinamento referem-se a conjuntos estruturados de dados (*database*) que foram utilizados para treinar os algoritmos de classificação. O *database* é essencial

Figura 10 – Estrutura principal do *software* Orange Data Mining

Fonte: Orange Data Mining (2025)

para que os modelos de *Machine Learning* aprendessem a partir de dados rotulados a identificar padrões e relações entre as características (atributos) das instâncias e suas respectivas classes (rótulos). O objetivo é que, após essa fase, o modelo consiga fazer previsões precisas quando confrontado com novos dados não rotulados. Como o objetivo deste projeto é a localização e quantificação do dano na placa, dois estudos foram conduzidos separadamente: algoritmos de classificação da localização do dano (zona) e da quantificação do dano (intensidade).

Os *databases* foram gerados a partir do processamento das FRFs numéricas obtidas das simulações do modelo de elementos finitos. A cada simulação foi atribuída uma nomenclatura que contém a zona e o dano da seguinte forma: $ZnDm$, na qual n representa a zona, podendo ser variar de 1 a 9, e m , variando de 1 a 6, representando a massa adicionada. Além disso, os danos foram organizados em três intensidades diferentes: Ameno (D1 e D2), Médio (D3 e D4) e Severo (D5 e D6). Esses rótulos foram, então, agrupados e utilizados para formar as bases de dados.

Os parâmetros de cada modelo foram ajustados conforme são apresentados nas Tabelas 7, 8 e 9. Os mesmos ajustes foram utilizados nos três algoritmos de classificação, tanto para a localização do dano, quanto para a quantificação.

Antes de iniciar o treinamento dos modelos, adotou-se a técnica de validação cruzada (*cross-validation*) por atributo (*feature*), na qual os próprios dados são particionados

Tabela 7 – Parâmetros da Rede Neural

Neurônios na camada oculta	21
Função de ativação	ReLU
Otimizador	Adam
Regularização	0,0001
Número máximo de iterações	200
Treinamento replicável	Sim

Fonte: elaborado pelo autor (2025)

Tabela 8 – Parâmetros do SVM

Tipo de SVM	C-SVM
Custo (C)	9,00
Épsilon da função de perda	10,00
Custo de regressão	1,00
Limite de complexidade (γ)	0,50
Kernel	RBF
Parâmetro C do RBF	2,0
Parâmetro γ do RBF	5,0
Tolerância numérica	0,010

Fonte: elaborado pelo autor (2025)

Tabela 9 – Parâmetros da Floresta Aleatória

Número de árvores	500
Número de atributos por divisão	15
Treinamento replicável	Sim
Balacear distribuição das classes	Não
Limitar profundidade das árvores	Não especificado
Não dividir subconjuntos menores que	5

Fonte: elaborado pelo autor (2025)

em subconjuntos de forma sistemática para treino e teste. Dessa forma, não foi necessária uma divisão fixa do *database* em conjuntos específicos, uma vez que, em cada iteração, parte dos dados é utilizada para treinar o modelo, enquanto a outra parte é utilizada para testá-lo. Essa abordagem permite avaliar o desempenho dos modelos de maneira mais robusta e confiável, além de auxiliar na mitigação de problemas como *overfitting*, garantindo que os parâmetros e hiper parâmetros sejam ajustados considerando diferentes partições dos dados.

Após a fase de treinamento, o desempenho dos modelos foi avaliado com base nos critérios de Acurácia, Precisão, Revocação e *F1-Score* a fim de identificar qual *database* e modelo proporciona os melhores resultados.

Na etapa de validação, os modelos previamente treinados foram submetidos a um conjunto de dados não visto, a fim de examinar sua habilidade de classificar adequadamente

o rótulo de cada instância. Para a etapa de validação, os dados foram extraídos das FRFs experimentais.

Após a classificação dos dados de validação, foi possível analisar os resultados através dos mesmos critérios de desempenho citados previamente. A validação forneceu uma avaliação imparcial da capacidade de generalização dos modelos para novos dados. Os resultados obtidos deram uma estimativa de como cada modelo opera em casos não vistos anteriormente.

3.4 Plano de estudos

As FRFs numéricas, índices de dano, os valores de intensidade e de localização da zona permitiram a formação de diferentes bases de dados que foram, então, utilizadas para alimentar e treinar os algoritmos de *Machine Learning* (ML). Duas abordagens na formação das bases de dados foram feitas visando avaliar o desempenho das FRFs e dos índices na precisão de classificação do dano na estrutura. Estas análises são descritas a seguir.

3.4.1 Magnitude das FRFs nas regiões de ressonância

A partir das FRFs numéricas simuladas, foram construídas quatro bases de dados distintas para o treinamento dos modelos de classificação, nomeadas como *Database* I, II, III e IV. Cada base corresponde à resposta obtida por um sensor piezolétrico específico: a *database* I refere-se ao sensor PZT 1, a II ao PZT 2, a III ao PZT 3 e a IV ao PZT 4. Para cada cenário de dano simulado, foi extraída a magnitude da FRF nas regiões próximas aos picos de ressonância. Assim, cada instância da base de dados é caracterizada por um vetor de 20 atributos extraídos dessas regiões, conforme apresentado na Tabela 10.

Tabela 10 – Exemplo de rótulos e atributos dos *databases* I, II, III e IV

Zona	Intensidade	Dano	30,5 Hz	...	35,5 Hz	92 Hz	...	96 Hz
Z1	Ameno	D1	0,43412	...	0,46113	0,3099	...	2,4209
Z1	Ameno	D2	0,4409	...	0,45648	0,33295	...	2,0013
Z1	Médio	D3	0,44787	...	0,45197	0,35868	...	1,7128
Z1	Médio	D4	0,45503	...	0,44759	0,38753	...	1,5027
Z1	Severo	D5	0,46241	...	0,44333	0,42012	...	1,3431
Z1	Severo	D6	0,47	...	0,43918	0,4572	...	1,2178
Z2	Ameno	D1	0,42902	...	0,46461	0,28923	...	3,0828

Fonte: elaborado pelo autor (2025)

3.4.2 Índice RMSD nas regiões de ressonância

Também foram geradas e testadas outras quatro bases de dados, nomeadas como *database* V, VI, VII e VIII, referentes ao PZT 1, 2, 3 e 4, respectivamente. Nessa abordagem

alternativa, cada instância com dano foi representada por um único índice, o *Root-Mean-Square Deviation* (RMSD), calculado conforme definido por Lopes Jr et al. (2000):

$$I_{RMSD} = \sum_{i=1}^n \sqrt{\frac{[(G_{i,B}) - (G_{i,CD})]^2}{[G_{i,B}]^2}} \quad (5)$$

Em que $G_{i,B}$ representa a magnitude da FRF no sinal de referência (*baseline*), isto é, da estrutura sem dano; $G_{i,CD}$ refere-se à magnitude da FRF sob condições danificadas; e n é o número de amostras da FRF consideradas no cálculo. Para essas bases, o índice foi calculado utilizando os mesmos pontos de frequência e magnitude utilizados na abordagem anterior, conforme apresentado na Tabela 11.

Tabela 11 – Exemplo de rótulos e atributos dos *databases* V, VI, VII e VIII

Zona	Intensidade	Dano	RMSD
Z1	Ameno	D1	22,258
Z1	Ameno	D2	16,031
Z1	Médio	D3	13,672
Z1	Médio	D4	15,479
Z1	Severo	D5	13,596
Z1	Severo	D6	9,2095
Z2	Ameno	D1	19,118

Fonte: elaborado pelo autor (2025)

Para a validação e avaliação de desempenho de cada modelo de classificação e conjunto de dados, foram geradas oito bases de dados — uma para cada *database* utilizado em treinamento — a partir dos dados experimentais.


4 RESULTADOS

Neste capítulo são apresentados os principais resultados obtidos a partir das análises experimentais, numéricas e computacionais realizadas ao longo do trabalho. Inicialmente, são comparadas as FRFs medidas e simuladas, de modo a avaliar a qualidade da calibração do modelo de elementos finitos. Em seguida, são discutidos os desempenhos dos algoritmos de *Machine Learning* na tarefa de localização e quantificação do dano, permitindo avaliar a eficácia da metodologia proposta.

4.1 FRFs experimentais e numéricas

As FRFs experimentais da placa, obtida após o processamento dos sinais de força e tensão elétrica coletados, são apresentadas na Figura 11. Pode-se observar os picos correspondentes as frequências naturais dos dois primeiros modos (flexão e torção) na faixa de frequência de 0 até 120 Hz, a qual será considerada nas análises.

Figura 11 – FRF experimental da placa engastada

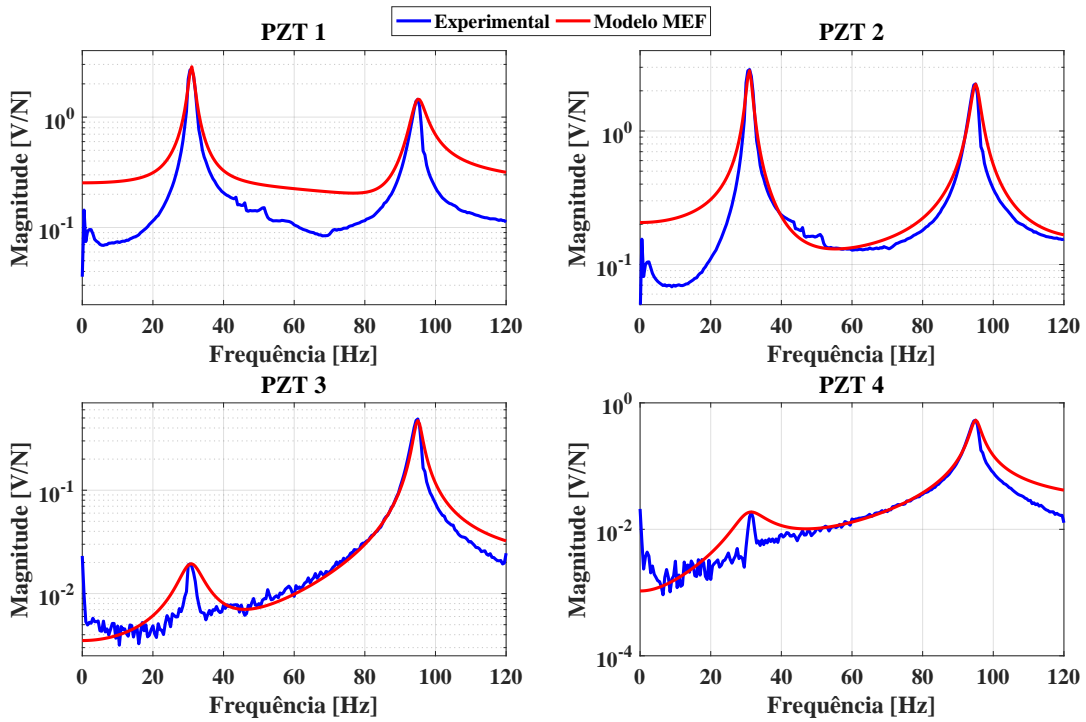


Fonte: elaborado pelo autor (2025)

Com a obtenção das FRFs experimentais, as FRFs do modelo de elementos finitos foram ajustadas alterando alguns parâmetros de rigidez do engaste e de amortecimento estrutural. Na Figura 12, é mostrada a comparação entre as FRFs experimentais e do modelo MEF com o primeiro ajuste de amortecimento. A comparação entre as FRFs numéricas e experimentais indica que os ajustes adotados reproduzem a posição e a magnitude dos

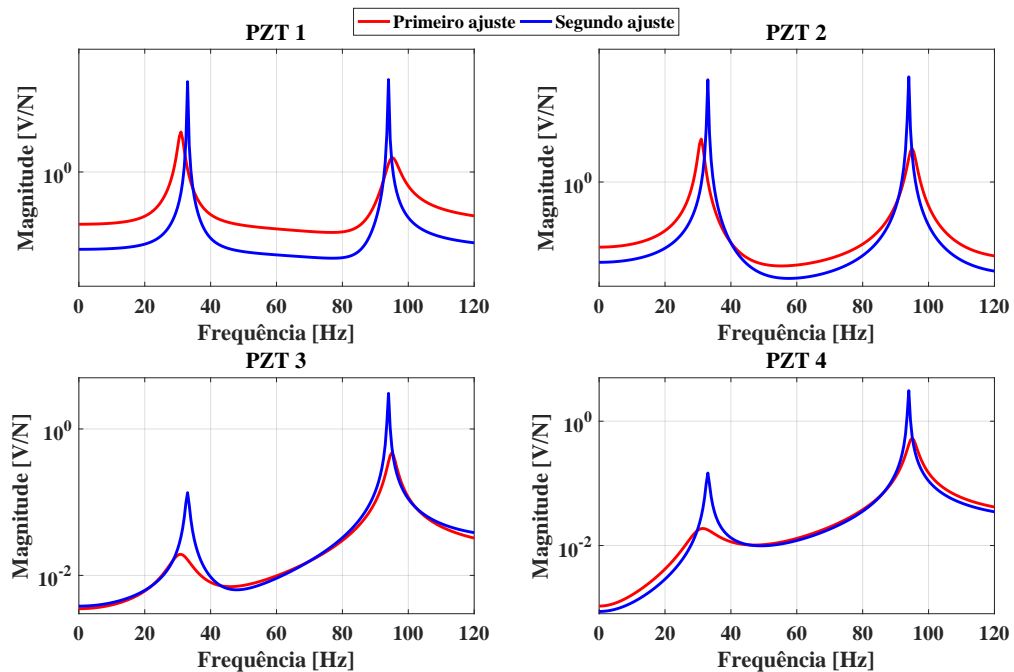
picos observados nas respostas medidas. A Figura 13 apresenta os resultados para ambos os ajustes.

Figura 12 – Comparação FRF experimental e modelo MEF



Fonte: elaborado pelo autor (2025)

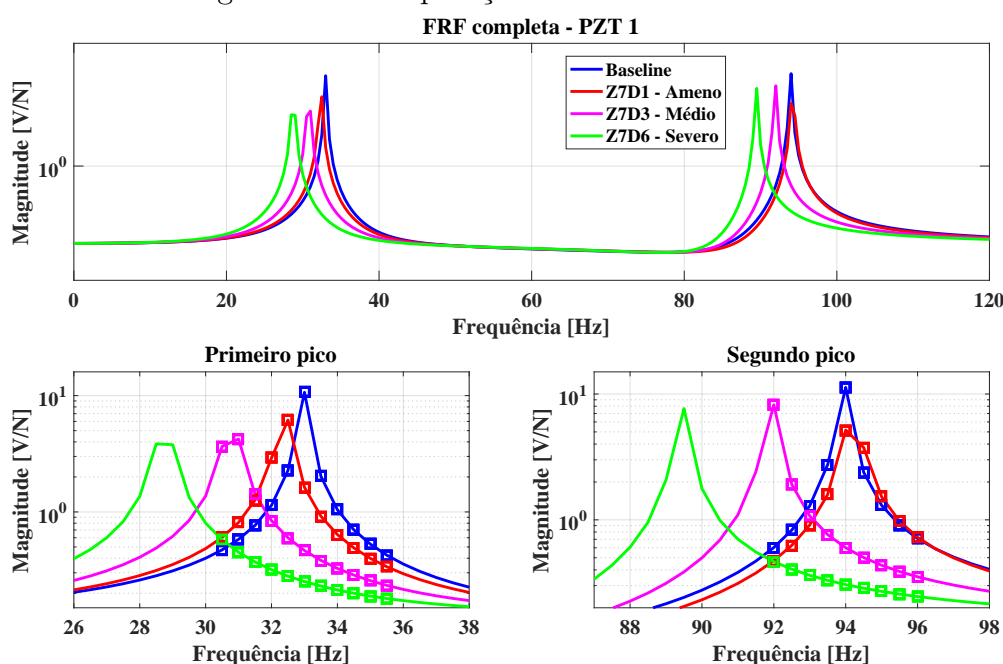
Figura 13 – Comparação FRFs MEF — primeiro e segundo ajuste



Fonte: elaborado pelo autor (2025)

A partir do segundo ajuste do modelo foram geradas as novas simulações da placa com os danos localizados nas zonas definidas na seção anterior. Na Figura 14 são apresentadas as FRFs do modelo comparando a *baseline* coletadas pelo PZT 1 com três intensidades de danos, todos localizados na zona 7. No primeiro pico de ressonância (entre 26 e 38 Hz), observa-se um deslocamento das frequências para valores menores conforme o dano se intensifica. Já no segundo pico (entre 88 e 98 Hz), também ocorre a redução da frequência de ressonância à medida que o dano aumenta. Em relação à magnitude, nota-se que houve uma tendência de diminuição conforme o aumento do dano — mais acentuada para o primeiro pico em comparação ao segundo.

Figura 14 – Comparação FRFs MEF — PZT 1

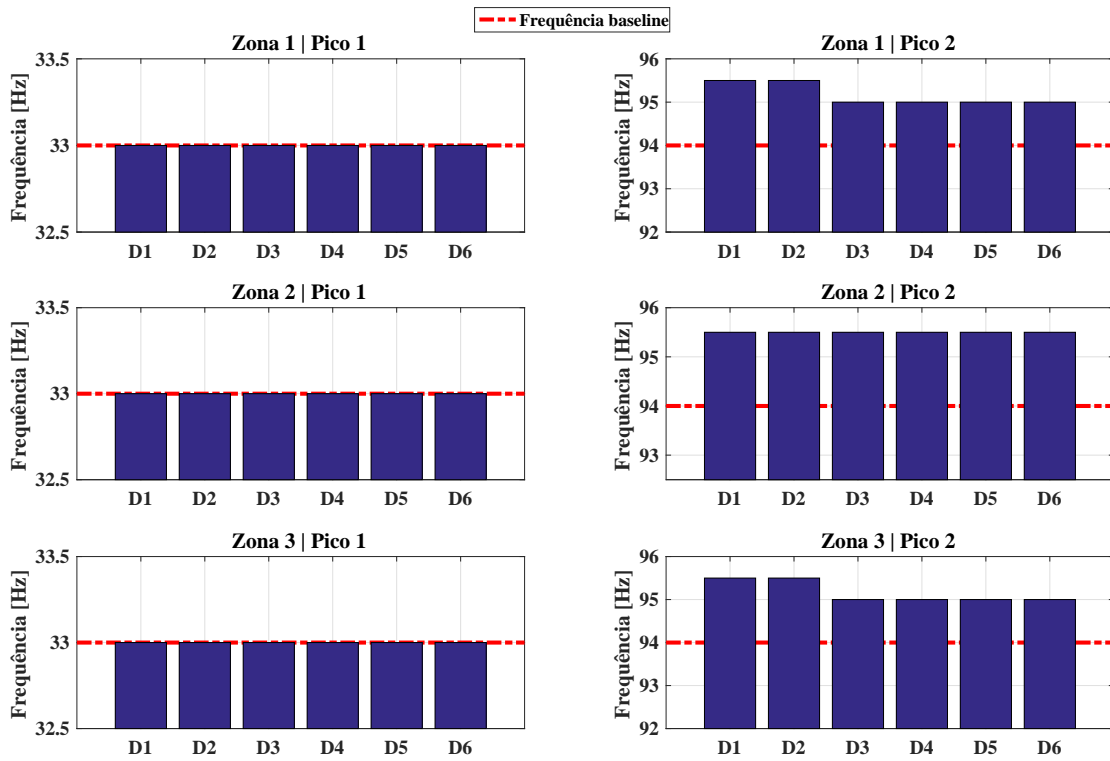


Fonte: elaborado pelo autor (2025)

Na Figura 15 são apresentadas as frequências de ressonância para as zonas 1 a 3, comparando a influência de cada intensidade de dano em cada pico. Observa-se que as frequências associadas ao primeiro pico situam-se próximas de 33 Hz, enquanto as correspondentes ao segundo pico permanecem em torno de 94 Hz. À medida que a intensidade do dano aumenta, nota-se uma redução gradual nos valores de frequência no segundo pico, especialmente perceptível a partir da condição D3.

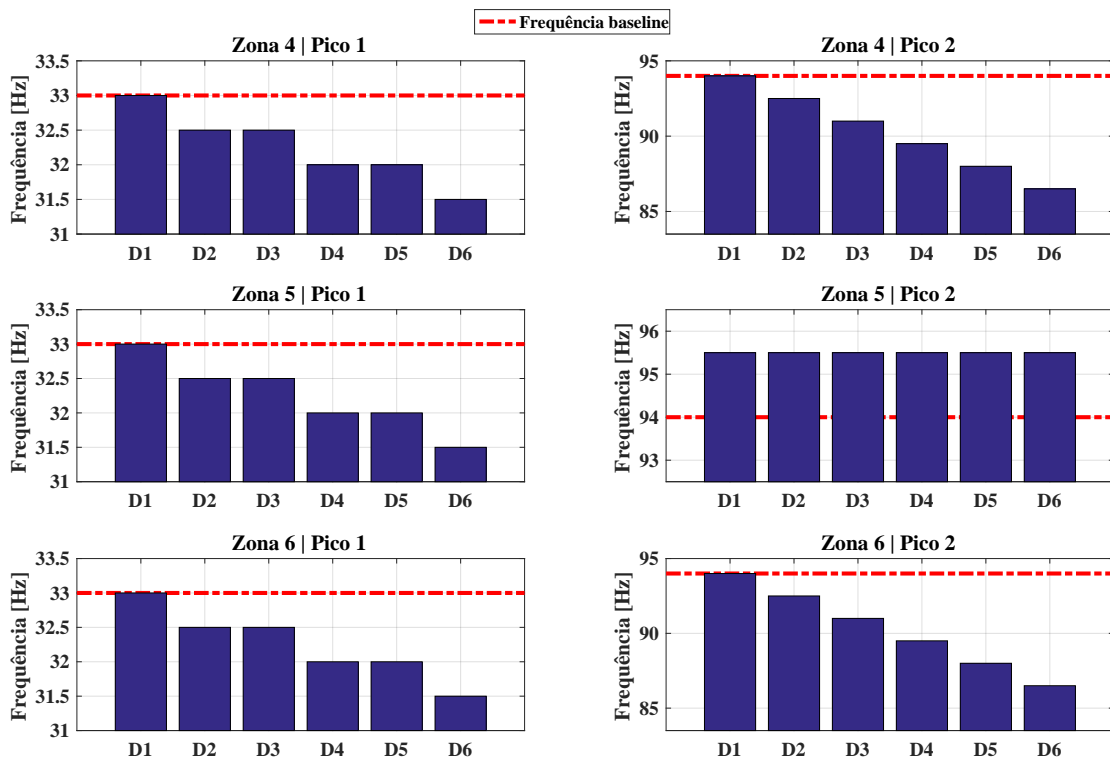
Dando continuidade à análise, na Figura 16 são apresentados os resultados obtidos para as Zonas 4 a 6, nas quais se observam frequências iniciais ligeiramente inferiores às das zonas anteriores. Os valores do primeiro pico concentram-se entre 31 e 33 Hz, enquanto os do segundo pico variam de aproximadamente 85 a 95 Hz. Verifica-se, também, uma tendência consistente de diminuição das frequências com o aumento do nível de dano, comportamento que se mantém em ambas as faixas analisadas.

Figura 15 – Comparação das frequências de ressonância — Zonas 1 a 3



Fonte: elaborado pelo autor (2025)


Figura 16 – Comparação das frequências de ressonância — Zonas 4 a 6



Fonte: elaborado pelo autor (2025)

Por fim, na Figura 17 são apresentados os resultados obtidos para as Zonas 7 a 9, nas quais se observa a faixa mais ampla de variação entre os níveis de dano. As frequências do primeiro pico concentram-se entre 28 e 34 Hz, enquanto as do segundo pico variam de 88 a 96 Hz. As reduções de frequência são mais pronunciadas nas condições de dano severo (D5 e D6), sendo essa tendência mais evidente no primeiro pico de ressonância.

Figura 17 – Comparação das frequências de ressonância — Zonas 7 a 9



Fonte: elaborado pelo autor (2025)

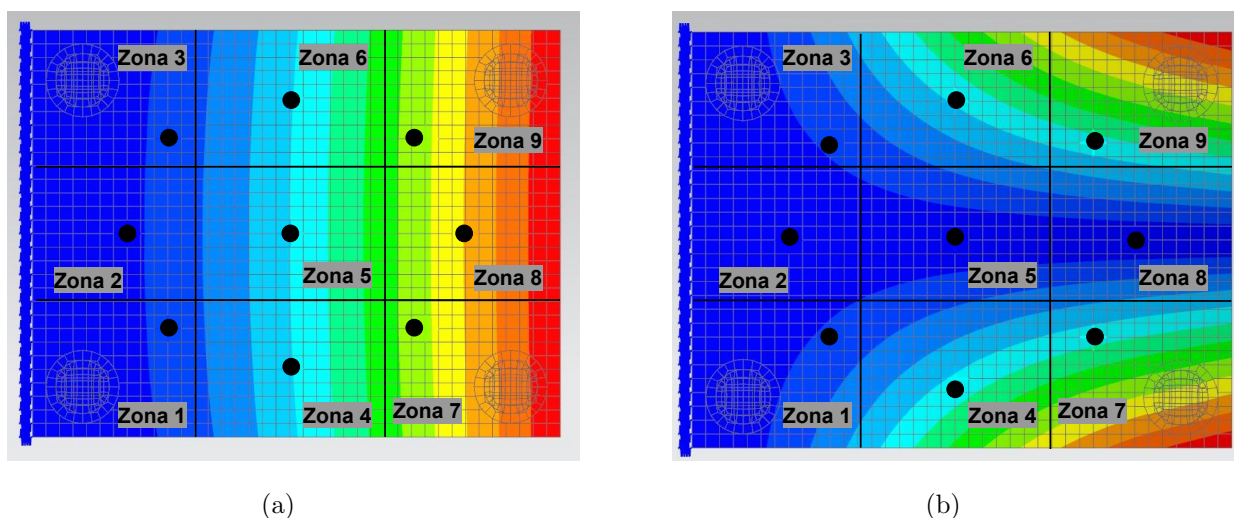
Observa-se que as Zonas 2, 5 e 8 não apresentaram variações significativas nas frequências correspondentes ao segundo pico de ressonância. Esse comportamento está associado ao fato de que o segundo modo de vibração da placa possui caráter predominantemente torsional, resultando em amplitudes modais próximas de zero nas regiões onde os danos foram aplicados. Dessa forma, a adição de massa nessas zonas exerce influência desprezível sobre a resposta modal, mantendo praticamente inalterada a frequência de ressonância correspondente a esse modo.

De forma geral, nota-se que a sensibilidade à variação de frequência difere entre as zonas. Algumas regiões — especialmente aquelas localizadas próximas às posições de maior amplitude modal — apresentaram reduções mais acentuadas das frequências em comparação com zonas menos solicitadas dinamicamente. Esse resultado evidencia a dependência espacial da resposta da estrutura em relação à localização do dano.

As formas modais correspondentes aos dois primeiros modos analisados são apresentadas na Figura 18. Observa-se que, dependendo da zona, ocorrem diferentes padrões

de deformação da placa, de modo que a adição de massa altera tanto a rigidez local quanto a inércia localizadamente. Além disso, dependendo da posição do dano, há predominância de um desses efeitos, o que faz com que o pico de ressonância aumente ou diminua em relação ao *baseline*.

Figura 18 – Confronto da localização das zonas com os deslocamentos para o (a) primeiro e (b) segundo modo de vibrar da placa



Fonte: elaborado pelo autor (2025)

4.2 Desempenho dos algoritmos de classificação

Antes de apresentar os gráficos consolidados de desempenho, são incluídas duas matrizes de confusão visando ilustrar de maneira explícita como os critérios de acurácia, precisão, revocação e *F1-Score* são derivados. Na Tabela 12, é apresentado um exemplo referente à classificação da severidade do dano, enquanto na Tabela 13, é mostrado a matriz correspondente à tarefa de localização. Essas matrizes permitem visualizar a distribuição dos acertos e erros entre as classes e auxiliam na interpretação dos resultados discutidos nas seções seguintes.

Tabela 12 – Matriz de confusão - Rede Neural - *database VIII*
Predita

		Ameno	Médio	Severo	Σ
Real	Ameno	22.2%	11.1%	66.7%	18
	Médio	16.7%	27.8%	55.6%	18
	Severo	27.8%	33.3%	38.9%	18
	Σ	12	13	29	54

Fonte: elaborado pelo autor (2025)

Tabela 13 – Matriz de confusão - Rede Neural - *database I*
Predita

		Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Σ
Real	Z1	33,3%	33,3%	33,3%	0%	0%	0%	0%	0%	0%	6
	Z2	0%	100%	0%	0%	0%	0%	0%	0%	0%	6
	Z3	33,3%	33,3%	33,3%	0%	0%	0%	0%	0%	0%	6
	Z4	16,7%	0%	16,7%	0%	0%	33,3%	16,7%	0%	16,7%	6
	Z5	0%	0%	0%	0%	66,7%	0%	0%	16,7%	16,7%	6
	Z6	0%	0%	16,7%	16,7%	0%	33,3%	16,7%	0%	16,7%	6
	Z7	0%	0%	16,7%	0%	0%	0%	16,7%	66,7%	0%	6
	Z8	0%	0%	0%	33,3%	0%	0%	0%	66,7%	0%	6
	Z9	16,7%	0%	0%	16,7%	0%	0%	16,7%	0%	50,0%	6
Σ	9	10	4	4	6	4	4	5	8	54	

Fonte: elaborado pelo autor (2025)


Na Figura 19, é apresentado o desempenho dos modelos de classificação na identificação da zona de dano, considerando os *databases I a IV*, construídos a partir das magnitudes das FRFs nas regiões de ressonância de cada transdutor PZT. Os algoritmos avaliados — Rede Neural (NN), Máquina de Vetores de Suporte (SVM) e Floresta Aleatória (RF) — foram analisados segundo quatro métricas de desempenho: Acurácia, *F1-score*, Precisão e Revocação, nas etapas de treinamento e validação.

Durante o treinamento, os modelos apresentaram resultados entre aproximadamente 45% e 70% em todas as métricas e bases de dados. O *database IV* destacou-se com desempenho ligeiramente superior, apresentando valores acima de 60% em todos os critérios, enquanto o *database I* obteve os menores desempenhos, ultrapassando os 60% somente em alguns casos. Entre os algoritmos, o SVM apresentou os melhores desempenhos médios, seguido pela RF e, por último, pela NN. Observa-se também que, com exceção do modelo RF aplicado ao *database IV* — que obteve Revocação e *F1-score* ligeiramente superiores à Acurácia e Precisão —, as demais combinações de modelos e bases apresentaram valores próximos entre as métricas, indicando consistência interna durante o treinamento.

Entretanto, na etapa de validação, apresentada na Figura 20, observou-se uma redução significativa nos valores das métricas. A acurácia global variou entre aproximadamente 30% e 60%, com os melhores resultados observados no *database III*, em que a NN e a RF atingiram cerca de 55% e 60%, respectivamente, enquanto o SVM apresentou cerca de 30%. A Rede Neural mostrou menor variação entre os *databases*, sugerindo maior estabilidade, enquanto o SVM e a RF apresentaram diferenças mais expressivas, especialmente no *database IV*, cujos valores ficaram abaixo de 30%.


O comportamento da Revocação foi semelhante ao da Acurácia, indicando que os modelos mantiveram taxas proporcionais de acertos na identificação correta das zonas de dano. Já a Precisão apresentou valores mais baixos, especialmente nos *databases III e IV*, com reduções em torno de 15% em relação à Acurácia. Essa diferença sugere que, embora

Figura 19 – Desempenho de treinamento *databases* I a IV - Zona



Fonte: elaborado pelo autor (2025)

Figura 20 – Desempenho de validação *databases* I a IV - Zona



Fonte: elaborado pelo autor (2025)

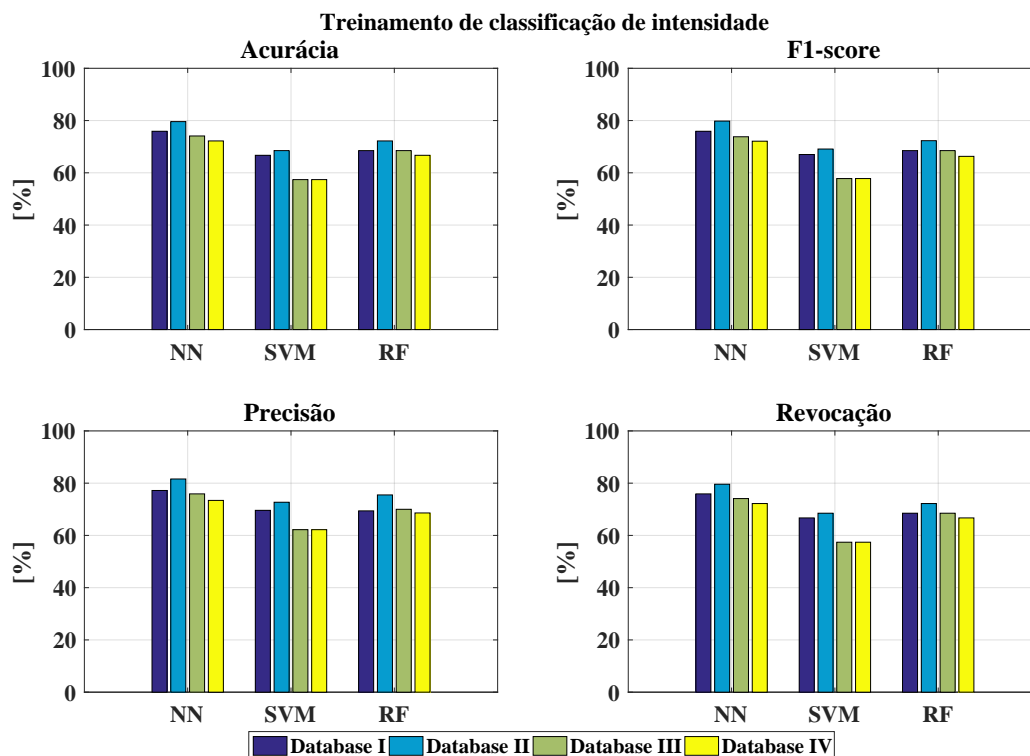
os modelos identifiquem a maioria das zonas corretas (alta revocação), eles também apresentam maior incidência de falsos positivos (baixa precisão), ou seja, classificam incorretamente zonas como danificadas quando não estão. Por outro lado, a revocação elevada implica que o modelo é mais sensível à presença de dano, o que pode ser vantajoso em contextos de monitoramento estrutural, onde é preferível detectar um possível dano (mesmo com alguns falsos alarmes) do que deixar de identificá-lo.

De modo geral, a Rede Neural apresentou o comportamento mais equilibrado entre as métricas, com pequena discrepância entre precisão e revocação; a RF mostrou-se mais precisa, porém menos abrangente (indicando menor sensibilidade); e o SVM demonstrou maior dependência das características da base utilizada, com variações mais acentuadas entre os resultados.

A Figura 21 apresenta o desempenho dos modelos de classificação na determinação da intensidade do dano, utilizando as *databases* I a IV formadas a partir das magnitudes das FRFs nas regiões de ressonância.

De modo geral, as métricas de desempenho mantiveram comportamento semelhante ao observado na identificação da zona de dano, porém com valores ligeiramente mais altos durante o treinamento — especialmente para o SVM e a Floresta Aleatória, que alcançaram acurácias próximas de 70%.

Figura 21 – Desempenho de treinamento *databases* I a IV — Intensidade

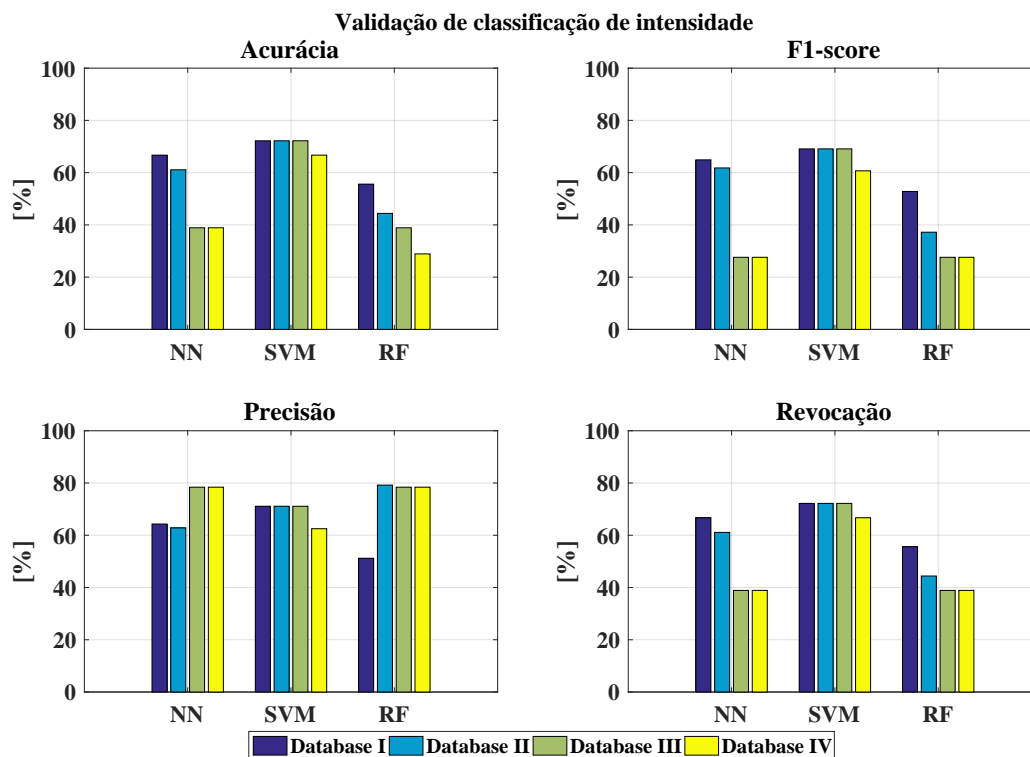


Fonte: elaborado pelo autor (2025)

Na etapa de validação, apresentada na Figura 22, os resultados variaram entre 40% e 80%, evidenciando que os modelos conservaram uma boa capacidade de generalização,

ainda que com diferenças mais marcantes entre as métricas. Entre os sensores, a base I é a que atingiu as melhores médias entre as métricas e modelos, enquanto a IV apresentou maiores oscilações.

Figura 22 – Desempenho de validação *databases* I a IV — Intensidade



Fonte: elaborado pelo autor (2025)

Observa-se, contudo, que nos *databases* III e IV, os modelos de Rede Neural e Floresta Aleatória exibiram precisão significativamente superior à revocação, atingindo valores próximos de 80% e 40%, respectivamente. Esse comportamento indica que, embora os modelos tenham sido eficazes em classificar corretamente as instâncias identificadas como danificadas (alta precisão), muitos casos de dano não foram detectados (baixa revocação), sugerindo uma tendência conservadora na predição.

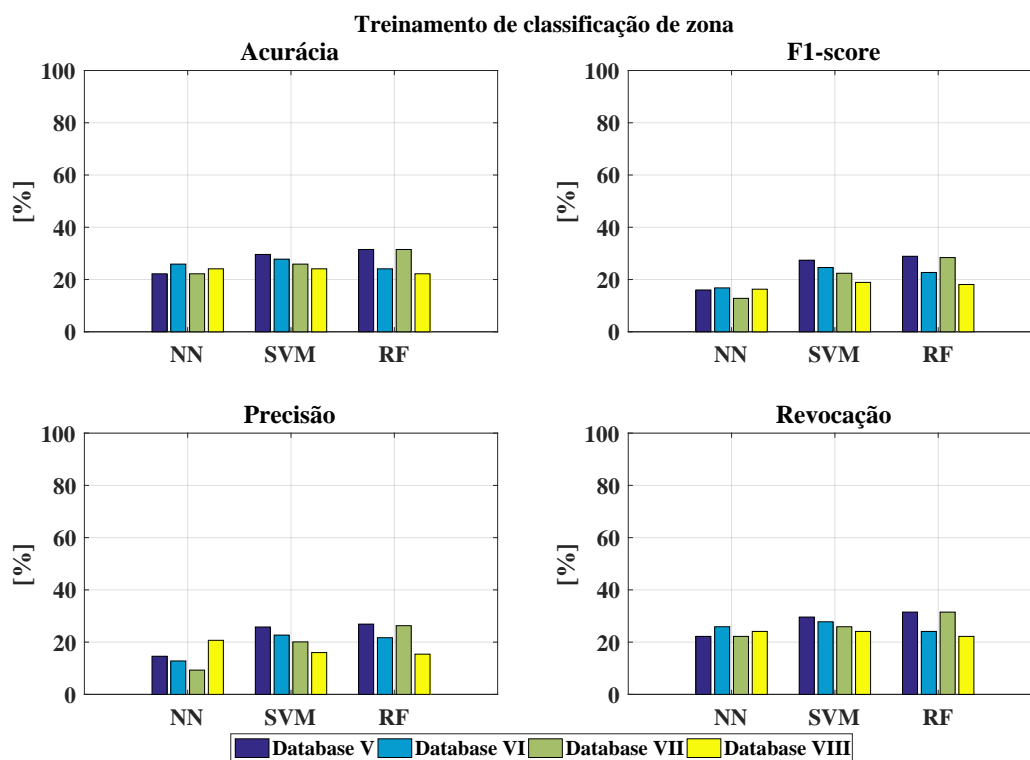
Por outro lado, o SVM apresentou maior consistência entre as métricas, mantendo tanto precisão quanto revocação em torno de 60–70%, refletindo um equilíbrio mais adequado entre sensibilidade e especificidade.

De forma geral, a Rede Neural mostrou desempenho superior em treinamento, enquanto o SVM apresentou superioridade e mais equilíbrio em validação. O *database* I obteve os melhores desempenhos médios.

Na Figura 23, é apresentado o desempenho durante treinamento dos modelos de classificação na identificação da zona de dano, considerando agora as *databases* V a VIII. Essas bases foram construídas a partir do índice RMSD calculado nas regiões de ressonância, permitindo avaliar a influência desse parâmetro agregado no desempenho dos algoritmos de ML.

Durante o treinamento, observou-se que os resultados gerais foram inferiores aos obtidos para as *databases* I a IV. As acurácias e demais métricas oscilaram entre 22% e 35%, com pequenas variações entre os algoritmos. Na maioria dos casos, os valores das métricas permaneceram próximos entre si, indicando um comportamento consistente dos modelos durante o aprendizado. A Floresta Aleatória apresentou desempenho ligeiramente superior aos demais algoritmos, alcançando os maiores valores médios em todas as métricas de treino.

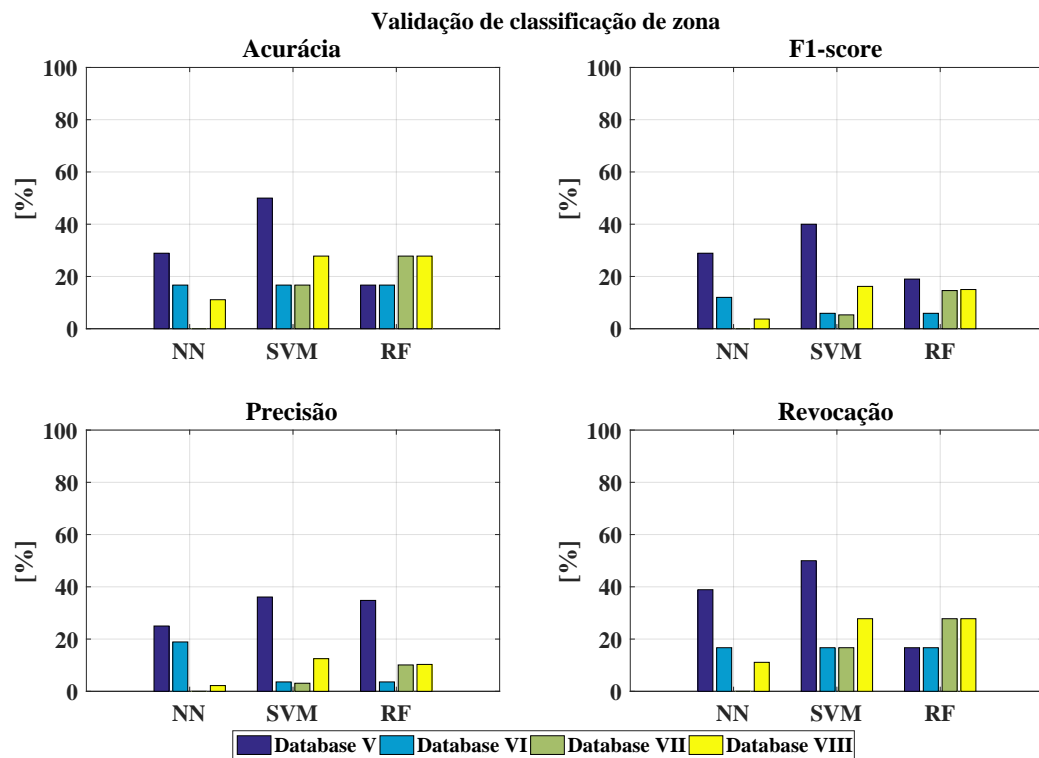
Figura 23 – Desempenho de treinamento *databases* V a VIII — Zona



Fonte: elaborado pelo autor (2025)

Na fase de validação, apresentada na Figura 24, os desempenhos apresentaram queda acentuada em relação ao treinamento, com acurácias variando predominantemente entre 15% e 30%. O *database* V destacou-se expressivamente, com valores mais elevados — entre 30% e 50% — em comparação com os demais conjuntos de dados. A Rede Neural apresentou o pior resultado isolado, atingindo desempenho nulo quando aplicada ao *database* VII. A Floresta Aleatória, por outro lado, manteve resultados mais estáveis entre as diferentes bases, evidenciando maior robustez frente às variações de entrada.

Em algumas combinações, entretanto, observou-se uma ligeira vantagem da Revocação sobre a Precisão, especialmente nos modelos de Rede Neural. De maneira geral, a Revocação apresentou valores entre 10 e 15 pontos percentuais superiores à Precisão, indicando que os algoritmos conseguiram identificar a maioria das zonas realmente danificadas, mas ao custo de um número mais elevado de falsos positivos. Em outras palavras, os

Figura 24 – Desempenho de validação *databases* V a VIII — Zona

Fonte: elaborado pelo autor (2025)

modelos demonstraram-se mais sensíveis à presença de dano — classificando corretamente a maioria dos casos reais — porém com menor capacidade de distinguir as zonas intactas.

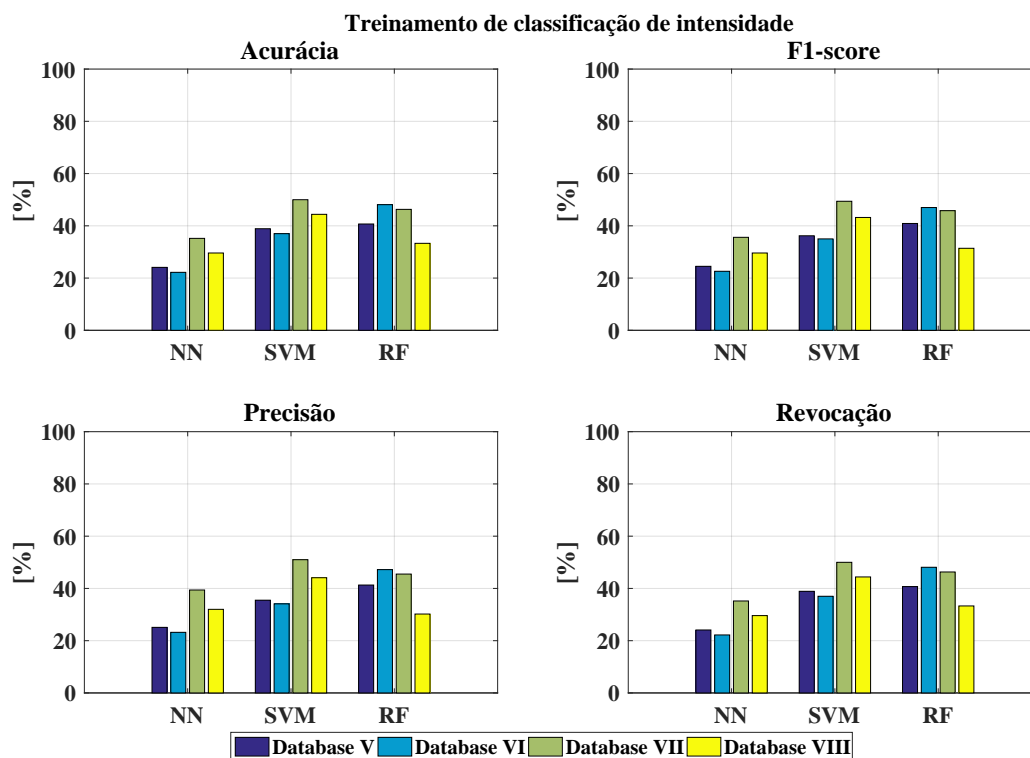
De modo geral, a Floresta Aleatória apresentou o desempenho mais equilibrado e consistente entre as métricas e os diferentes *databases*, enquanto a Rede Neural mostrou-se mais instável e sensível às variações dos dados de entrada. O *database* V demonstrou ser o mais informativo para a tarefa de localização de dano, indicando que o índice RMSD calculado nessa configuração contém características mais discriminantes para os modelos de classificação. Já o SVM manteve resultados intermediários, apresentando boa coerência entre as métricas, mas sem alcançar o mesmo nível de desempenho obtido pela Floresta Aleatória.

A Figura 25 apresenta o desempenho durante treinamento dos modelos de classificação na determinação da *intensidade do dano*, considerando as *databases* V a VIII formadas a partir do índice RMSD nas regiões de ressonância.

Durante o treinamento, observou-se que as métricas apresentaram desempenho consideravelmente superior em relação à etapa de classificação da zona. As acurácias variaram entre aproximadamente 22% e 50%, com destaque para o SVM, que obteve os melhores resultados médios entre os modelos avaliados, seguido pela Floresta Aleatória e, por fim, pela Rede Neural. De modo geral, os valores de *F1-score*, Precisão e Revocação permaneceram próximos à acurácia, indicando uma boa consistência interna entre as métricas e sugerindo que os algoritmos conseguiram aprender padrões relevantes a partir

do índice RMSD.

Figura 25 – Desempenho de treinamento *databases* V a VIII — Intensidade




Fonte: elaborado pelo autor (2025)

Na fase de validação, apresentada na Figura 26, o desempenho superou o obtido durante o treinamento, com acurácias variando de 40% a 70%. Destaca-se o SVM aplicado ao *database* VI, que apresentou os melhores resultados entre todos os casos analisados. Os demais modelos também apresentaram comportamento semelhante entre si, sem grandes discrepâncias entre as bases, demonstrando boa capacidade de generalização e estabilidade das classificações.

No que se refere à relação entre Precisão e Revocação na etapa de validação, observou-se um comportamento inverso ao verificado nas análises anteriores: a Precisão superou a Revocação em praticamente todos os modelos, sendo essa diferença mais pronunciada para a Rede Neural e o SVM. Nesses casos, a Precisão ultrapassou 80%, enquanto a Revocação permaneceu abaixo de 70%. Esse resultado indica que, quando os modelos classificam uma amostra como pertencente a determinado nível de dano, essa predição tende a estar correta (alta precisão); entretanto, parte dos casos de dano existentes não foi identificada (baixa revocação). Em outras palavras, os algoritmos mostraram-se mais criteriosos e conservadores em suas previsões — privilegiando a exatidão das classificações confirmadas, mas reduzindo a sensibilidade à detecção de todos os danos presentes.

De maneira geral, o SVM destacou-se como o modelo com melhor desempenho médio entre as métricas e bases analisadas, apresentando tanto alta acurácia quanto boa estabilidade. A Floresta Aleatória também apresentou resultados consistentes, embora

Figura 26 – Desempenho de validação *databases* V a VIII — Intensidade

Fonte: elaborado pelo autor (2025)

ligeiramente inferiores ao SVM, enquanto a Rede Neural manteve desempenho mais irregular. Entre os conjuntos de dados, o *database* VI demonstrou ser o mais representativo para a classificação da intensidade do dano, indicando que o índice RMSD obtido nessa configuração captura de forma mais eficiente as variações associadas à severidade das perturbações estruturais.

De maneira geral, os resultados obtidos indicam que a tarefa de identificação da intensidade do dano apresentou desempenho superior à de localização da zona afetada. Esse comportamento sugere que as variações na severidade do dano impactam a resposta dinâmica de forma mais homogênea ao longo da estrutura, enquanto a posição do dano introduz alterações mais localizadas e, portanto, mais sutis e difíceis de capturar pelos modelos de aprendizado. Nesse contexto, o uso do índice RMSD mostrou-se particularmente eficiente para a classificação da intensidade, uma vez que esse parâmetro sintetiza o grau de diferença entre as FRFs sem considerar a direção ou o sentido das variações espectrais. Como o RMSD quantifica somente o afastamento global das curvas, ele tende a representar bem fenômenos associados à magnitude das alterações estruturais, mas não necessariamente à sua localização, justificando o desempenho inferior nas tarefas de identificação da zona de dano.

Entre os modelos avaliados, observou-se que a Floresta Aleatória e o SVM apresentaram desempenho mais consistente entre as diferentes *databases*, enquanto a Rede

Neural mostrou maior variação conforme o conjunto de dados utilizado. Essa diferença pode estar relacionada ao número de atributos de entrada, visto que a Rede Neural tende a se beneficiar de conjuntos mais ricos em informações, ao passo que os outros modelos mantêm maior estabilidade em bases menores ou mais condensadas, como as formadas pelo índice RMSD.

Em relação aos sensores, as bases I e II apresentaram os melhores resultados entre os conjuntos formados pelas magnitudes das FRFs, enquanto o *database V* destacou-se entre aqueles baseados no RMSD, confirmando a relevância dessas configurações para ambas as tarefas de classificação. Por fim, verificou-se que as diferenças entre Precisão e Revocação variaram conforme o tipo de problema analisado: para a intensidade, predominou maior Precisão, refletindo modelos mais conservadores e seletivos, enquanto para a localização, observou-se maior Revocação, indicando maior sensibilidade à detecção de dano. No contexto do monitoramento estrutural, essa diferença é relevante, pois, em aplicações práticas, priorizar a Revocação — isto é, reduzir a chance de não detectar um dano — pode ser mais desejável do que maximizar a Precisão.

5 CONSIDERAÇÕES FINAIS E CONCLUSÃO

O presente trabalho teve como objetivo investigar a aplicação de algoritmos de aprendizado de máquina na identificação de danos estruturais por meio da técnica de monitoramento baseada em vibrações, com ênfase na utilização de sensores piezoelétricos e na análise das funções de resposta em frequência (FRFs). A partir da FRF experimental obtida por testes com martelo de impacto e sensores piezoelétricos, ajustou-se um modelo de elementos finitos para representar o comportamento dinâmico da estrutura. O modelo apresentou resultados compatíveis com os dados experimentais.

Após a calibração do modelo, foram realizadas simulações para a obtenção de novas FRFs numéricas, considerando danos representados pela adição de massas pontuais. Seis valores distintos de massa foram utilizados para representar diferentes magnitudes de dano, os quais foram agrupados em três intensidades, sendo distribuídos em nove zonas da estrutura. As respostas obtidas para cada combinação de intensidade e localização do dano permitiram a construção de oito bases de dados, utilizadas para treinar e testar algoritmos de classificação.

A análise das FRFs danificadas em relação à *baseline* indicou que o dano afeta os modos de vibração distintamente, com alterações específicas nos picos de ressonância. Verificou-se que a localização do dano influencia significativamente os padrões de deformação da placa, alterando localmente a rigidez e a massa. Dependendo da zona, um desses efeitos se sobressai, resultando em aumentos ou reduções na amplitude e frequência dos picos de ressonância. Além disso, a intensidade do dano também teve impacto direto, intensificando as alterações nas frequências e magnitudes das FRFs.

Com as bases geradas, foram implementados três modelos de classificação no *software* Orange Data Mining: uma Rede Neural (NN), uma Máquina de Vetores de Suporte (SVM) e uma Floresta Aleatória (RF). Os parâmetros de ambos os algoritmos foram mantidos constantes em todas as simulações, possibilitando a comparação direta de desempenho entre os modelos e entre os diferentes conjuntos de dados.

Os resultados obtidos demonstraram que a tarefa de identificação da intensidade do dano apresentou melhor desempenho global em comparação à de localização da zona afetada. Esse comportamento indica que a severidade do dano tende a alterar a resposta dinâmica da estrutura de maneira mais uniforme, enquanto a localização gera variações mais localizadas e, portanto, mais difíceis de serem capturadas pelos modelos. Nesse contexto, o índice RMSD mostrou-se especialmente eficiente para representar o grau de modificação das FRFs associadas à intensidade do dano, revelando-se um indicador promissor para aplicações de detecção e avaliação da severidade em estruturas monitoradas.

Entre os modelos analisados, observou-se que o SVM e a Floresta Aleatória apresentaram os desempenhos mais consistentes e equilibrados entre as métricas, enquanto a

Rede Neural mostrou maior sensibilidade ao número de atributos de entrada. Essa característica sugere que seu uso é mais vantajoso em bases de dados com maior dimensionalidade, onde há maior disponibilidade de informações para o aprendizado. Além disso, verificou-se que os sensores associados aos *databases* I e II obtiveram os melhores resultados entre as análises com FRFs, ao passo que o *database* V destacou-se entre as análises baseadas no RMSD, evidenciando que determinadas posições dos transdutores são mais sensíveis às perturbações estruturais. Em contrapartida, a bases de dados derivadas dos sensores PZT 3 e 4 apresentaram desempenhos inferiores na etapa de validação, possivelmente devido à menor exposição à flexão no primeiro modo de ressonância e à maior influência do ruído experimental.

A análise das métricas de desempenho também evidenciou comportamentos distintos conforme o tipo de classificação. Para a identificação da zona, prevaleceu uma maior Revocação, o que indica que os modelos foram mais sensíveis à presença de dano, ainda que com maior número de falsos positivos — característica desejável em aplicações de monitoramento, nas quais a falha em detectar um dano é mais crítica que um alarme indevido. Já na classificação da intensidade, observou-se maior Precisão, refletindo um comportamento mais seletivo e conservador, no qual as predições positivas tendem a ser mais confiáveis.

De forma geral, os resultados obtidos confirmam o potencial do uso combinado da técnica SHM baseada em vibrações com algoritmos de aprendizado de máquina para identificação de danos estruturais. Os achados reforçam a importância da escolha adequada das variáveis de entrada e dos modelos de classificação em função do tipo de problema a ser tratado. Além disso, os resultados experimentais validaram a aplicabilidade dos métodos desenvolvidos, evidenciando a viabilidade dessa abordagem para sistemas reais de monitoramento e prognóstico estrutural. Esses avanços estabelecem uma base sólida para o desenvolvimento futuro de metodologias mais robustas e precisas de detecção e previsão de danos, ampliando o potencial de aplicação de técnicas inteligentes no contexto do SHM.

REFERÊNCIAS

- ABHINAV, P.; OJHA, S.; AHMAD, A.; HABIB, A. Wavelet scattering transformation for sub-surface damage detection and localization in pzt sensor. **Ultrasonics**, Elsevier B.V., v. 157, p. 107793, 2026. Disponível em: <<https://doi.org/10.1016/j.ultras.2025.107793>>.
- BAO, Y.; LI, H. Machine learning paradigm for structural health monitoring. **Structural Health Monitoring**, p. 1353–1372, 2021.
- BAO, Y. et al. Recent advances in structural health diagnosis: a machine learning perspective. **Advances in Bridge Engineering**, v. 6, n. 7, p. 1–28, 2025. Disponível em: <<https://doi.org/10.1186/s43251-024-00155-z>>.
- DIAO, Y. et al. Structural damage identification based on the transmissibility function and support vector machine. **Shock and Vibration**, v. 2018, p. ID 4892428, 2018.
- FANG, Y. et al. Substructure damage identification based on sensitivity of power spectral density. **Journal of Sound and Vibration**, v. 545, p. 117451, 2023.
- FRANCO, V. R. **Monitoramento da integridade em estruturas aeronáuticas**. Dissertação (Mestrado) — Universidade Estadual Paulista, Faculdade de Engenharia de Iha Solteira, São Paulo, 2009.
- FREITAS, E. S. de; BAPTISTA, F. G. Experimental analysis of the feasibility of low-cost piezoelectric diaphragms in impedance-based shm applications. **Sensors and Actuators A: Physical**, Elsevier, Amsterdam, Netherlands, v. 238, p. 220–228, 2016. Disponível em: <<https://doi.org/10.1016/j.sna.2015.11.031>>.
- JAMSHED, A.; MISHRA, A.; KHATTER, H.; KUMAR, R. A novel enhanced digital image correlation framework for structural health monitoring of aircraft. **Measurement**, Elsevier Ltd., v. 258, p. 119264, 2026. Disponível em: <<https://doi.org/10.1016/j.measurement.2025.119264>>.
- KOT, P. et al. Recent advancements in non-destructive testing techniques for structural health monitoring. **Applied Sciences**, v. 229, p. 1–28, 2021.
- Lopes Jr, V.; PARK, G.; CUDNEY, H. H.; INMAN, D. J. Impedance-based structural health monitoring with artificial neural network. **Journal of Intelligent Material Systems and Structures**, v. 11, n. 3, p. 206–214, 2000.
- MAHDI, S. Q.; GHARGHAN, S. K.; MUTLAG, A. H. A novel anomaly detection approach for structural health monitoring using multiple linear regression technique. **Journal of Building Pathology and Rehabilitation**, Springer Nature Switzerland AG, v. 11, n. 51, 2026. Disponível em: <<https://doi.org/10.1007/s41024-025-00726-1>>.
- MALEKLOO, A.; OZER, E.; ALHAMAYDEH, M.; GIROLAMI, M. Machine learning and structural health monitoring overview with emerging technology and highdimensional data source highlights. **Structural Health Monitoring**, p. 1906–1955, 2022.
- MCCONNELL, K.; VAROTO, P. **Vibration Testing: Theory and Practice**. [S.l.]: Wiley, 2008.

RAO, S. S. **Vibrações Mecânicas**. 4. ed. São Paulo: Pearson, 2008. E-book. Disponível em: <<https://plataforma.bvirtual.com.br>>. Acesso em: 28 ago. 2024.

RYTTER, A. **Vibration Based Inspection of Civil Engineering Structures**. Tese (Doutorado) — Aalborg University, Aalborg, Denmark, 1993.

THAI, H. T. Machine learning for structural engineering: A state-of-the-art review. **Structures**, v. 38, p. 448–491, 2022.

TOH, G.; PARK, J. Review of vibration-based structural health monitoring using deep learning. **Applied Sciences**, v. 10, p. 1–24, 2020.

VIEIRA, B. Z.; FRANCO, V.; MALAVOLTA, A. T. Investigação de danos em uma viga engastada utilizando a técnica SHM baseada em vibrações e modelo de elementos finitos. In: **Anais do XXX Congresso Nacional de Estudantes de Engenharia Mecânica (CREEM 2024)**. São Paulo: ABCM, 2024. ISSN 2237-1168.

VIEIRA, B. Z.; FRANCO, V.; MALAVOLTA, A. T. Investigação de danos em uma placa engastada utilizando a técnica SHM baseada em vibrações e modelo de elementos finitos. In: **Anais do XXXI Congresso Nacional de Estudantes de Engenharia Mecânica (CREEM 2025)**. São Paulo, SP, Brasil: ABCM, 2025. Disponível em: <<https://doi.org/10.26678/ABCM.CREEM2025.CRE2025-0050>>.

VIEIRA, B. Z.; MALAVOLTA, A. T.; FRANCO, V. R.; ARAUJO, L. A. O. Machine learning-based SHM for damage detection in clamped metallic beams using frequency response functions. In: **Anais do 28^o Congresso Internacional de Engenharia Mecânica (COBEM 2025)**. Curitiba, Brasil: ABCM, 2025.

WORDEN, K.; DULIEU-BARTON, J. M. An overview of intelligent fault detection in systems and structures. **Structural Health Monitoring**, SAGE Publications, v. 3, n. 1, p. 85–98, 2004.

YANG, Y.; ZHANG, Y.; TAN, X. Review on vibration-based structural health monitoring techniques and technical codes. **Symmetry**, v. 13, p. 1–18, 2021.

Apêndices

APÊNDICE A – Bases de dados completas

As bases de dados completas utilizadas nas análises deste Trabalho de Conclusão de Curso encontram-se disponibilizadas em uma pasta no Google Drive. Os arquivos incluem todas as tabelas originais, planilhas auxiliares e dados complementares que, devido ao seu tamanho, não puderam ser inseridos integralmente neste documento.

O conteúdo pode ser acessado pelo seguinte link: <<https://drive.google.com/drive/folders/16gFiE6DUIvvffTEZeUHyifiBHj1mzUXY?usp=sharing>>