

UNIVERSIDADE FEDERAL DE SÃO CARLOS – UFSCAR
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA – CCET
DEPARTAMENTO DE ENGENHARIA MECÂNICA – DEMEC

RODRIGO JUN HAGIHARA

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL A
PARTIR DE SENSORIAMENTO DE BAIXO-CUSTO:
INVESTIGAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL PARA CLASSIFICAÇÃO DE DANOS
ESTRUTURAIS**



SÃO CARLOS
2023

RODRIGO JUN HAGIHARA

**MONITORAMENTO DA INTEGRIDADE ESTRUTURAL A PARTIR DE
SENSORIAMENTO DE BAIXO-CUSTO: INVESTIGAÇÃO DE TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE DANOS ESTRUTURAIIS**

Trabalho de conclusão de curso apresentada ao Curso de Graduação em Engenharia Mecânica da Universidade Federal de São Carlos, para obtenção do título de Bacharel em Engenharia Mecânica.

Orientador: Prof. Dr. Sidney Bruce Shiki

São Carlos

2023

*

Rodrigo Jun Hagihara

Monitoramento da integridade estrutural a partir de sensoriamento de baixo-custo: investigação de técnicas de inteligência artificial para classificação de danos estruturais/ Rodrigo Jun Hagihara. – São Carlos, 2023-

66p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Sidney Bruce Shiki

Trabalho de conclusão de curso – Universidade Federal de São Carlos – UFSCar
Centro de Ciências Exatas e de Tecnologia – CCET
Departamento de Engenharia Mecânica – DEMec, 2023.

Integridade estrutural. Detecção de danos. Sensoriamento. Baixo-custo. Inteligência artificial.

1. Integridade estrutural. 2. Detecção de danos. 3. Sensoriamento. 4. Baixo-custo. 5. Inteligência artificial. I. Prof. Dr. Sidney Bruce Shiki . II. Universidade Federal de São Carlos - UFSCar. III. Centro de Ciências Exatas e de Tecnologia - CCET. IV. Departamento de Engenharia Mecânica - DEMec. V. Monitoramento da integridade estrutural a partir de sensoriamento de baixo-custo: investigação de técnicas de inteligência artificial para classificação de danos estruturais.



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS

COORDENAÇÃO DO CURSO DE ENGENHARIA MECÂNICA - CCEMec/CCET

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 53/2023/CCEMec/CCET

Graduação: Defesa Pública de Trabalho de Conclusão de Curso

Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

RODRIGO JUN HAGIHARA

MONITORAMENTO DA INTEGRIDADE ESTRUTURAL A PARTIR DE SENSORIAMENTO DE BAIXO CUSTO: INVESTIGAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE DANOS ESTRUTURAIS

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 16 de novembro de 2023

ASSINATURAS E CIÊNCIAS

Cargo/Função	Nome Completo
Orientador	Sidney Bruce Shiki
Membro da Banca 1	Luis Antonio Oliveira Araujo
Membro da Banca 2	Adailton Gomes Pereira



Documento assinado eletronicamente por **Sidney Bruce Shiki, Docente**, em 16/11/2023, às 09:15, 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 **Luis Antonio Oliveira Araujo, Docente**, em 16/11/2023, às 09:15, 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 **1264116** e o código CRC **63AA28CB**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.041373/2023-73

SEI nº 1264116

Modelo de Documento: Grad: Defesa TCC: Folha Aprovação, versão de 02/Agosto/2019

Dedico este trabalho a: Deus, meus professores, minha família e meus amigos que estiveram ao meu lado, me apoiando e auxiliando em todos os momentos.

AGRADECIMENTOS

Primeiramente, gostaria de expressar meu agradecimento a quem sempre esteve me guiando e sustentando, independentemente de onde estivesse, e a quem devo toda honra e glória: Deus.

Expresso minha gratidão aos meus pais, Suely e Antonio, responsáveis pela minha educação desde que nasci e que nunca deixaram me faltar nada.

Agradeço ao Prof. Dr. Sidney Bruce Shiki, quem me orientou com excelência na Iniciação Científica, no TCC e sempre esteve disposto a ajudar com o que fosse necessário.

Deixo meus agradecimentos aos docentes com quem tive o privilégio de aprender ao longo de todo o período da graduação, certamente levarei suas lembranças e ensinamentos por toda a vida.

Um muito obrigado aos meus amigos Gabriel, Juan, Lucas e Rafael, amizades valiosas que me ensinaram o significado de trabalho em equipe realizado com afino e precisão.

Finalmente, deixo o meu agradecimento à minha namorada Débora, quem me acompanhou, motivou, apoiou e incentivou em todos os momentos.

*"Seja você quem for,
seja qual for a posição social que você tenha na vida,
a mais alta ou a mais baixa,
tenha sempre como meta
muita força, muita determinação
e sempre faça tudo com muito amor e com muita fé em Deus,
que um dia você chega lá.
De alguma maneira você chega lá."*

Ayrton Senna da Silva

RESUMO

Na engenharia, uma estrutura é concebida considerando-se sua possível falha devido aos danos que surgem com o decorrer do tempo. Nesse contexto, com o intuito de prolongar a vida útil dos componentes, evitar falhas e problemas operacionais, manutenções periódicas são realizadas. Diversos estudos são conduzidos sobre a manutenção baseada no monitoramento em tempo real do estado de uma estrutura, antecipando a detecção de danos. A elevada precisão e a constante dependência de recursos humanos para obtenção de parâmetros conclusivos torna o processo oneroso. Portanto, o maior obstáculo para o monitoramento está na diferenciação entre as estruturas danificadas e não-danificadas utilizando equipamentos de baixo-custo e algoritmos estatísticos de reconhecimento de padrões. No presente trabalho, foram empregadas técnicas de aprendizado supervisionado nas análises de sinais de vibração simulados e sinais vibratórios de uma estrutura para a correlação com diferentes tipos de danos. Utilizando *MATLAB*, acelerômetro ADXL335 e microcontrolador ESP-32 para monitorar o estado de uma estrutura simples de dois andares excitada por forças externas do tipo impacto, foi possível extrair as frequências naturais e coeficientes de amortecimento como atributos principais para a classificação da dimensão do dano associado. Ao final do estudo, verificou-se que os diferentes classificadores *Medium Gaussian SVM*, *Medium KNN*, *Medium Tree* e *Linear Discriminant* obtiveram acurácia superior a 85% para evidenciar as diferenças entre as condições de danos. Diferentes métricas de desempenho foram analisadas para comprovar suas acurácias, como: taxa de verdadeiros positivos, taxa de verdadeiros negativos, valores preditivos positivos, taxa de falso descobrimento, taxa de falsos positivos, curva *ROC* e *AUC*. Através da comparação entre os resultados obtidos com a estrutura e com os sinais simulados, avaliou-se a eficácia da inteligência artificial e a viabilidade de se utilizar uma instrumentação economicamente acessível para monitorar a integridade estrutural em pequenas estruturas. Apesar da necessidade de uma grande quantidade de dados para a obtenção de bons resultados, acredita-se que o modelo obtido possa contribuir para a geração de novos algoritmos capazes de classificar diferentes tipos de danos em estruturas.

Palavras-chave: Integridade estrutural. Detecção de danos. Sensoriamento. Baixo-custo. Inteligência artificial.

ABSTRACT

In engineering, a structure is designed considering its possible failure due to damage that appear over time. In this context, in order to extend the life of components, avoid failures and operational problems, periodic maintenance is performed. Several studies are conducted on maintenance based on real-time monitoring of the state of a structure, anticipating the detection of damage. The high accuracy and constant dependency on human resources to obtain conclusive parameters makes the process onerous. Therefore, the biggest obstacle for monitoring is in differentiating between damaged and undamaged structures using low-cost equipment and statistical pattern recognition algorithms. In the present work, supervised learning techniques were employed in the analysis of simulated vibration signals and vibration signals from a structure for correlation with different types of damage. Using MATLAB, accelerometer and microcontroller to monitor the state of a simple two-story structure excited by external forces caused by impact, it was possible to extract the natural frequencies and damping coefficients as main attributes for the classification of the associated damage dimension. At the end of the study, it was found that the different classifiers Medium Gaussian SVM, Medium KNN, Medium Tree and Linear Discriminant classifiers were found to be more than 85% accurate in to highlight the differences between the damage conditions. Different performance metrics were analyzed to prove their accuracies, such as: true positive rate, true negative rate, positive predictive values, false discovery rate, false positive rate, ROC curve and AUC. By comparing the results obtained with the structure and the simulated signals, the effectiveness of the artificial intelligence and the feasibility of using an affordable instrumentation to monitor structural integrity in small structures was evaluated. Despite the need for a large amount of data to obtain good results, it is believed that the model obtained can contribute to the generation of new algorithms capable of classifying different types of damage in structures.

Keywords: Structural integrity. Damage detection. Sensing. Low-cost. Artificial intelligence.

LISTA DE FIGURAS

Figura 1 – Processo de SHM baseado no paradigma de SPR.	15
Figura 2 – Esquemático para o monitoramento de danos.	15
Figura 3 – Exemplo de uma árvore de decisão.	22
Figura 4 – Representação geométrica da análise discriminante de duas classes.	23
Figura 5 – Hiperplano de separação.	25
Figura 6 – Possíveis hiperplanos de separação e hiperplanos de margens máximas.	25
Figura 7 – Margem flexível e impacto sobre o hiperplano de separação.	26
Figura 8 – Função <i>kernel</i> e suas implicações.	26
Figura 9 – Diagrama de Voronoi em classificadores KNN.	27
Figura 10 – Influência do parâmetro <i>K</i> sobre os resultados.	27
Figura 11 – Análise de parâmetros em uma matriz de confusão para uma classe B qualquer.	29
Figura 12 – Exemplo de curva ROC e sua AUC.	29
Figura 13 – Esquemático da estrutura projetada no <i>software NX Siemens</i>	32
Figura 14 – Primeiro modo de vibração obtido no <i>NX NASTRAN</i>	32
Figura 15 – Simulações realizadas para diferentes dimensões de danos.	33
Figura 16 – Estrutura para aquisição de dados finalizada.	34
Figura 17 – Posicionamento dos componentes para sensoriamento.	35
Figura 18 – Fluxograma <i>hardware-software</i>	36
Figura 19 – Marcação das dimensões de dano.	37
Figura 20 – Espessura do dano em diferentes cenários.	38
Figura 21 – Comprimentos considerados para os danos.	38
Figura 22 – Resposta temporal à uma excitação externa.	39
Figura 23 – Diferentes frequências naturais para cada cenário de dano.	41
Figura 24 – Variações nos valores de coeficientes de amortecimento para cada condição de dano.	41
Figura 25 – Representação gráfica de TVP ou sensibilidades.	43
Figura 26 – Representação gráfica de TVN ou especificidades.	44
Figura 27 – Representação gráfica de VPP ou precisões.	45
Figura 28 – Representação gráfica de TFD.	46
Figura 29 – Curvas ROC com 0 mm sendo a classe positiva	47
Figura 30 – Curvas ROC com 6 mm sendo a classe positiva	48
Figura 31 – Curvas ROC com 12 mm sendo a classe positiva	49
Figura 32 – Curvas ROC com 18 mm sendo a classe positiva	50

LISTA DE TABELAS

Tabela 1 – Dimensões de dano e frequências naturais simuladas.	34
Tabela 2 – Condições de dano e quantidade de amostras consideradas.	39
Tabela 3 – Condições de dano e respectivas frequências naturais.	40
Tabela 4 – Acurácias obtidas pelos classificadores considerados.	42
Tabela 5 – TVP ou sensibilidades obtidas com os classificadores selecionados.	43
Tabela 6 – TVN ou especificidades obtidas com os classificadores selecionados.	44
Tabela 7 – VPP ou precicões obtidas com os classificadores selecionados.	45
Tabela 8 – TFD obtidas com os classificadores selecionados.	46

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
AUC	<i>Area Under ROC Curve</i>
CNN	<i>Convolutional Neural Network</i>
DA	<i>Discriminant Analysis</i>
DFT	<i>Discrete Fourier Transform</i>
DT	<i>Decision Trees</i>
FEM	<i>Finite Element Method</i>
FFT	<i>Fast Fourier Transform</i>
FN	Falso Negativo
FP	Falso Positivo
IDE	<i>Integrated Development Environment</i>
KNN	<i>K-Nearest Neighbors</i>
MEMS	<i>Micro Electromechanical Systems</i>
NN	<i>Neural Network</i>
ROC	<i>Receiver Operating Characteristic</i>
SHM	<i>Structural Health Monitoring</i>
SPR	<i>Statistical Pattern Recognition</i>
SVM	<i>Support Vector Machines</i>
TFD	Taxa de Falso Descobrimento
TFP	Taxa de Falsos Positivos
TVN	Taxa de Verdadeiros Negativos
TVP	Taxa de Verdadeiros Positivos
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
VPP	Valores Preditivos Positivos

LISTA DE SÍMBOLOS

A_r	r-ésimo coeficiente da DFT
K	Quantidade de vizinhos em um classificador KNN
$P(A)$	Probabilidade de A
$P(B)$	Probabilidade de B
$P(A B)$	Probabilidade condicional de A dado B
$P(B A)$	Probabilidade condicional de B dado A
q	Quantidade de dimensões associadas aos atributos de um classificador KNN
w_1	Limite inferior de frequência para a largura de banda de meia-potência
w_2	Limite superior de frequência para a largura de banda de meia-potência
w_n	Frequência natural
w_r	Frequência de ressonância
x'	Padrão-alvo de uma determinada classe em classificadores KNN
x_i	Valores associados aos dados de um classificador KNN
x_j	Conjunto de observações para uma mesma classe de classificador KNN
X_k	k-ésima amostra da série temporal na FFT
ξ	Coefficiente de amortecimento

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	17
2	REVISÃO DA LITERATURA	18
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	EXTRAÇÃO DE ATRIBUTOS	21
3.2	CLASSIFICADORES DE APRENDIZADO SUPERVISIONADO	22
3.2.1	Árvores de decisão (DT)	22
3.2.2	Análise discriminante (DA)	23
3.2.3	<i>Naïve Bayes</i>	23
3.2.4	Máquinas de vetores de suporte (SVM)	24
3.2.5	K-vizinhos mais próximos (KNN)	26
3.3	MÉTRICAS DE DESEMPENHO	28
4	MATERIAIS E MÉTODOS	31
4.1	BANCADA EXPERIMENTAL	31
4.2	SIMULAÇÕES COMPUTACIONAIS	32
4.3	ESTRUTURA DE TESTES	34
4.4	INTERFACE <i>HARDWARE-SOFTWARE</i>	36
4.5	DANOS ESTRUTURAIIS E AQUISIÇÃO DE DADOS	37
5	RESULTADOS E DISCUSSÃO	39
5.1	ANÁLISE DAS FREQUÊNCIAS NATURAIS E COEFICIENTES DE AMOR- TECIMENTO	40
5.2	ANÁLISE DE DESEMPENHO DOS CLASSIFICADORES	41
6	CONCLUSÕES	51
	REFERÊNCIAS	53
	APÊNDICE A – ROTINA UTILIZADA PARA AQUISIÇÃO DE ACE- LERAÇÕES	57
	APÊNDICE B – ROTINA UTILIZADA NO <i>MATLAB</i> PARA PROCES- SAMENTO E EXTRAÇÃO DE ATRIBUTOS	59

1 INTRODUÇÃO

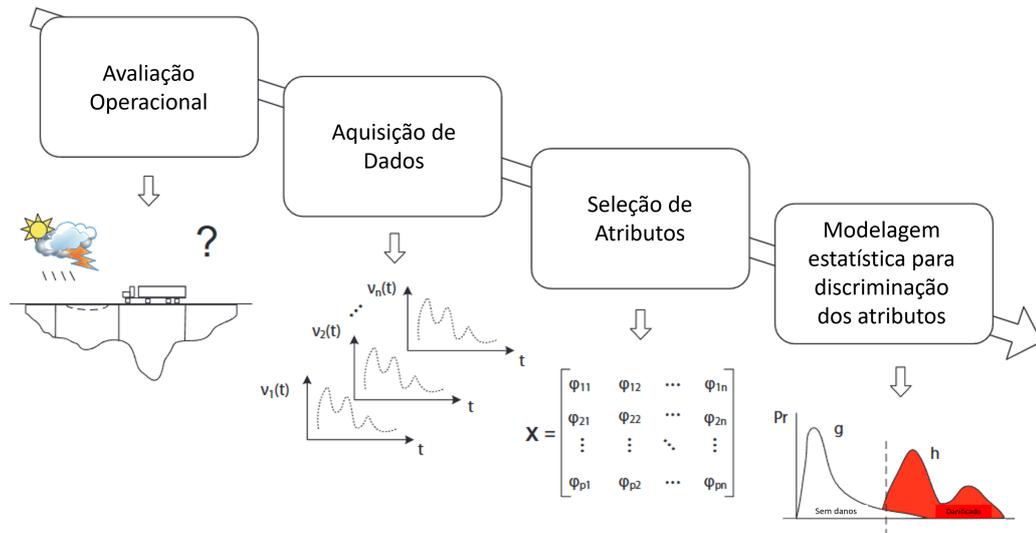
Os ciclos de vida dos projetos de engenharia apresentam ampla variedade, sendo a duração uma das principais características de interesse. Em vista disso, nota-se o desenvolvimento de técnicas necessárias para a manutenção dos produtos, prevenindo danos e permitindo maiores durabilidades e confiabilidades. Nesse contexto, o monitoramento da saúde estrutural, do inglês *Structural Health Monitoring* (SHM), é o processo de identificação não destrutiva de quatro características relacionadas à adequação de um componente de engenharia conforme ele opera (ADAMS, 2007):

- Carregamentos operacionais e ambientais;
- Danos mecânicos causados por esses carregamentos;
- Crescimento do dano;
- Desempenho futuro conforme os danos vão sendo acumulados.

A maioria das manutenções de sistemas estruturais e mecânicos é realizada com base no tempo. De acordo com Farrar e Worden (2007), SHM é a tecnologia que possibilitará a evolução das filosofias de manutenções periódicas para filosofias mais econômicas e baseadas em uma manutenção de acordo com as condições do sistema. Este conceito é aplicado através de um sistema de detecção instalado na estrutura que será responsável por monitorar a resposta do sistema e notificar o operador que um dano foi detectado. No entanto, é necessário realizar comparações entre os estados atual e inicial da estrutura para que os danos sejam avaliados. A análise das diferenças e similaridades entre os dois estados geralmente é feita com base na experiência de um profissional, porém, nota-se o crescimento do campo de pesquisa relacionado ao reconhecimento de padrões estatísticos, do inglês *Statistical Pattern Recognition* (SPR), através do aprendizado de máquina para avaliação dos danos. Farrar e Worden (2012) afirmam que um paradigma geral de SPR pode ser definido através da integração de quatro procedimentos, conforme ilustrado na Figura 1.

A normalização dos dados, remoção de ruído, compressão e fusão são encontrados nos procedimentos de aquisição de dados, seleção de atributos e modelagem estatística para discriminação dos atributos, sendo possível utilizar tanto *hardware* como *software* para execução destas etapas. O aprendizado de máquina, do inglês *machine learning*, foi empregado nas últimas duas etapas, onde são correlacionados os atributos extraídos e o estado danificado da estrutura. O problema de aprendizado a ser resolvido consiste em estimar uma função que descreve esta relação, representada pelos dados de treinamento (FARRAR; WORDEN, 2012).

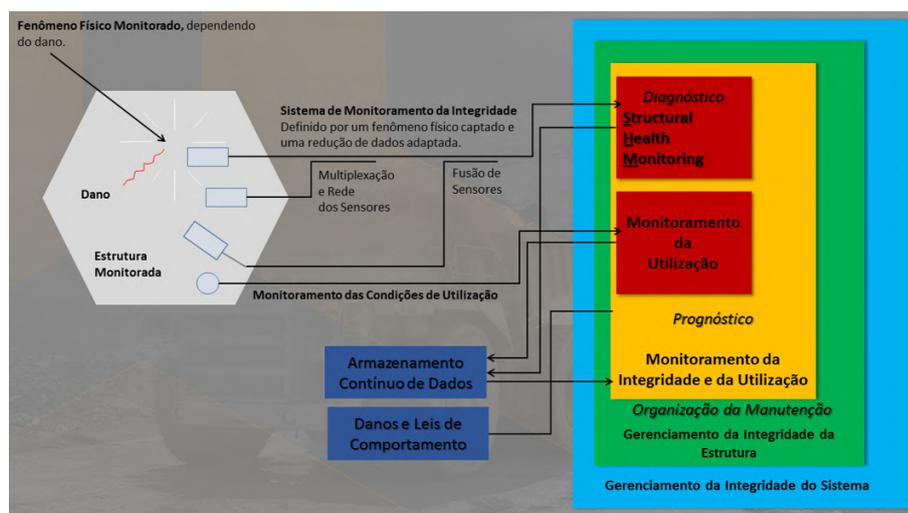
Figura 1 – Processo de SHM baseado no paradigma de SPR.



Fonte: Adaptado de Figueiredo e Santos (2018).

Na Figura 2 observa-se uma representação esquemática para o monitoramento de danos, considerando-se o Sistema de Monitoramento da Integridade correspondente à avaliação operacional para a obtenção de um diagnóstico, o Armazenamento Contínuo de Dados equivalente à aquisição de dados e os Danos e Leis de Comportamento referem-se à seleção de atributos e modelagem estatística para um prognóstico. A partir da obtenção do prognóstico, inicia-se a utilização de técnicas de reconhecimento de padrões para a avaliação estrutural através da comparação entre novos diagnósticos e prognósticos.

Figura 2 – Esquemático para o monitoramento de danos.



Fonte: Adaptado de Balageas, Fritzen e Güemes (2010).

O processo de reconhecimento de padrões pode ser efetuado através do aprendizado de máquina. Existem três tipos principais de aprendizado de máquina: supervisionado, não

supervisionado e por reforço.

De acordo com Ludermir (2021), um dos métodos mais utilizados é o aprendizado supervisionado, em que as respostas são conhecidas para cada instância apresentada ao algoritmo de aprendizado, isto é, são rotuladas para informar a qual classe pertence. Um exemplo seria o problema de distinção entre gatos e cachorros através da classificação de imagens. Os exemplos fornecidos são analisados para extração de vetores de valores, denominados atributos, e são rotulados de acordo com sua classe. Com base nestes dados, o algoritmo é utilizado para configurar um classificador que possa determinar corretamente a classe de novos dados ainda não rotulados. Dependendo da natureza dos valores de rótulos de classe, são obtidos dois tipos de algoritmos: de classificação para valores discretos e de regressão para valores contínuos.

No aprendizado não supervisionado, não há rótulos para os exemplos fornecidos ao algoritmo. São agrupados de acordo com as similaridades dos seus atributos, isto é, são analisados e o classificador tenta determinar se alguns deles podem ser agrupados de alguma maneira, formando agrupamentos ou *clusters*. Normalmente, após a definição destes, deve-se conduzir uma análise para determinar qual o significado de cada agrupamento no contexto do problema.

No aprendizado por reforço, não há uma resposta exata para ser utilizada como referência, porém o algoritmo recebe um sinal de reforço, de recompensa ou de punição. Baseando-se nos exemplos, o algoritmo elabora uma hipótese e determina se essa hipótese foi boa ou ruim. Este tipo de aprendizado é comumente encontrado em jogos e na robótica.

Conforme Farrar e Worden (2012), a questão chave para o desenvolvimento de um sistema de sensor SHM é a capacidade de capturar a resposta do sistema em durações e escalas de tempo amplamente variadas a um custo razoável. É necessário que qualquer sistema de detecção de danos possa adquirir dados que englobam qualquer alteração nas propriedades do sistema e que, por sua vez, possa afetar a capacidade do sistema de desempenhar a função pretendida de maneira segura e econômica.

Com base nisso, a medição dos danos foi realizada com base na comparação entre uma simulação de um modelo computacional de uma estrutura de dois andares e a estrutura física construída em escala real. Os danos foram aplicados de forma progressiva e foram rotulados conforme o aumento do dano. Posteriormente, analisou-se as frequências naturais como principal atributo, extraídas a partir de acelerações decorrentes de forças externas aplicadas, e os coeficientes de amortecimento como atributos secundários para avaliar o desempenho de diferentes classificadores de aprendizado supervisionado.

No presente trabalho, optou-se pela investigação de técnicas para o aprendizado supervisionado, considerando-se a maior quantidade de materiais e pesquisas disponíveis. O sensoriamento de baixo-custo utilizado foi do tipo MEMS, do inglês *Micro Electromechanical Systems*, composto pelo microcontrolador ESP-32 e o acelerômetro ADXL335. O termo MEMS refere-se a dispositivos que possuem comprimento característico inferior a 1 mm, mas superior a

1 μm , que combinam componentes elétricos e mecânicos e que são fabricados usando tecnologias de processamento em lote de circuitos integrados (HAK, 2001) . Embora os circuitos eletrônicos sejam estruturas inerentemente sólidas e compactas, os MEMS possuem furos, cavidades, canais, vigas suspensas, membranas, etc, e, de alguma forma, se assemelham a partes mecânicas (CHOLLET; LIU, 2013).

1.1 OBJETIVOS

O principal objetivo do presente trabalho de monografia foi avaliar o desempenho de diferentes algoritmos de aprendizado supervisionado na classificação de danos. Os objetivos específicos do estudo são:

- Analisar computacionalmente a influência de danos nas características estruturais de uma estrutura de dois andares;
- Analisar o comportamento da estrutura construída em escala real e comparar os resultados simulados e obtidos experimentalmente;
- Estudar a viabilidade dos MEMS no monitoramento da integridade estrutural;
- Investigar a eficiência de técnicas de aprendizado de máquina na classificação de danos estruturais.

2 REVISÃO DA LITERATURA

O advento da instrumentação facilitou a implementação de sensores capazes de adquirir dados relacionados às estruturas, em especial os MEMS. Estes dispositivos podem ser combinados com plataformas de prototipagem eletrônica para compor uma solução mais econômica com desempenho satisfatório. Sabato, Niezrecki e Fortino (2016) realizaram um estudo que resume características de diferentes acelerômetros sem fio utilizados para monitoramento de vibrações estruturais. Através das análises de microvibrações, foi provado que é possível obter uma acurácia semelhante à de acelerômetros piezoelétricos, cujos custos são maiores. Pérez et al. (2019) conduziram um trabalho que apresenta um *design* flexível e fácil de usar ao replicar um modelo para experimentos no domínio do monitoramento da saúde estrutural. O sistema nó/barra proposto permitiu que o modelo simulasse diversos cenários reais, cujas alterações estruturais foram realizadas somente com a troca das barras. Além da flexibilidade está o fato de que todos os materiais utilizados foram de baixo custo, incluindo o controlador Arduino MEGA e os sensores ADXL335. Graças a isso, a primeira versão funcional foi construída com um orçamento inferior a 100 euros. No estudo conduzido por Ribeiro e Lameiras (2019) avaliou-se o desempenho de seis acelerômetros MEMS de baixo custo, compreendendo uma análise das especificações documentadas para cada acelerômetro, através do monitoramento em tempo real de um modelo de três andares excitado por um ventilador e uma laje de concreto excitada por um impacto com o calcanhar no centro da laje. Ao final do experimento, realizou-se uma avaliação experimental de desempenho de ruído e o acelerômetro ADXL335, utilizado no presente trabalho, apresentou o melhor desempenho devido aos menores picos de aceleração e à menor densidade de ruído. Os autores concluíram que sistemas de monitoramento SHM de baixo custo são viáveis e que acelerômetros MEMS de baixo custo apresentam comportamento razoável em termos de resolução, sensibilidade e nível de ruído.

Em paralelo, verifica-se que a temática de SHM apresenta um amplo histórico na literatura, abordando os mais variados projetos de engenharia. Analisando o estado-da-arte relacionado ao tema, Sun et al. (2020) apresentaram um resumo das principais técnicas utilizadas no monitoramento estrutural de pontes e métodos de classificação comumente utilizados. As quatro principais categorias de atributos extraídos são: do domínio da frequência, do domínio do tempo e frequência, estatísticos e mecânicos. Paralelamente a essas diferentes metodologias, os autores listaram diferentes pesquisas que utilizaram técnicas de aprendizado supervisionado e não-supervisionado. Foi destacada a técnica de rede neural, do inglês *neural network* (NN), pois é capaz de providenciar novos métodos para extração de atributos que são sensíveis e robustos em relação às variações nas condições estruturais. Flah et al. (2021) realizaram uma revisão sistemática de algoritmos de aprendizado de máquina baseados em vibrações e em imagens. Foram comparadas as técnicas de máquina de vetores de suporte, do inglês *support vector*

machines (SVM), k-vizinhos mais próximos, do inglês *k-nearest neighbors* (KNN) e NN.

No trabalho conduzido por Ibrahim et al. (2019), acelerômetros de baixo-custo e classificadores foram utilizados para análise de conjuntos de dados ruidosos referentes às vibrações de construções, tais como: KNN, SVM, e rede neural convolucional, do inglês *convolutional neural network* (CNN). Um modelo também foi criado com o método de elementos finitos, do inglês *finite element method* (FEM), para auxiliar na geração de dados, posteriormente utilizados para treinamento dos classificadores. De maneira similar, Tanida et al. (2018) exploraram a detecção de danos em um modelo de casa incluindo reforços estruturais, porém com a utilização de sensores piezoelétricos e NN. A pesquisa de Dackermann, Li e Samali (2013) também utiliza acelerômetros de baixo-custo e NN para avaliar danos em uma estrutura de dois andares, porém com a possibilidade de alteração das massas em diferentes posições. Nick et al. (2015) analisaram sinais de emissão acústica e avaliaram o desempenho de três técnicas de aprendizado supervisionado: NN, SVM e classificadores *Naïve Bayes*. Notou-se a maior acurácia com a técnica SVM, com valores entre 77 a 90%, ao passo que o classificador *Naïve Bayes* apresentou acurácia entre 60 a 73% e NN entre 60 a 62%. Os autores também destacam a maior velocidade do classificador SVM para classificar as amostras no conjunto de testes.

Outro estudo comparativo foi feito por Farooq et al. (2012) através de duas abordagens baseadas em algoritmos de classificação para detecção e identificação de danos multiclases. Os classificadores SVM e redes neurais artificiais, do inglês *artificial neural network* (ANN), foram treinados com dados extraídos de um painel compósito de fibras, modelado por FEM. Os dados de deformação estática foram adquiridos de 6 locais predefinidos para 2 experimentos: um deles para detectar a presença de dano e outro para identificar a severidade do dano ao comparar a estrutura com uma trinca e outra estrutura com duas trincas. Ao final do estudo, concluiu-se que o SVM apresentou desempenho melhor ao obter acurácias maiores que o ANN. Outra referência de trabalho referente à comparação de técnicas de aprendizado supervisionado foi publicado por Khan e Kim (2022). Utilizou-se laminados de compósitos inteligentes para classificação e previsão de danos variados, destacando-se o desempenho do algoritmo de análise discriminante, do inglês *discriminant analysis* (DA).

Park et al. (2006) realizaram um estudo sobre danos em uma trinca localizada em um modelo em escala, retirado de um pedaço que caiu da ponte Seongsu, colapsada em 1994. Os autores investigaram técnicas de detecção de dano em avaliações não-destrutivas, concluindo-se que a ferramenta de processamento de sinais denominada transformada *wavelet* contínua e o classificador SVM são muito eficazes na melhoria da capacidade de detecção de danos do sistema. Mariniello et al. (2021) pesquisaram sobre a detecção e localização de danos estruturais em modelos computacionais, de testes em *benchmarks* e com dados adquiridos experimentalmente, utilizando conjuntos de árvores de decisão, do inglês *decision trees* (DT), para a classificação de dados relativos às vibrações estruturais. Os autores tinham por objetivo a identificação de danos em um único elemento estrutural através dos atributos extraídos de análises modais e as próprias

frequências naturais do sistema.

Os principais diferenciais do presente projeto de monografia em relação aos estudos já conduzidos são o uso de *hardwares* de baixo-custo para executar as tarefas propostas anteriormente e a construção simplificada da estrutura de testes com materiais economicamente acessíveis. Consequentemente, é possível destacar a possibilidade de reprodução dos experimentos realizados para o estudo dos conhecimentos empregados. Após a revisão bibliográfica e análise das principais características inerentes aos trabalhos relacionados a esse tema, foram realizadas simulações com modelos de elementos finitos e conduzidas investigações sobre diversas técnicas de inteligência artificial, aliadas a sensores de baixo-custo capazes de adquirir dados referentes a danos em uma estrutura de testes representando um prédio de dois andares. Finalmente, os principais resultados das simulações numéricas e dos ensaios realizados foram comparados para validação do modelo experimental.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 EXTRAÇÃO DE ATRIBUTOS

Este capítulo contém o detalhamento do conhecimento teórico aplicado no processamento dos sinais adquiridos. O primeiro processo executado foi a aplicação da transformada rápida de Fourier, do inglês *Fast Fourier Transform* (FFT). A técnica consiste em computar eficientemente a transformada discreta de Fourier, do inglês *Discrete Fourier Transform* (DFT), de séries temporais no domínio da frequência, cujas amostras de dados adquiridos são discretas (COCHRAN et al., 1967). Cooley e Tukey (1965) publicaram uma interpretação de trabalhos previamente publicados para o cálculo de séries complexas de Fourier. A DFT é definida pela Equação 1 (COCHRAN et al., 1967):

$$A_r = \sum_{k=0}^{N-1} (X_k) e^{(-\frac{2\pi jrk}{N})} \quad r = 0, \dots, N-1 \quad (1)$$

sendo A_r o r -ésimo coeficiente da DFT, X_k representa a k -ésima amostra da série temporal com N amostras, j é o número complexo $\sqrt{-1}$ e r é a frequência da DFT, pois os X_k são valores da função em pontos discretos de tempo. No *software MATLAB*, a função *fft* foi utilizada para executar estes cálculos e a primeira frequência natural foi obtida através da função *max*, sendo o ponto com a maior amplitude no intervalo de frequência analisado.

Os coeficientes de amortecimentos foram obtidos através do método da largura de banda de meia potência, calculados através da Equação 2 (PAPAGIANNPOULOS; HATZIGEORGIOU, 2011):

$$2\xi \approx \frac{\omega_2 - \omega_1}{\omega_n} \quad (2)$$

sendo ξ o coeficiente de amortecimento, ω_2 e ω_1 os pontos de frequência de meia potência, localizados onde a amplitude de resposta é igual a $1/\sqrt{2}$ do valor da amplitude máxima e ω_n a frequência natural. Papagiannopoulos e Hatzigeorgiou (2011) apontam que a frequência de ressonância ω_r pode ser aproximada à frequência natural ω_n para pequenos valores de coeficientes de amortecimento ξ . A função *powerbw* do *MATLAB* foi utilizada para determinar a largura de banda de meia potência. As frequências mínima e máxima deste intervalo correspondem aos valores em que a amplitude da resposta em frequência decai 3 dB em relação ao pico, que indica a resposta gerada pelo valor da frequência de ressonância do sistema (MACIOCE, 2003). Após a extração da largura de banda de meia potência, os valores de ξ foram calculados através da Equação 2.

3.2 CLASSIFICADORES DE APRENDIZADO SUPERVISIONADO

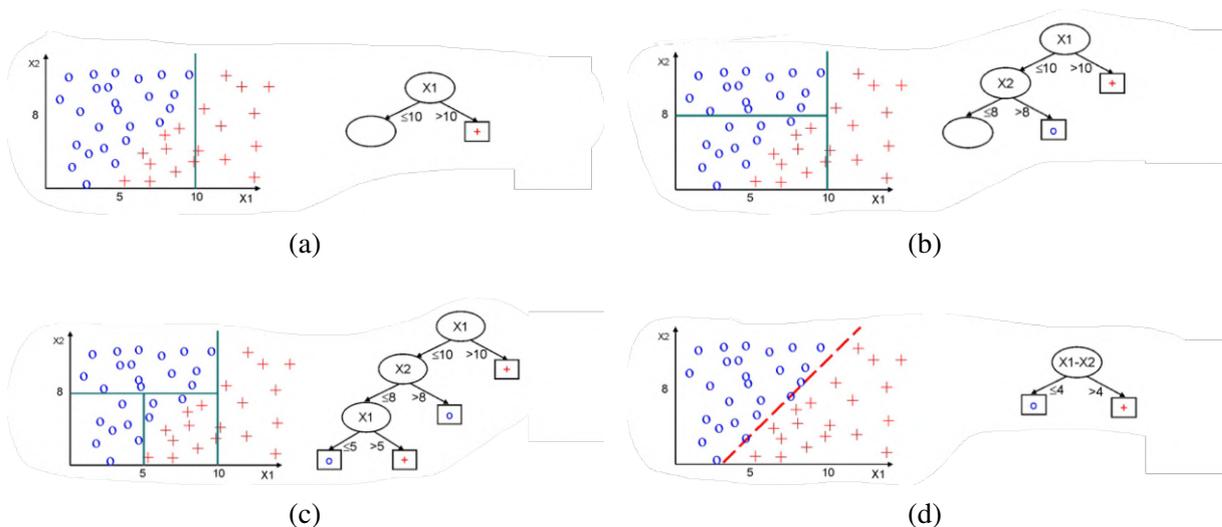
O processamento dos atributos foi realizado utilizando-se classificadores de aprendizado supervisionado, isto é, todas as classes são conhecidas para cada amostra analisada. O aplicativo *Classification Learner* do *MATLAB* disponibiliza diversos algoritmos de aprendizado de máquina pré-programados para avaliar o desempenho de diferentes tipos de classificadores. Nesta seção são apresentadas brevemente as características dos modelos adotados para este trabalho, que foram:

- Árvores de decisão (DT);
- Análise discriminante (DA);
- *Naïve Bayes*;
- Máquinas de vetores de suporte (SVM);
- K-vizinhos mais próximos (KNN).

3.2.1 Árvores de decisão (DT)

As árvores de decisão classificam dados através de uma série de questionamentos sobre os atributos associados a cada amostra. Uma interpretação geométrica de um exemplo de árvore de decisão pode ser observada na Figura 3, cujas etapas de ramificações são representadas nas Figuras 3a, 3b, 3c e 3d:

Figura 3 – Exemplo de uma árvore de decisão.



Fonte: Adaptado de Monard e Baranauskas (2003)

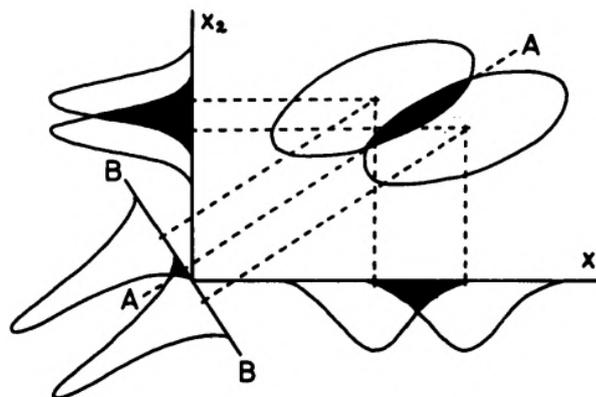
As questões estão contidas nos ramos da árvore de decisão, sendo perguntas com respostas binárias ou de intervalos numéricos, por exemplo. A estruturação da árvore de decisão ocorre

por meio das respostas às perguntas, construindo-se um caminho desde o nó superior, denominado raiz, até o nó sem ramos, denominado nó folha. Uma amostra é rotulada quando o caminho termina em um nó folha, sendo classificada de acordo com o atributo analisado. As árvores de decisão naturalmente suportam problemas de classificação com mais de duas classes e podem ser modificadas para lidar com problemas de regressão (KINGSFORD; SALZBERG, 2008). Monard e Baranauskas (2003) comentam que a linha tracejada na Figura 3d representa uma hipótese mais simples e que pode classificar os exemplos de maneira mais eficaz, possibilitando a classificação de mais de um atributo.

3.2.2 Análise discriminante (DA)

A análise discriminante, por sua vez, utiliza o conceito de fronteiras de decisão para a discriminação dos atributos de suas diferentes classes (MISHRA et al., 2016). Foi inicialmente proposto por Fisher (1936) na tentativa de criar uma função linear para resolver o problema de combinação de conjuntos de dados para discriminação de duas classes distintas (SOLBERG, 1978). Uma interpretação geométrica para a análise discriminante de duas classes é apresentada na Figura 4 :

Figura 4 – Representação geométrica da análise discriminante de duas classes.



Fonte: Solberg (1978)

Solberg (1978) indica que o eixo B-B representa uma função de discriminação linear, ao passo que a linha A-A representa a fronteira de decisão. Em casos de três ou várias classes, as representações geométricas são planos ou hiperplanos, respectivamente.

3.2.3 Naïve Bayes

O nome *Naïve Bayes* é dado a uma coleção de algoritmos de classificação que são baseados no Teorema de Bayes. O classificador *Naïve Bayes* consiste em uma técnica de aprendizado supervisionado probabilística (RAHAT; KAHIR; MASUM, 2019). Na prática, o Teorema de Bayes leva em consideração a ideia de probabilidade apresentada na Equação 3:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

sendo $P(A|B)$ a probabilidade condicional de A dado B, $P(A)$ a probabilidade de A, $P(B)$ a probabilidade de B e $P(B|A)$ a probabilidade condicional de B dado A (EFRON, 2013). O classificador pode apresentar um desempenho melhor que muitos classificadores mais sofisticados e é utilizado em problemas com a suposição de que os atributos não são fortemente correlacionados (ADDIN et al., 2007).

3.2.4 Máquinas de vetores de suporte (SVM)

De acordo com Noble (2006), o classificador SVM é um algoritmo computacional que aprende através de exemplos para atribuir rótulos às amostras. Essencialmente, seu objetivo é maximizar uma função matemática em relação a um determinado conjunto de dados. Em muitos casos, a distinção das classes pode ser feita visualmente e não requer fórmulas e cálculos complexos. No entanto, os algoritmos são baseados em 4 conceitos principais para distinguir as amostras e classificá-las:

- Hiperplano de separação;
- Hiperplanos de margens máximas;
- Margem flexível;
- Função *kernel*.

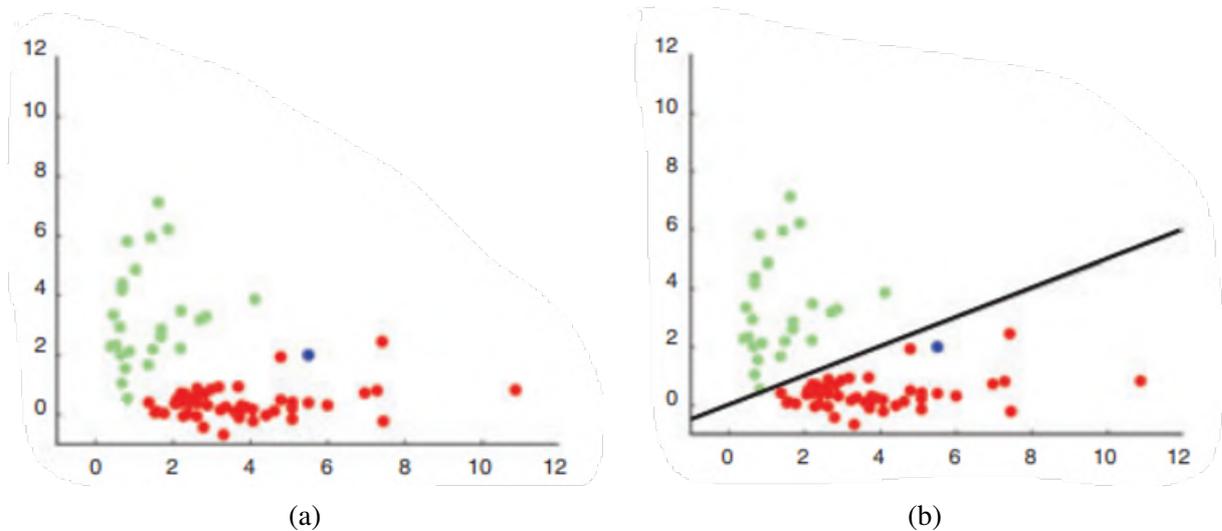
O hiperplano de separação é geometricamente representado como a curva que separa os agrupamentos de classes distintas. É possível observar tal separação na Figura 5, cuja amostra de dados é representada na Figura 5a e a separação das classes é feita através do hiperplano de separação na Figura 5b:

É possível encontrar diversos hiperplanos de separação, conforme representado na Figura 6a. Portanto, conforme a Figura 6b, determinam-se os hiperplanos de margens máximas através da maximização das margens, que são definidas como a distância entre o hiperplano de separação e o valor de cada amostra.

Na maioria dos problemas, os dados não apresentam uma distribuição proporcional e existem amostras que não apresentam os valores de atributos esperados para uma determinada classe, conhecidas como *outliers*, conforme Figura 7a. Nestas ocasiões, observa-se na Figura 7b que a amostra impacta no posicionamento do hiperplano de separação, uma vez que a margem relativa à amostra difere-se das demais esperadas para sua classe.

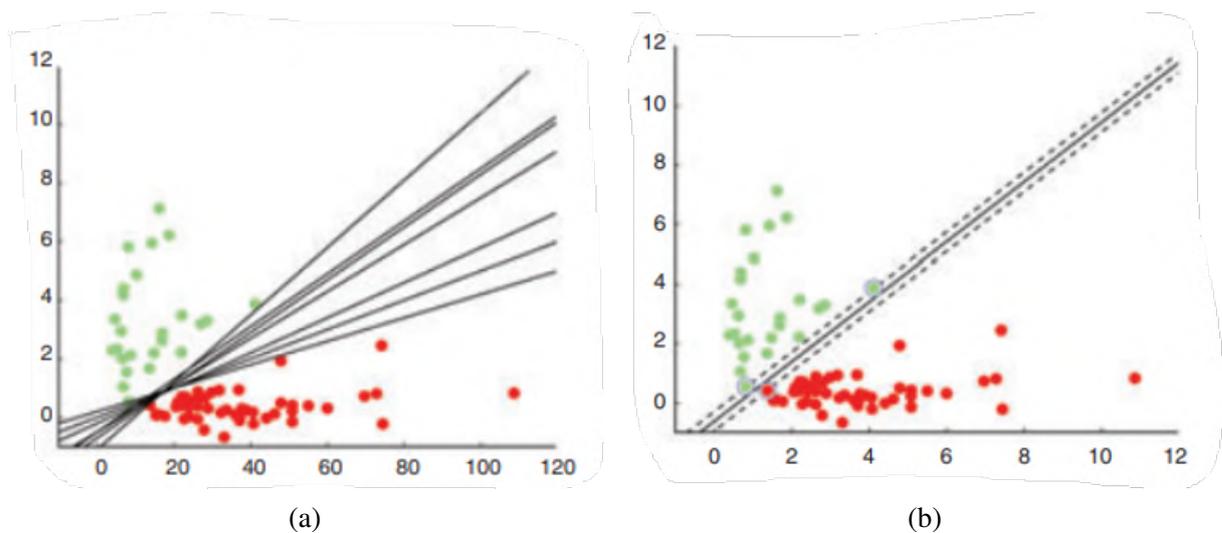
Finalmente, o conceito de função *kernel* é aplicado quando não é possível distinguir classes somente com os dados brutos das amostras, conforme apresentado na Figura 8a. É necessário

Figura 5 – Hiperplano de separação.



Fonte: Adaptado de Noble (2006)

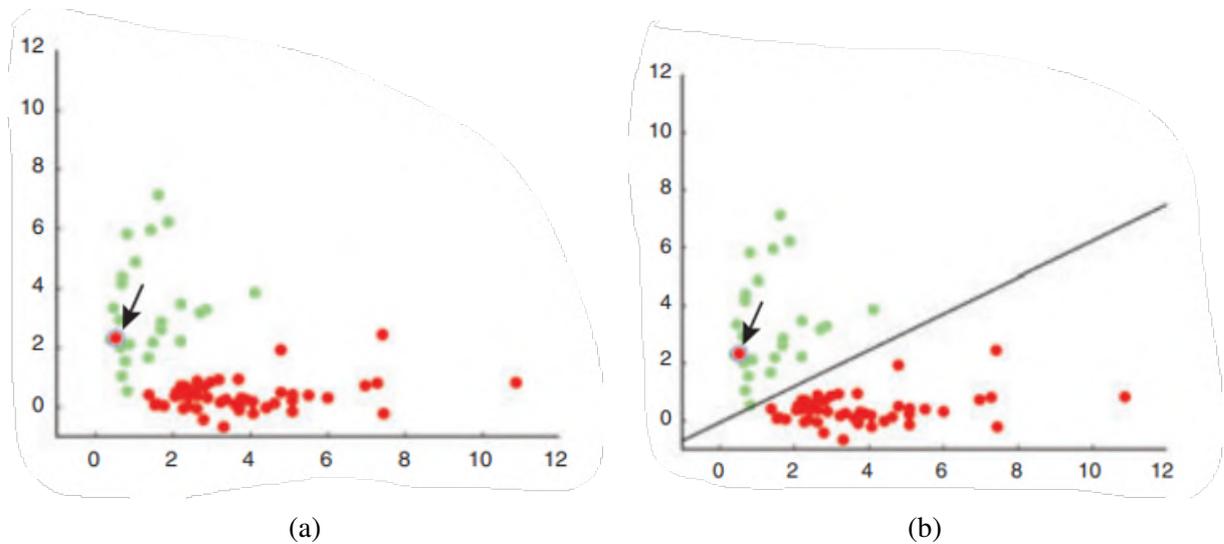
Figura 6 – Possíveis hiperplanos de separação e hiperplanos de margens máximas.



Fonte: Adaptado de Noble (2006)

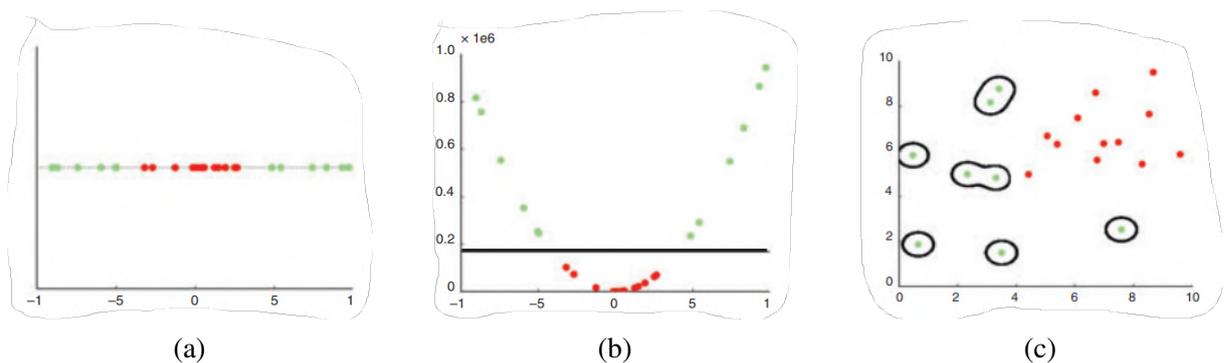
processar os dados de forma que a distinção entre atributos de diferentes categorias seja possível. Um exemplo é obter os valores dos atributos elevados ao quadrado para facilitar a separação, representados na Figura 8b. Dependendo do tipo, os classificadores apresentam variadas funções *kernel*, como: quadráticas, Gaussianas, cúbicas, dentre outras. Este procedimento é caracterizado pelo aumento do número de dimensões dos atributos analisados. Contudo, existe um limite para a quantidade de dimensões criadas, uma vez que amostras da mesma classe podem ser categorizadas erroneamente em duas classes distintas devido à função *kernel* de múltiplas dimensões. Este fenômeno é chamado sobre-ajuste, do inglês *overfitting* e é indesejável para problemas de aprendizado de máquina, uma vez que se torna um obstáculo para a classificação correta dos dados. Um exemplo disso pode ser visualizado na Figura 8c:

Figura 7 – Margem flexível e impacto sobre o hiperplano de separação.



Fonte: Adaptado de Noble (2006)

Figura 8 – Função *kernel* e suas implicações.



Fonte: Adaptado de Noble (2006)

3.2.5 K-vizinhos mais próximos (KNN)

Os classificadores KNN são fundamentados na busca por um padrão-alvo, o qual procura-se sua classificação, e os padrões mais próximos a esse devem fornecer informações úteis sobre a classe de cada amostra. Os valores utilizados para avaliação das similaridades e diferenças entre as amostras no espaço de dados podem ser calculados através da Equação 4 (KRAMER; KRAMER, 2013):

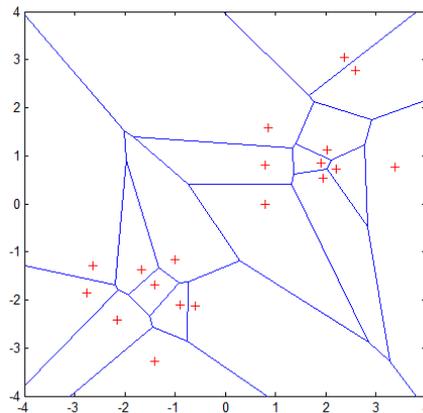
$$\|x' - x_j\|^p = \left(\sum_{i=1}^q |(x_i)' - (x_i)_j|^p \right)^{(1/p)} \quad (4)$$

sendo x' o padrão-alvo para uma determinada classe, x_j o conjunto de observações para a mesma classe, x_i os valores associados aos dados e q a quantidade de dimensões associadas aos atributos. Caso $p = 2$, a Equação 4 passa a representar o cálculo da distância Euclidiana,

geralmente utilizado para resolver os problemas de KNN. Cabe destacar que a função escolhida para resolver o problema está diretamente relacionada à dimensionalidade do conjunto de dados e seus atributos.

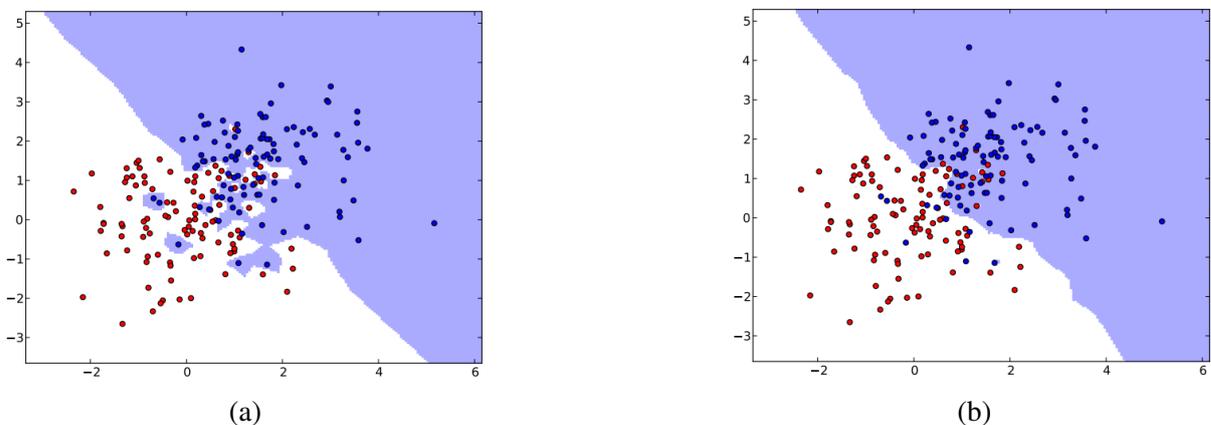
Na Figura 9 é possível observar a formação de um diagrama de Voronoi conforme as vizinhanças, definidas pelo parâmetro K e representadas pelas linhas azuis, são criadas para a separação dos atributos, representados pelos pontos vermelhos. Um valor de K elevado significa a redução do impacto da variância gerada por erros aleatórios sobre os resultados, porém aumenta o risco de ignorar padrões discretos e importantes (ZHANG, 2016). É possível verificar a influência do valor de K sobre os resultados de um exemplo qualquer na Figura 10, uma vez que para $K = 1$ ocorre o *overfitting* e a criação de vizinhanças em aglomerações pequenas que poderiam ser desprezadas, conforme Figura 10a. O valor de $K = 20$ para o mesmo conjunto de dados equivale a uma generalização maior que no caso de $K = 1$ e passa a ignorar pequenas aglomerações de padrões, segundo ilustrado na Figura 10b (KRAMER; KRAMER, 2013).

Figura 9 – Diagrama de Voronoi em classificadores KNN.



Fonte: Peterson (2009)

Figura 10 – Influência do parâmetro K sobre os resultados.



Fonte: Kramer e Kramer (2013)

3.3 MÉTRICAS DE DESEMPENHO

Nesta seção são apresentadas as equações utilizadas para avaliar o desempenho dos classificadores. Os primeiros parâmetros obtidos foram extraídos a partir da matriz de confusão, obtida após o treinamento e classificação dos dados. A principal métrica utilizada como referência é a acurácia, calculada de acordo com a Equação 5:

$$Acurácia = \frac{(VP + VN)}{(VP + FP + VN + FN)} \quad (5)$$

sendo Verdadeiro Positivo (VP) os atributos classificados corretamente de acordo com a sua verdadeira classe, Falso Positivo (FP) os atributos especificados de acordo com sua classe, porém incorretos em relação à sua verdadeira classe, Falso Negativo (FN) os atributos categorizados como sendo não pertencentes à sua verdadeira classe, mas que de fato pertencem e Verdadeiro Negativo (VN) os atributos rotulados às demais classes e que não possuem qualquer relação com a classe de interesse (SAMMUT; WEBB, 2017).

As seguintes métricas secundárias foram consideradas: sensibilidade ou taxa de verdadeiros positivos (TVP), especificidade ou taxa de verdadeiros negativos (TVN), precisão ou valores preditivos positivos (VPP) e taxa de falso descobrimento (TFD), respectivamente calculadas através das Equações 6, 7, 8 e 9:

$$TVP = \frac{VP}{(VP + FN)} \quad (6)$$

$$TVN = \frac{VN}{(VN + FP)} \quad (7)$$

$$VPP = \frac{VP}{(VP + FP)} \quad (8)$$

$$TFD = \frac{FP}{(FP + VP)} \quad (9)$$

Em problemas de aprendizado de máquina multiclases, isto é, com mais de duas classificações possíveis para os atributos, a análise da matriz de confusão em relação a uma classe B qualquer é interpretada conforme a representação esquemática na Figura 11.

Os últimos indicadores considerados para a análise de desempenho dos classificadores é a curva ROC, do inglês *Receiver Operating Characteristic*, e o valor da área sob a curva, do inglês *Area under ROC curve* (AUC). A curva ROC representa a relação entre a sensibilidade e a especificidade, indicando pontos de relação entre as taxas de verdadeiros positivos e as taxas de falsos positivos (TFP). Este parâmetro é calculado através da Equação 10 e representa o valor complementar da especificidade ou TVN.

Figura 11 – Análise de parâmetros em uma matriz de confusão para uma classe B qualquer.

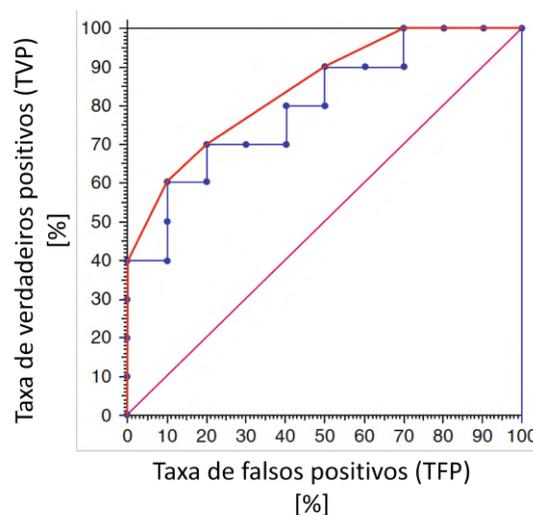
		Classificação prevista			
		Classes	A	B	C
Classificação verdadeira	A	VN	FP	VN	VN
	B	FN	VP	FN	FN
	C	VN	FP	VN	VN
	D	VN	FP	VN	VN

Fonte: Elaborada pelo próprio autor.

$$TFP = \frac{FP}{(FP + VN)} = 1 - TVN \tag{10}$$

Os pontos da curva ROC representam valores prováveis relacionados à sensibilidade e especificidade, obtidos para determinado conjunto de dados utilizado para o treinamento do classificador. Destaca-se que o aspecto da curva pode alterar de acordo com os parâmetros adotados, como: função *kernel*, quantidade de validações cruzadas efetuadas pelo conjunto de dados de treinamento e dimensão do número de amostras. No capítulo 5, serão apresentados resultados referentes ao desempenho de classificadores pré-programados no *MATLAB* com parâmetros pré-definidos. Paralelamente, o valor de AUC varia de 0 a 1 e indica que todas as classificações negativas apresentam percentual maior em relação às positivas quando é igual a 0. Por outro lado, o valor de 1 representa o maior valor percentual de positivas em relação a todas as negativas. A interpretação estatística da AUC esperada para um bom classificador é a de que uma classificação do tipo positiva (TVP) escolhida aleatoriamente tenha o maior valor de razão entre TVP e TFP possível (SAMMUT; WEBB, 2017). O exemplo de uma curva ROC e a sua respectiva AUC podem ser observados na Figura 12.

Figura 12 – Exemplo de curva ROC e sua AUC.



Fonte: Sammut e Webb (2017)

No presente trabalho, utilizou-se a métrica de acurácia para a exclusão de classificadores com desempenhos piores em relação aos demais. As métricas secundárias, curva ROC e AUC foram utilizadas somente para a comparação dos classificadores que apresentaram os melhores valores de acurácia, cujos resultados serão apresentados no capítulo 5.

4 MATERIAIS E MÉTODOS

Considerando a necessidade de realizar os experimentos para este trabalho fora do ambiente da universidade, foi construída uma estrutura de baixo custo para a extração de dados e capaz de representar estruturas estudadas na engenharia. Esta seção irá apresentar os procedimentos adotados e as técnicas computacionais empregadas para a obtenção dos resultados desejados.

Inicialmente, realizaram-se simulações computacionais da estrutura no *software NX Siemens*, utilizadas como referências para análise dos resultados. Em seguida, foram avaliadas as possibilidades de materiais que pudessem ser utilizados, visto que deveriam ser de baixo custo. Construiu-se a estrutura de dois andares, instrumentada com acelerômetro e placa de prototipagem, possibilitando a extração dos atributos para o aprendizado de máquina. Os principais atributos analisados foram as frequências naturais e os coeficientes de amortecimentos. A propagação dos danos foi realizada manualmente, induzindo-se o aumento da dimensão do dano e cuja ideia é relacionada ao aumento do tamanho de uma trinca que propaga com o passar do tempo. Os danos estruturais foram aplicados à medida que os dados extraídos eram suficientes para o algoritmo de aprendizado de máquina reconhecer os padrões inerentes a cada dimensão de dano. Os sinais obtidos foram então processados para análise posterior no *software MATLAB*, utilizando-se algoritmos de aprendizado de máquina supervisionado.

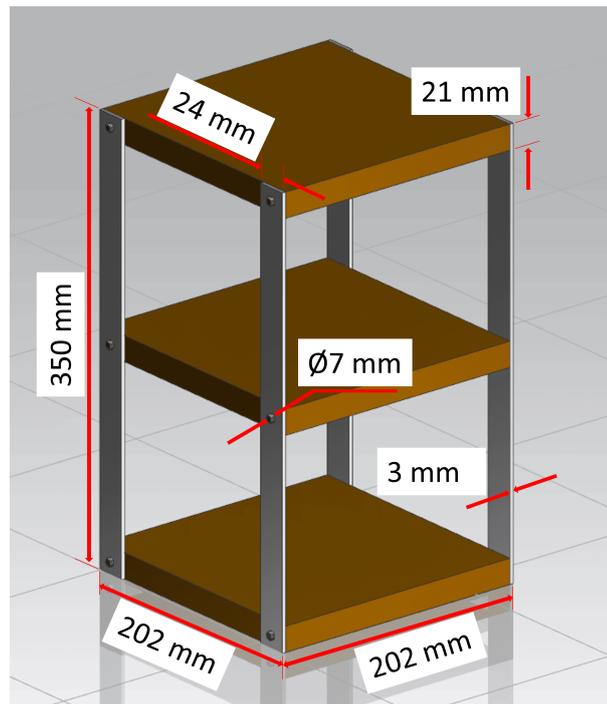
4.1 BANCADA EXPERIMENTAL

A bancada experimental foi construída com base no modelo adotado por Shiki e Franco (2020), constituída por dois andares de madeira de eucalipto e quatro vigas de policloreto de vinila (PVC) rígidas, totalizando 350 mm de altura. As dimensões de cada material foram escolhidas levando-se em consideração a necessidade de obter uma estrutura rígida, porém capaz de apresentar certa mobilidade ao aplicar-se uma força externa. Dessa forma, foi possível analisar os deslocamentos e amplitudes dos sinais extraídos com maior nitidez.

Cada andar é representado por uma base com seções quadradas de 202 mm de lado, com 21 mm de espessura. A sustentação dos andares é feita por parafusos de aço inoxidáveis M7 que conectam as quatro vigas com 350 mm de comprimento, 24 mm de largura e 3 mm de espessura aos blocos de madeira no meio de cada andar.

O esquemático da estrutura projetada no *software NX Siemens* com suas respectivas dimensões pode ser observado na Figura 13:

Figura 13 – Esquemático da estrutura projetada no *software NX Siemens*.



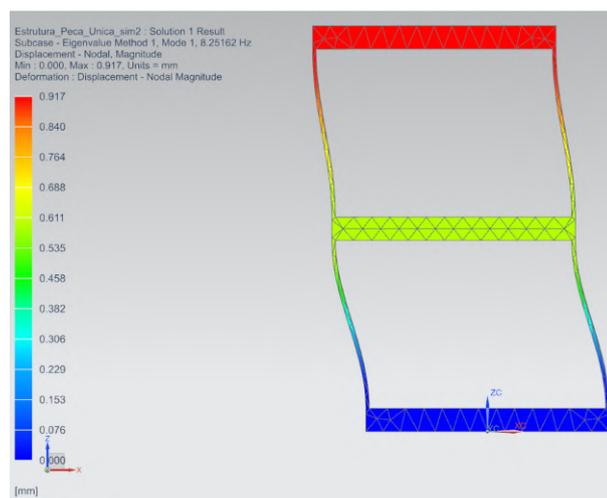
Fonte: Elaborada pelo próprio autor.

4.2 SIMULAÇÕES COMPUTACIONAIS

A primeira simulação computacional foi realizada através da SOL 103 *Real Eigenvalues* do *NX NASTRAN*, cujo resultado obtido para a frequência natural ω_n em caso de uma estrutura intacta são apresentados na Figura 14.

Figura 14 – Primeiro modo de vibração obtido no *NX NASTRAN*.

1º Modo de vibração: $\omega_n = 8,25$ Hz

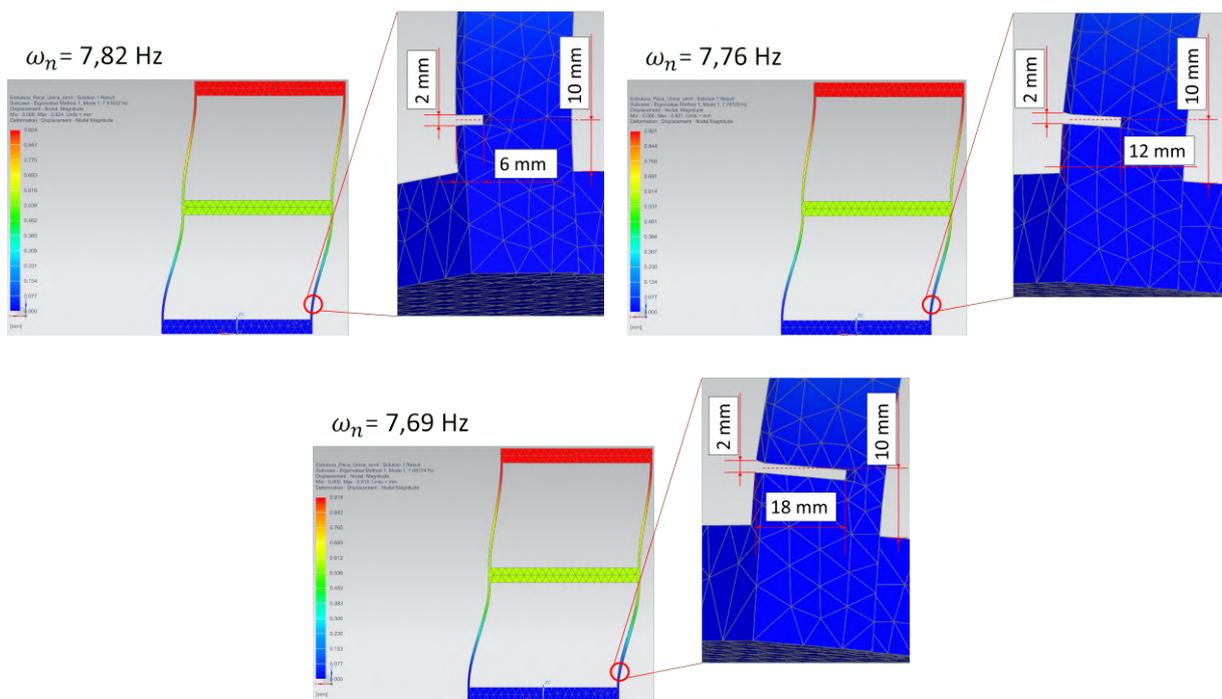


Fonte: Elaborada pelo próprio autor.

A simulação feita no *NX NASTRAN* é composta por uma análise de elementos finitos (FEM) e deve-se levar em consideração que foi simplificada, pois os componentes e materiais foram criados de forma aproximada à estrutura real. A primeira aproximação feita foi em relação à malha, dividida em elementos tetraédricos de forma arbitrária. Também considerou-se que o material da estrutura é anisotrópico, isto é, as propriedades físicas e químicas do material dependem de sua direção (NEWNHAM, 2005), uma vez que a maior porcentagem da massa da estrutura é composta pela madeira, caracterizada pela anisotropia. Adicionalmente, observa-se que os modos de vibração são apresentados em uma simulação em que a base é fixada pela parte inferior, isto é, na forma de engaste. Considerando-se estas aproximações e especulações, era esperado que os resultados computacionais e reais fossem próximos, porém com algumas divergências.

As dimensões dos danos aplicados à uma das vigas progrediu de 6 em 6 mm, totalizando um total de 4 condições de dano. Ao quantificar os danos, o objetivo é estimar um parâmetro fisicamente significativo que caracterize o nível de dano (ADAMS, 2007). O intervalo entre cada dimensão de dano foi determinado de acordo com a progressão nas diferenças observadas entre cada condição, isto é, optou-se por dimensões de danos em que pudessem ser observadas diferenças significativas entre os atributos extraídos. A espessura considerada para o dano foi de 2 mm, cujo plano médio do corte é localizado 10 mm acima da parte superior da base de madeira. As simulações da estrutura com dimensões de danos iguais a 6, 12 e 18 mm podem ser visualizadas na Figura 15:

Figura 15 – Simulações realizadas para diferentes dimensões de danos.



Fonte: Elaborada pelo próprio autor.

Na Tabela 1 são apresentadas as correlações entre o tamanho das dimensões dos danos em 4 condições avaliadas e as frequências naturais simuladas:

Tabela 1 – Dimensões de dano e frequências naturais simuladas.

Condição	Dimensão do dano [mm]	ω_n [Hz]
1	0	8,25
2	6	7,82
3	12	7,76
4	18	7,69

Fonte: Elaborada pelo próprio autor.

O principal atributo analisado neste trabalho é a primeira frequência natural, uma vez que é o menor valor e o mais suscetível à excitações de fontes externas neste valor de frequência em estruturas desta natureza. O segundo atributo a ser analisado é o coeficiente de amortecimento, sendo determinante para a característica do sinal oscilatório extraído da estrutura. Não são apresentadas simulações acerca dos valores de coeficientes de amortecimento neste trabalho, pois a análise modal em FEM assume coeficientes nulos para o cálculo das frequências naturais. No entanto, alterações nos valores de coeficientes de amortecimento são esperadas devido à presença de danos estruturais.

4.3 ESTRUTURA DE TESTES

Na Figura 16, observa-se a estrutura de testes finalizada e sua dimensão total na imagem à esquerda. A dimensão referente a cada andar e a direção de movimentação da estrutura considerada para a realização dos testes podem ser observados na imagem à direita.

Figura 16 – Estrutura para aquisição de dados finalizada.

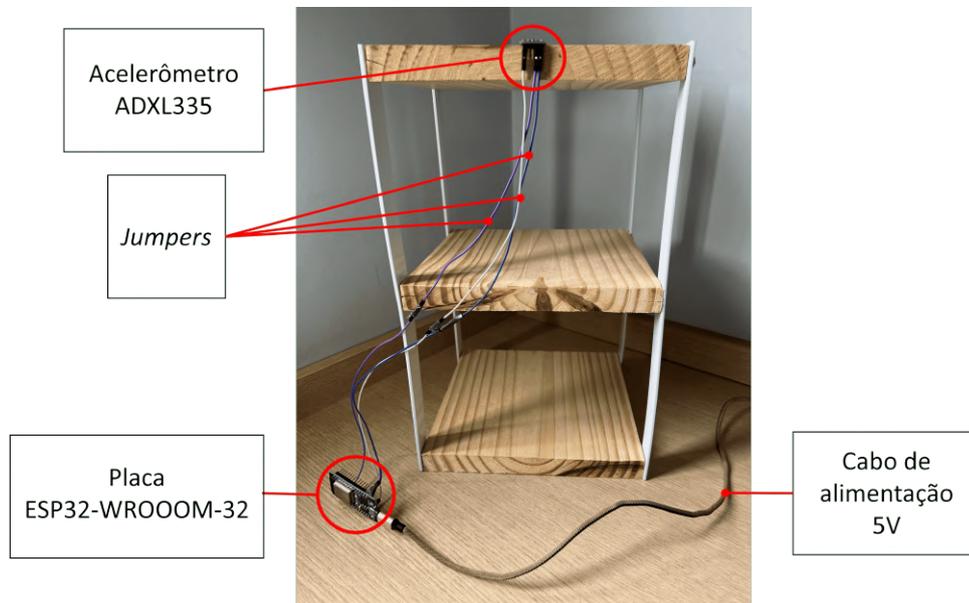


Fonte: Elaborada pelo próprio autor.

Os valores de acelerações foram medidos em uma única direção para simplificar a análise e o processo de extração dos atributos estudados neste trabalho.

Os componentes utilizados para a aquisição de dados de aceleração são representados na Figura 17 e suas especificações são:

Figura 17 – Posicionamento dos componentes para sensoriamento.



Fonte: Elaborada pelo próprio autor.

- 1 acelerômetro triaxial ADXL335 (sensibilidade: 300 mV/g, faixa de medição: $\pm 3,6$ g de pico, faixa de frequência: até 1600 Hz);
- 1 microcontrolador ESP32-WROOM-32 (18 pinos analógicos, resolução: 12 bits);
- *Jumpers* para conexão dos componentes à placa de prototipagem;
- Cabo de alimentação 5V.

O acelerômetro foi fixado através de parafusos na parte superior do segundo andar da estrutura e a placa de prototipagem foi conectada ao computador através do cabo de alimentação de 5V. O acelerômetro ADXL335 é do tipo MEMS, analógico e mede vibrações devido à variação da capacitância em condensadores diferenciais. Pode ser utilizado para medir a aceleração estática da gravidade e as acelerações devidas ao movimento, choque ou vibração. Apresenta baixo-custo e é ideal para aplicações de baixa frequência (VARANIS et al., 2018). O microcontrolador ESP32-WROOM-32 consiste em um módulo utilizado em uma ampla variedade de aplicações, inclusive redes de sensores com baixo consumo de energia (SYSTEMS, 2021).

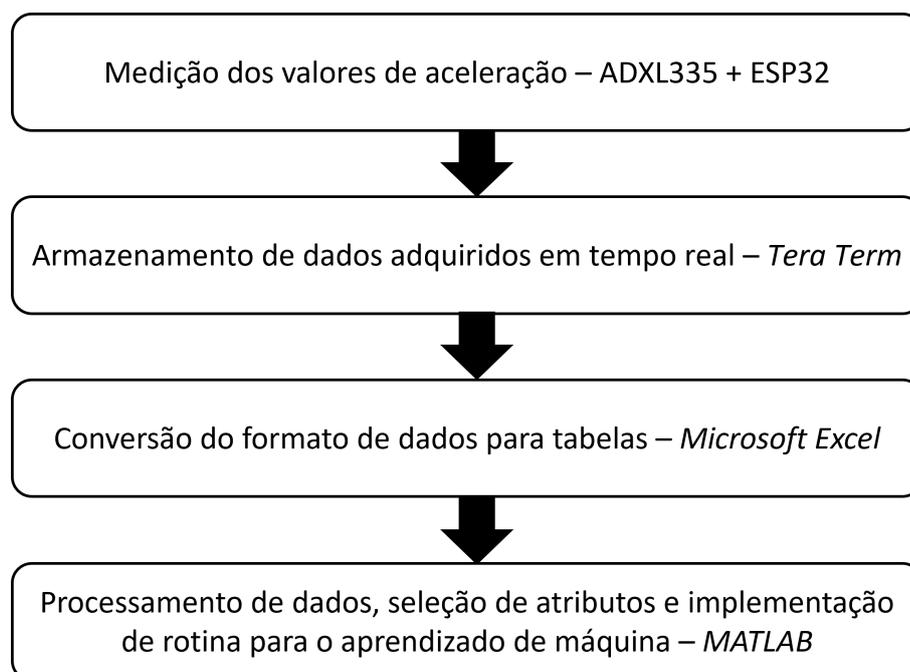
4.4 INTERFACE *HARDWARE-SOFTWARE*

Inicialmente, utilizou-se o Arduino IDE, do inglês *Integrated Development Environment*, um *software open-source* baseado na linguagem C++, para extrair os valores de acelerações. A rotina para o processamento de dados é apresentado no Apêndice A, cujos principais parâmetros escolhidos são a frequência de amostragem igual a 128 Hz e o intervalo de medição de 8 segundos. Conforme apresentado na seção de simulações computacionais, considerando-se que as frequências naturais a serem analisadas são relativamente baixas, foram conduzidos experimentos com uma frequência de amostragem maior que as observadas nas simulações. Em paralelo, o intervalo de tempo escolhido foi suficiente para observar o amortecimento total da estrutura antes de realizar uma nova amostragem.

Ao mesmo tempo em que as medições foram realizadas, utilizou-se o *software open-source Tera Term* para salvar cada valor medido em um arquivo no *Microsoft Excel*. Os dados foram transformados em tabelas, exportados para o *MATLAB* e submetidos ao processamento de dados através da rotina computacional para seleção dos atributos, cujo algoritmo utilizado para a criação da matriz de atributos é apresentado no Apêndice B. Finalmente, realizou-se a modelagem estatística para o aprendizado de máquina através dos próprios recursos do *MATLAB*, disponibilizados em sua biblioteca de aplicativos.

Na Figura 18 é possível observar o fluxograma que descreve a integração entre os dispositivos e programas computacionais utilizados:

Figura 18 – Fluxograma *hardware-software*.



Fonte: Elaborada pelo próprio autor.

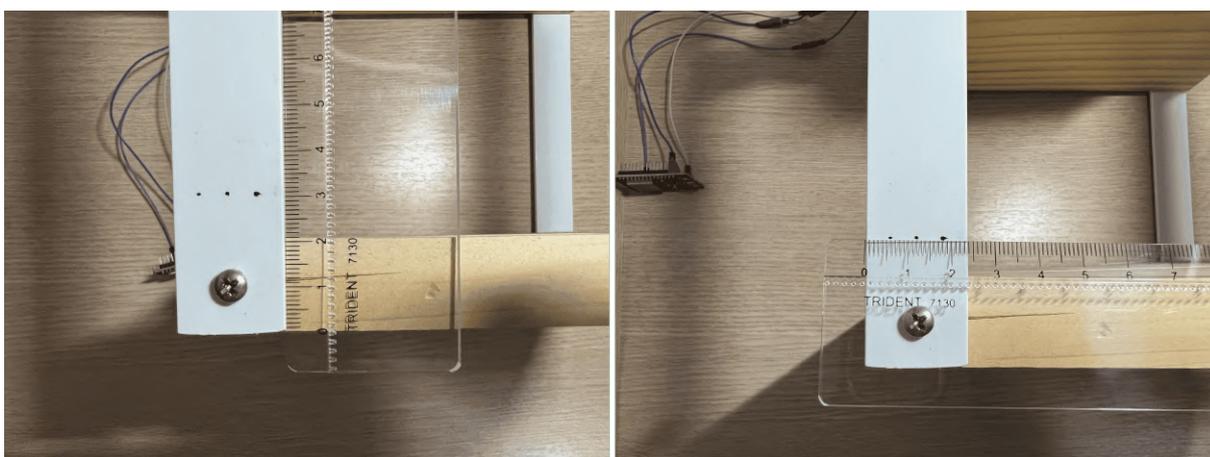
4.5 DANOS ESTRUTURAIS E AQUISIÇÃO DE DADOS

Nesta seção serão apresentados os detalhes sobre as condições de dano e o procedimento adotado para os experimentos. Peeters, Maeck e Roeck (2001) comentam que a perda de rigidez é observada conforme a diminuição das frequências naturais devido aos danos e condições ambientais. Neste caso, o problema é que as alterações devidas a danos podem ser indetectáveis devido à variação dos parâmetros ambientais. Em vista do objetivo de analisar apenas os efeitos das alterações causadas por danos, desprezou-se a influência das mudanças ambientais sobre os resultados obtidos neste trabalho.

Os testes foram realizados manualmente para todas as condições de dano, cuja base da estrutura permaneceu fixa. Os dados de aceleração foram extraídos a partir de aplicações de forças externas do tipo impulso, variando-se a localização da aplicação de força com o intuito de se evitar a obtenção de dados enviesados para o algoritmo de aprendizado de máquina. Nos problemas de SHM, destaca-se a importância de obter dados referentes a amostras adquiridas em diferentes circunstâncias e que devem apontar consistência nos resultados, visto que Sun et al. (2020) afirmam que a amostragem de distribuições particulares pode diminuir a variância dos atributos estimados, porém aumentarão o enviesamento, uma vez que a distribuição verdadeira pode ser muito diferente da assumida.

Os danos simulados progrediram de 6 em 6 mm em uma única viga, cuja marcação das dimensões para auxiliar na realização dos cortes está representada na Figura 19:

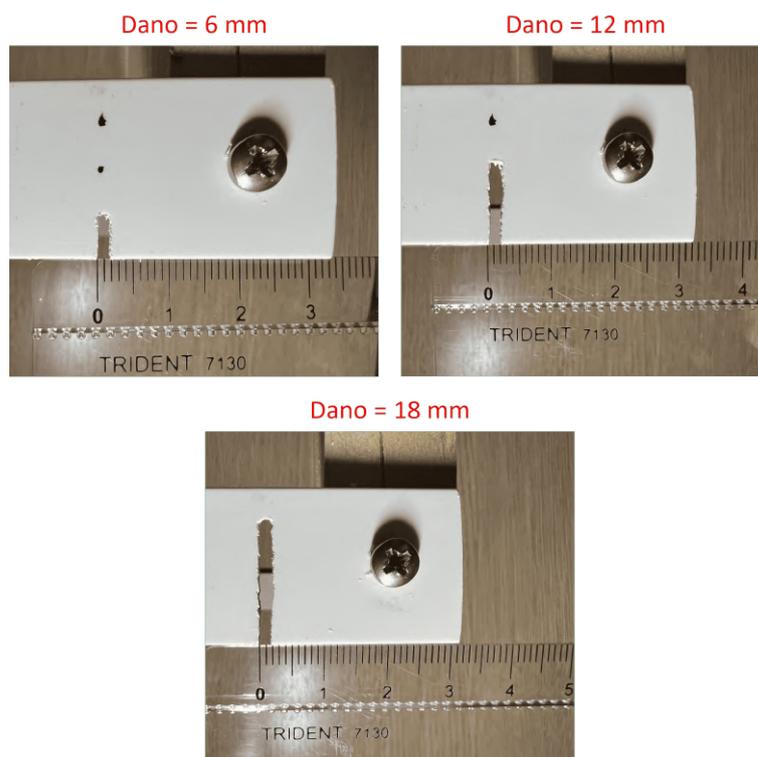
Figura 19 – Marcação das dimensões de dano.



Fonte: Elaborada pelo próprio autor.

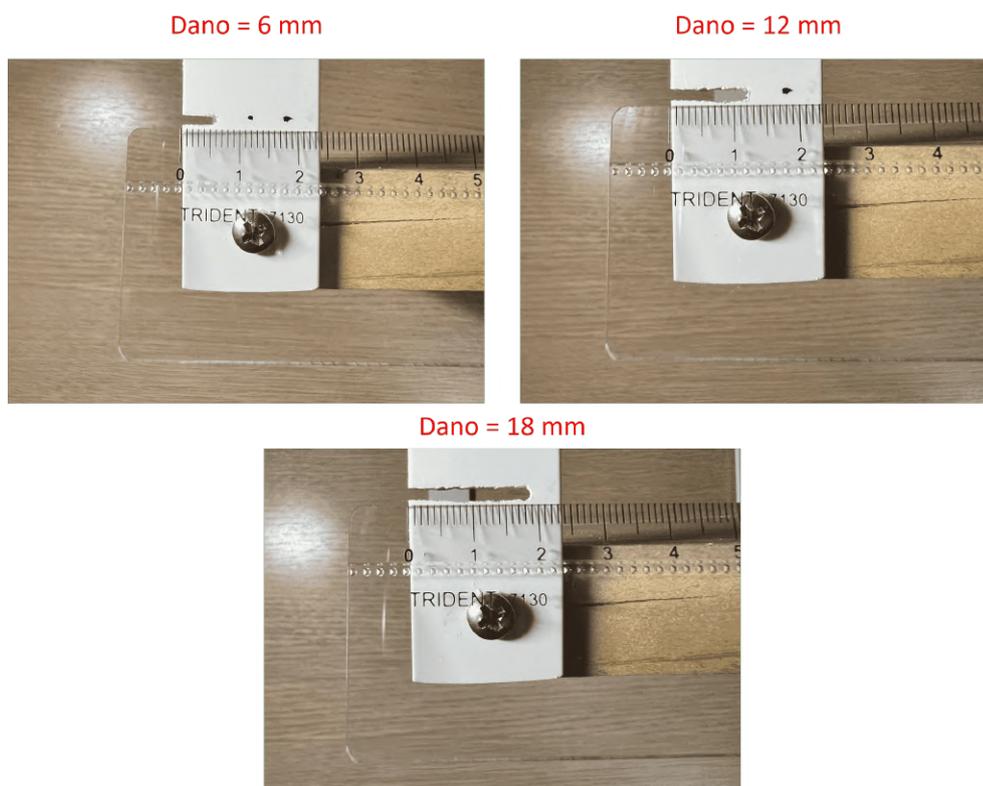
Após a realização dos testes iniciais com a estrutura em seu estado inicial, realizou-se o primeiro corte com uma serra e novas medições foram realizadas. O procedimento foi realizado para as diferentes dimensões de dano, crescendo sucessivamente de 6 em 6 mm com o intuito de simular um dano estrutural. Na Figura 20 é possível observar que a espessura do corte igual a 2 mm manteve-se constante em todos os cenários de dano, enquanto na Figura 21 são apresentados os comprimentos dos diferentes danos:

Figura 20 – Espessura do dano em diferentes cenários.



Fonte: Elaborada pelo próprio autor.

Figura 21 – Comprimentos considerados para os danos.

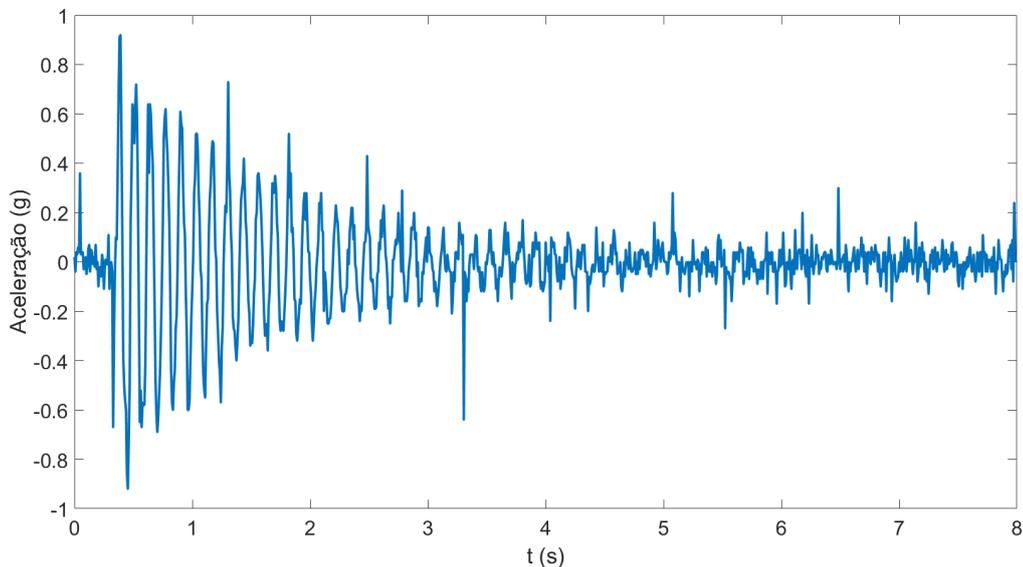


Fonte: Elaborada pelo próprio autor.

5 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos após a realização das etapas descritas no capítulo de Materiais e Métodos. Os valores de aceleração foram obtidos com a aplicação de uma força externa do tipo impulso sobre a estrutura, produzindo um sinal de vibração oscilatório com amortecimento total dentro do intervalo de tempo considerado para a amostragem. Um exemplo do comportamento vibratório pode ser visualizado na Figura 22, relativo à primeira amostra obtida com a estrutura sem danos.

Figura 22 – Resposta temporal à uma excitação externa.



Fonte: Elaborada pelo próprio autor.

Com o intuito de construir uma base de dados para o treinamento dos algoritmos de aprendizado de máquina, foram realizados diversos experimentos para as 4 condições de dano apresentadas. A quantidade de amostras adquiridas para cada condição pode ser verificada na Tabela 2:

Tabela 2 – Condições de dano e quantidade de amostras consideradas.

Condição	Dimensão do dano [mm]	Quantidade de amostras
1	0	109
2	6	134
3	12	139
4	18	163

Fonte: Elaborada pelo próprio autor.

É possível observar a presença de ruído e variações abruptas nos valores de aceleração ao longo do tempo. Isso se deve ao fato de que foram feitas medições com valores discretos

e com aproximações em relação à escala da verdadeira magnitude do sinal. Entretanto, tais irregularidades e desvios não impactam os resultados obtidos na resposta em frequência.

Na próxima seção são apresentadas os valores de frequências naturais obtidas com a transformada rápida de Fourier para os diferentes cenários de danos.

5.1 ANÁLISE DAS FREQUÊNCIAS NATURAIS E COEFICIENTES DE AMORTECIMENTO

As frequências naturais obtidas em cada cenário de dano apresentaram elevada consistência e baixa variância. É possível observar a diminuição dos valores de frequências naturais com o aumento da dimensão do dano na Tabela 3, sendo que os valores considerados para ω_n real são a moda de cada condição de dano.

Tabela 3 – Condições de dano e respectivas frequências naturais.

Condição	Dimensão do dano [mm]	ω_n real [Hz]
1	0	7,625
2	6	7,500
3	12	7,375
4	18	7,250

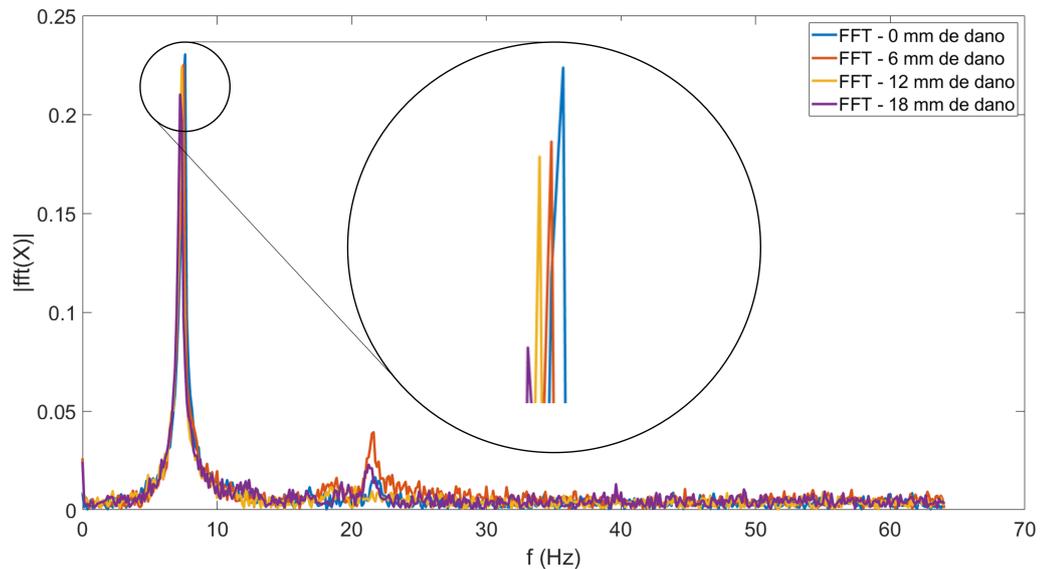
Fonte: Elaborada pelo próprio autor.

As diferenças entre os valores de frequências naturais para as respectivas dimensões de dano podem ser observadas no espectro em frequência apresentado na Figura 23, cujos dados foram extraídos de amostras escolhidas aleatoriamente. Ressalta-se que foram observadas pequenas variações entre amostras que apresentam a mesma dimensão de dano, cuja influência sobre o desempenho dos classificadores será discutida mais adiante.

As diferenças observadas entre os valores reais e àqueles obtidos com as simulações computacionais são justificadas pelas aproximações e hipóteses consideradas no modelo simulado. No entanto, foi possível constatar a diminuição dos valores conforme o aumento da dimensão do dano estrutural.

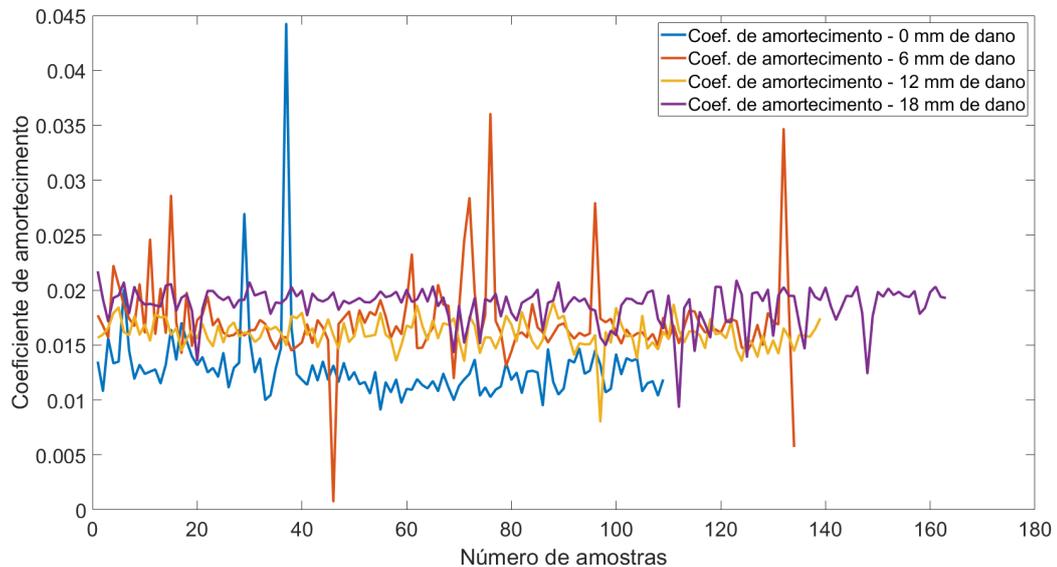
Os valores obtidos para os coeficientes de amortecimento também apresentaram variações, ocasionadas pela presença e dimensão dos danos. A representação gráfica das alterações pode ser observada na Figura 24, que contém todos os valores obtidos para as condições de dano consideradas neste trabalho. Nota-se que foram observados diferentes valores que podem ser considerados *outliers*, uma vez que estão fora de suas curvas e podem ser resultados de falhas nas medições devido à imprecisão do acelerômetro. Entretanto, cabe destacar a importância da representatividade dos dados, considerando que o melhor conjunto de dados para o treinamento de algoritmos de aprendizado de máquina é aquele que não apresenta *overfitting*, conforme mencionado no capítulo 3.

Figura 23 – Diferentes frequências naturais para cada cenário de dano.



Fonte: Elaborada pelo próprio autor.

Figura 24 – Variações nos valores de coeficientes de amortecimento para cada condição de dano.



Fonte: Elaborada pelo próprio autor.

5.2 ANÁLISE DE DESEMPENHO DOS CLASSIFICADORES

O treinamento dos classificadores foi realizado no aplicativo *Classification Learner* do *MATLAB* e as acurácias para os diferentes classificadores são apresentadas na Tabela 4. Os classificadores foram validados através do método de validação cruzada, criando-se 10 partições do conjunto de dados, sendo 75% de cada partição equivalente ao conjunto de treinamento e 25% correspondente ao conjunto de validação.

Tabela 4 – Acurácias obtidas pelos classificadores considerados.

Classificador	Acurácia [%]
<i>Fine Tree</i>	85,5
<i>Medium Tree</i>	85,9
<i>Coarse Tree</i>	85,5
<i>Linear Discriminant</i>	85,5
<i>Quadratic Discriminant</i>	85,1
<i>Gaussian Naïve Bayes</i>	-
<i>Kernel Naïve Bayes</i>	65,3
<i>Linear SVM</i>	85,0
<i>Quadratic SVM</i>	75,4
<i>Cubic SVM</i>	63,3
<i>Fine Gaussian SVM</i>	87,2
<i>Medium Gaussian SVM</i>	88,1
<i>Coarse Gaussian SVM</i>	85,7
<i>Fine KNN</i>	83,5
<i>Medium KNN</i>	86,8
<i>Coarse KNN</i>	85,9
<i>Cosine KNN</i>	80,4
<i>Cubic KNN</i>	86,8
<i>Weighted KNN</i>	83,7

Fonte: Elaborada pelo próprio autor.

Todas as variações dos classificadores apresentam diferenças quanto à função *kernel*, mencionada no capítulo 3. Neste trabalho, os resultados de acurácia obtidos são utilizados apenas como referência para determinar quais seriam avaliados detalhadamente. Cabe destacar que o foco do trabalho não é apresentar detalhes técnicos sobre as diferentes funções *kernel*, mas sim a aplicabilidade dos diferentes algoritmos em problemas de SHM. Em relação aos algoritmos adotados, destacam-se os seguintes pontos:

- Árvores de decisão e análise discriminante apresentam desempenhos constantes, independentemente da função *kernel*;
- *Naïve Bayes* apresenta desempenho inferior aos demais classificadores, sendo que um deles falhou;
- Nem todas as técnicas de SVM são adequadas, a acurácia do classificador varia dependendo da função *kernel*;
- KNN apresentam bom resultado, de modo geral.

É razoável afirmar que os classificadores Árvore de Decisão, Análise Discriminante e KNN poderiam ser escolhidos sem a necessidade de avaliar a acurácia de cada variação. Entretanto, os classificadores SVM requerem análise detalhada da influência da função *kernel*

sobre o desempenho final. Finalmente, pode-se afirmar que os algoritmos *Naïve Bayes* não são adequados para resolver problemas de SHM, pois os atributos escolhidos possuem relação de dependência. Conforme mencionado no capítulo 3, supõe-se que os atributos sejam independentes entre si para algoritmos que envolvem o Teorema de Bayes, caso contrário observa-se um comportamento similar à do treinamento que falhou.

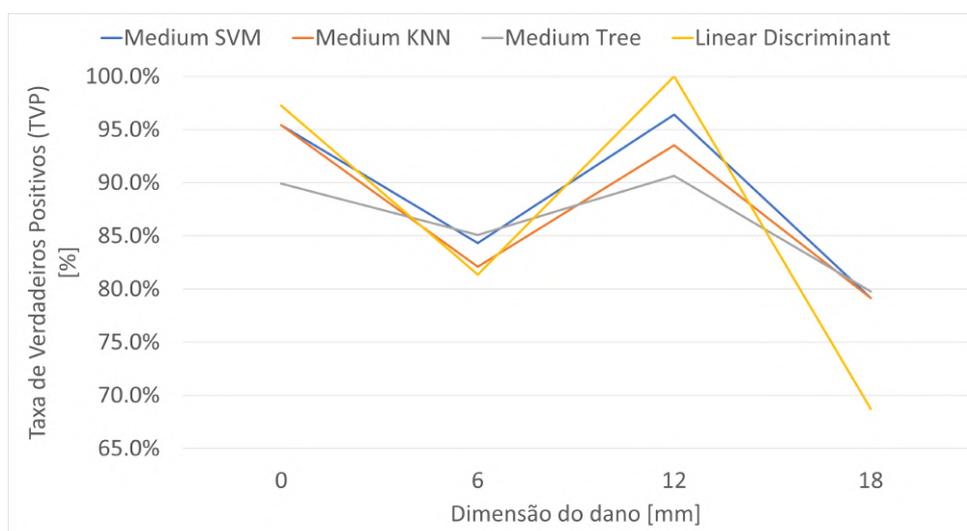
Os 4 melhores classificadores com maiores valores de acurácia foram escolhidos, sendo cada um de tipo distinto. Em seguida, são apresentados os valores obtidos para as métricas secundárias em função das diferentes dimensões de dano. Na Tabela 5 são apresentadas as TVP ou sensibilidades para os classificadores com os maiores valores de acurácia de cada modelo, enquanto na Figura 25 estão representados os mesmos valores de maneira gráfica.

Tabela 5 – TVP ou sensibilidades obtidas com os classificadores selecionados.

Dimensão do dano [mm]	Classificador			
	<i>Medium</i> <i>Gaussian SVM</i>	<i>Medium</i> <i>KNN</i>	<i>Medium</i> <i>Tree</i>	<i>Linear</i> <i>Discriminant</i>
	[%]	[%]	[%]	[%]
0	95,4	95,4	89,9	97,2
6	84,3	82,1	85,1	81,3
12	96,4	93,5	90,6	100
18	79,1	79,1	79,8	68,7

Fonte: Elaborada pelo próprio autor.

Figura 25 – Representação gráfica de TVP ou sensibilidades.



Fonte: Elaborada pelo próprio autor.

Os classificadores apresentam desempenhos similares, diferenciando-se sutilmente nos cenários de danos iguais a 6 e 12 mm. No entanto, nota-se a maior variação para o algoritmo

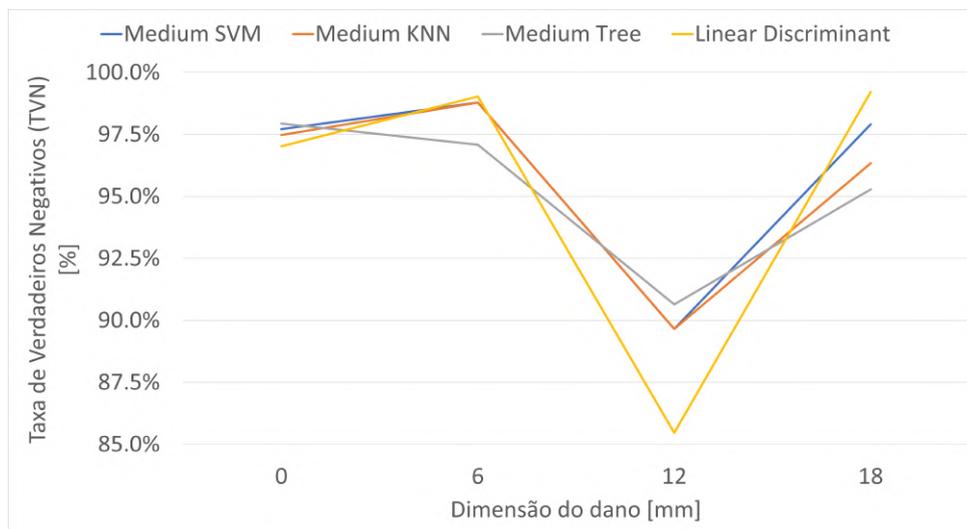
Linear Discriminant na condição de dano igual a 18 mm, indicando piora na capacidade de classificar os atributos às suas classes verdadeiras. Em sequência, estão representadas as TVN ou especificidades na Tabela 6 e sua forma gráfica pode ser observada na Figura 26:

Tabela 6 – TVN ou especificidades obtidas com os classificadores selecionados.

Dimensão do dano [mm]	Classificador			
	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Linear</i>
	<i>Gaussian SVM</i> [%]	<i>KNN</i> [%]	<i>Tree</i> [%]	<i>Discriminant</i> [%]
0	97,7	97,5	97,9	97,0
6	98,8	98,8	97,1	99,0
12	89,7	89,7	90,6	85,5
18	97,9	96,3	95,3	99,2

Fonte: Elaborada pelo próprio autor.

Figura 26 – Representação gráfica de TVN ou especificidades.



Fonte: Elaborada pelo próprio autor.

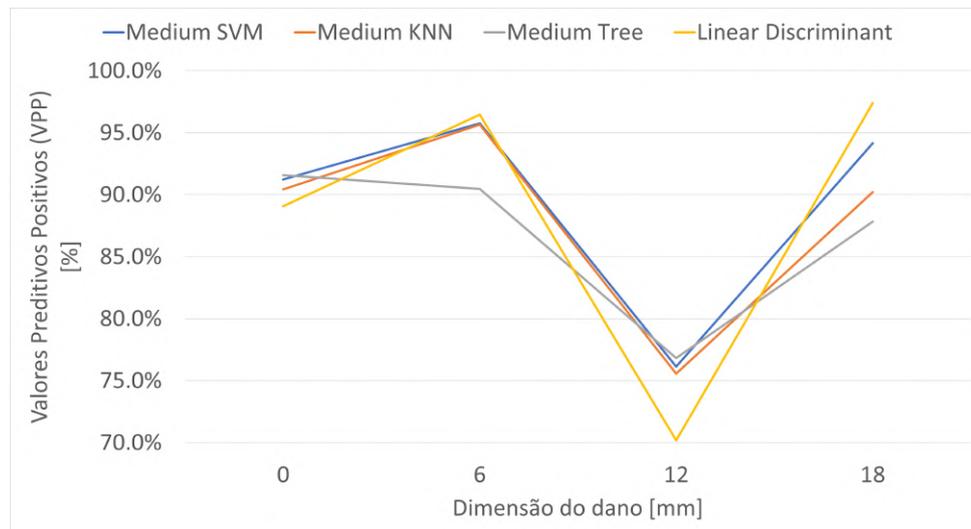
Os algoritmos são similares no quesito especificidade, que indica a capacidade de identificar atributos não-pertencentes às suas verdadeiras classes. Foram obtidos resultados satisfatórios, porém com desvio maior do classificador *Linear Discriminant* no cenário de dano igual a 12 mm. O mesmo fenômeno pode ser observado na comparação de VPP ou precisão na Tabela 7 e sua ilustração gráfica é apresentada na Figura 27:

Tabela 7 – VPP ou precissões obtidas com os classificadores selecionados.

Dimensão do dano [mm]	Classificador			
	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Linear</i>
	<i>Gaussian SVM</i> [%]	<i>KNN</i> [%]	<i>Tree</i> [%]	<i>Discriminant</i> [%]
0	91,2	90,4	91,6	89,1
6	95,8	95,7	90,5	96,5
12	76,1	75,6	76,8	70,2
18	94,2	90,2	87,8	97,4

Fonte: Elaborada pelo próprio autor.

Figura 27 – Representação gráfica de VPP ou precissões.



Fonte: Elaborada pelo próprio autor.

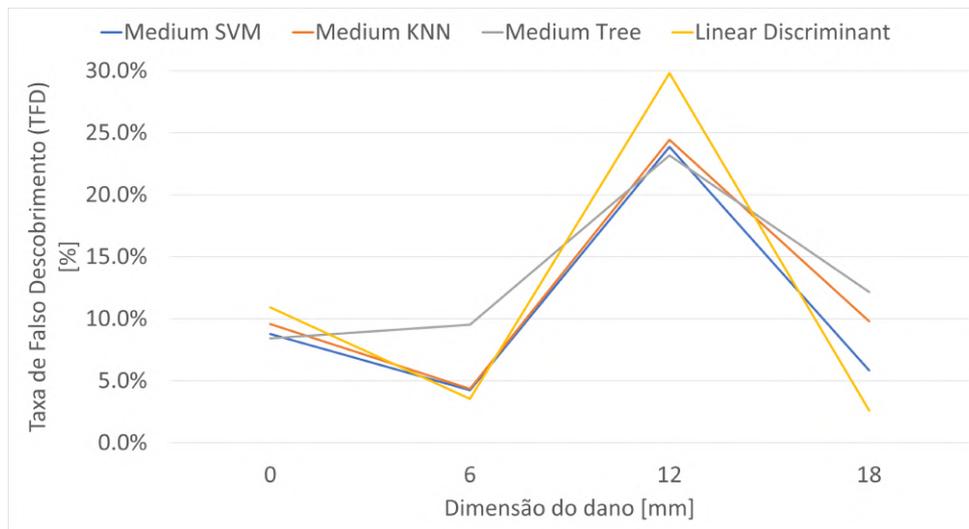
Os valores de TFD indicam o potencial de identificação de FPs, sendo o complemento do valor de VPP. O maior desvio é observado na condição de dano igual a 12 mm para o classificador *Linear Discriminant*. É plausível que tal diferença ocorra devido à baixa diferenciação das propriedades da estrutura nesta dimensão de dano em relação às demais, dificultando a classificação dos atributos. Outras hipóteses plausíveis são: a menor adequação do algoritmo ao modelo devido à determinação da fronteira que divide as classes e a quantidade limitada de dados analisados. Os resultados obtidos estão na Tabela 8 e representados na Figura 28:

Tabela 8 – TFD obtidas com os classificadores selecionados.

Dimensão do dano [mm]	Classificador			
	<i>Medium</i> <i>Gaussian SVM</i>	<i>Medium</i> <i>KNN</i>	<i>Medium</i> <i>Tree</i>	<i>Linear</i> <i>Discriminant</i>
	[%]	[%]	[%]	[%]
0	8,8	9,6	8,4	10,9
6	4,2	4,3	9,5	3,5
12	23,9	24,4	23,2	29,8
18	5,8	9,8	12,2	2,6

Fonte: Elaborada pelo próprio autor.

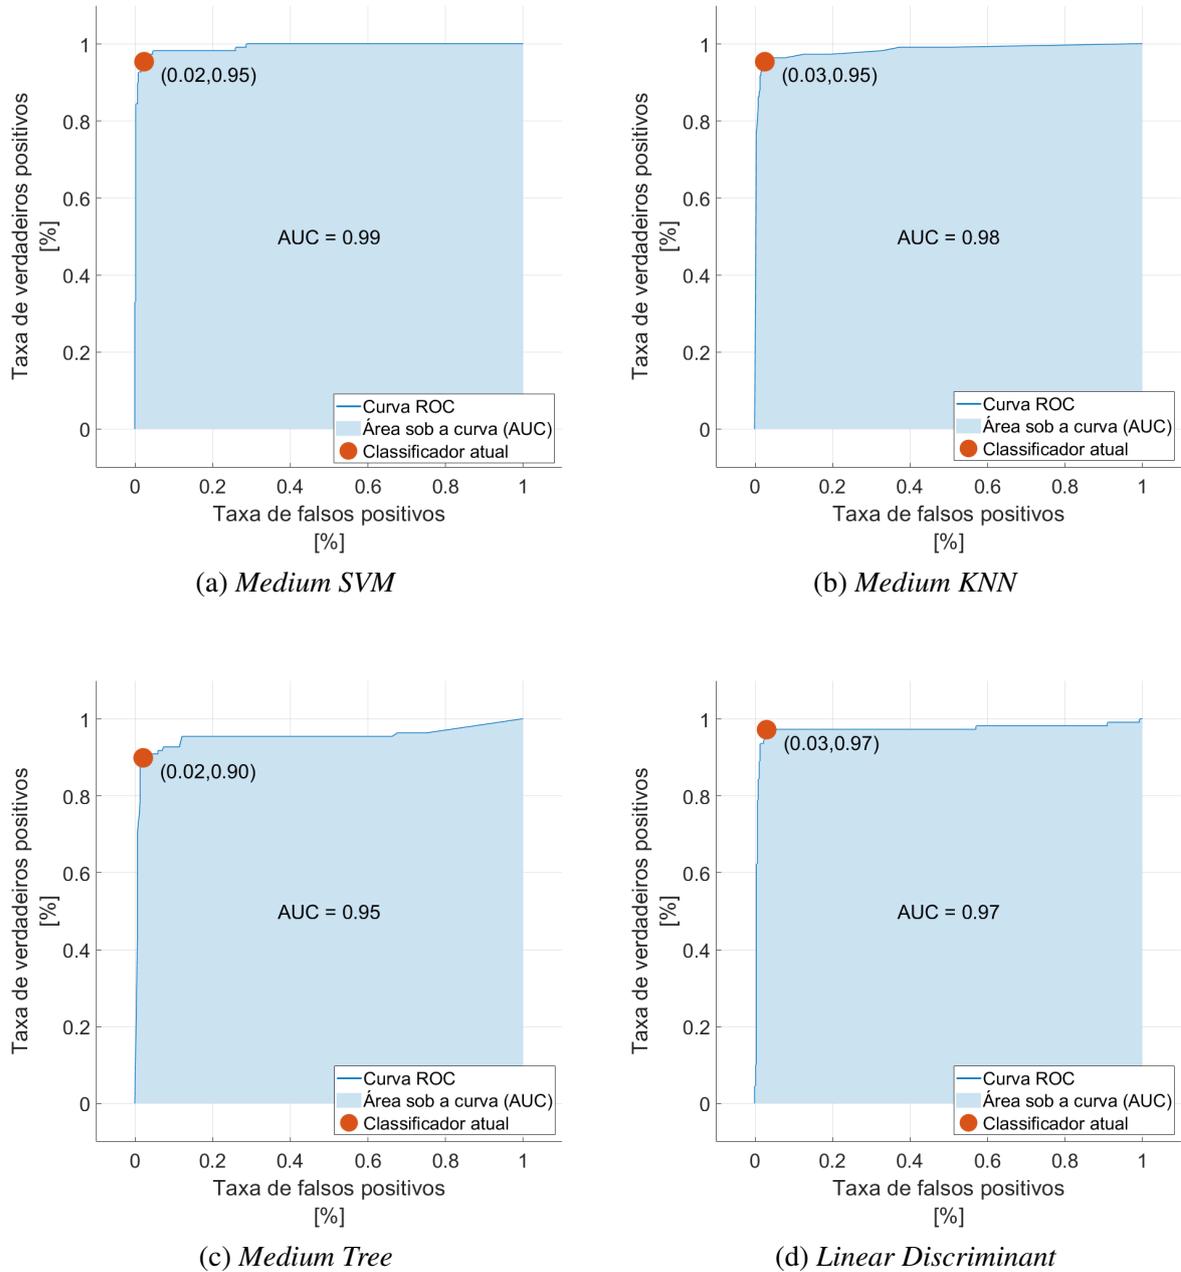
Figura 28 – Representação gráfica de TFD.



Fonte: Elaborada pelo próprio autor.

Finalmente, as curvas ROC e os valores de AUC obtidos para cada um dos classificadores foram comparados para avaliação de desempenho. São avaliados 4 cenários, variando-se a classe positiva e com as demais classes sendo negativas. A comparação das curvas é ilustrada na Figura 29, considerando-se os atributos referentes ao dano de 0 mm como sendo a classe positiva:

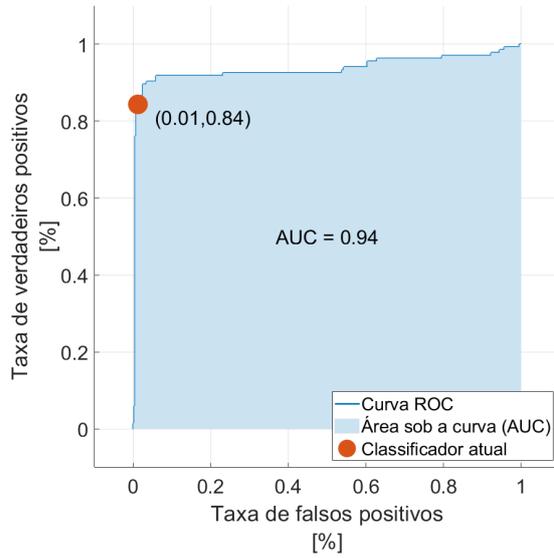
Figura 29 – Curvas ROC com 0 mm sendo a classe positiva



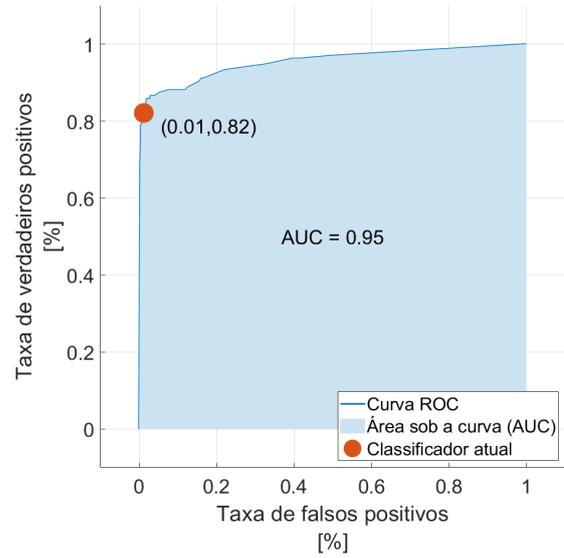
Fonte: Elaborada pelo próprio autor.

Observa-se que a classificação dos atributos extraídos da estrutura com dano igual a 0 mm é melhor com o classificador *Medium SVM*, pois o valor de AUC e a razão entre TVP e TFP são os maiores dentre todos para o classificador atual, isto é, com os parâmetros pré-estabelecidos. A mesma análise é apresentada na Figura 30, considerando-se que os atributos relativos ao dano de 6 mm pertencem à classe positiva:

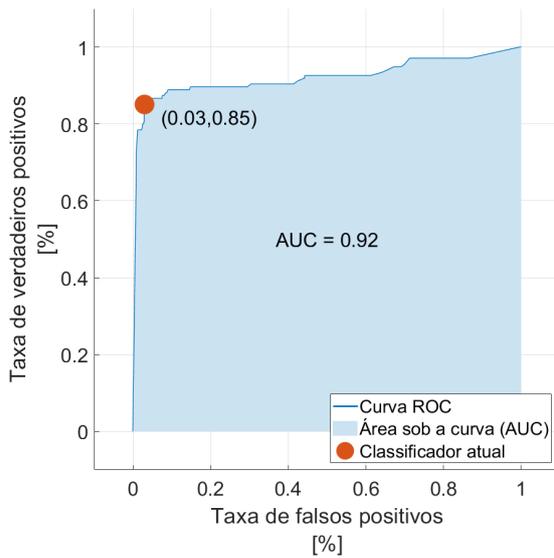
Figura 30 – Curvas ROC com 6 mm sendo a classe positiva



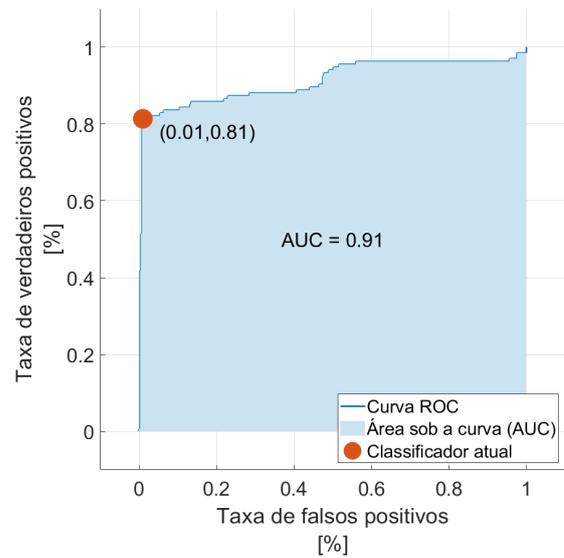
(a) *Medium SVM*



(b) *Medium KNN*



(c) *Medium Tree*

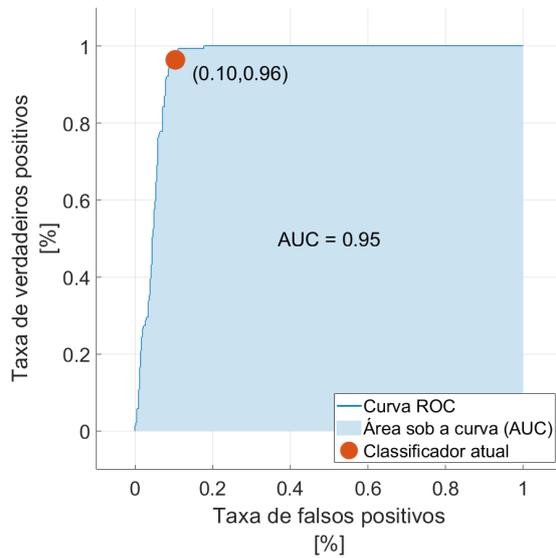


(d) *Linear Discriminant*

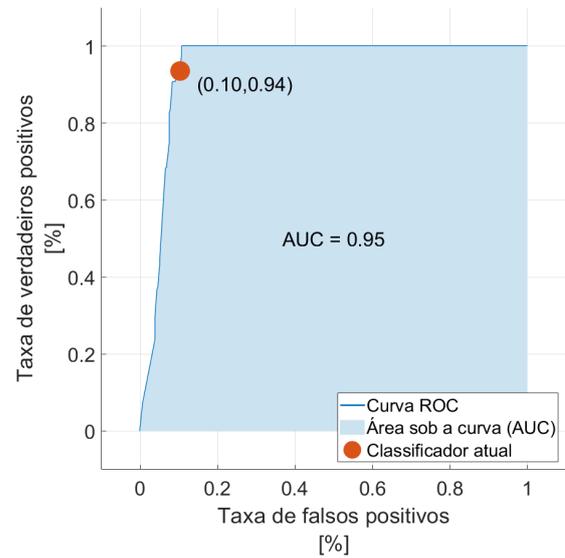
Fonte: Elaborada pelo próprio autor.

O algoritmo *Medium KNN* produz melhores resultados referentes à identificação de atributos referentes à classe de 6 mm, enquanto *Medium Tree* e *Linear Discriminant* apresentam queda no desempenho. A continuação da comparação é apresentada na Figura 31, levando-se em conta a classe de 12 mm como positiva:

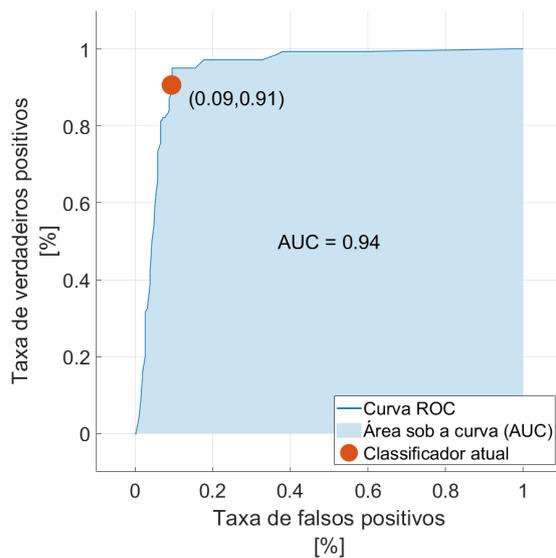
Figura 31 – Curvas ROC com 12 mm sendo a classe positiva



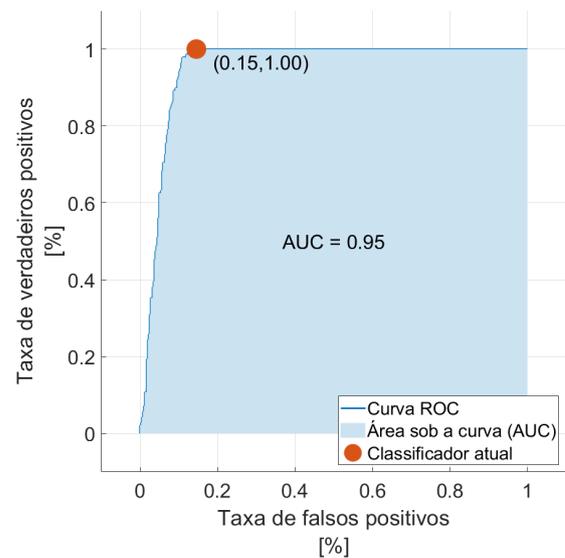
(a) *Medium SVM*



(b) *Medium KNN*



(c) *Medium Tree*

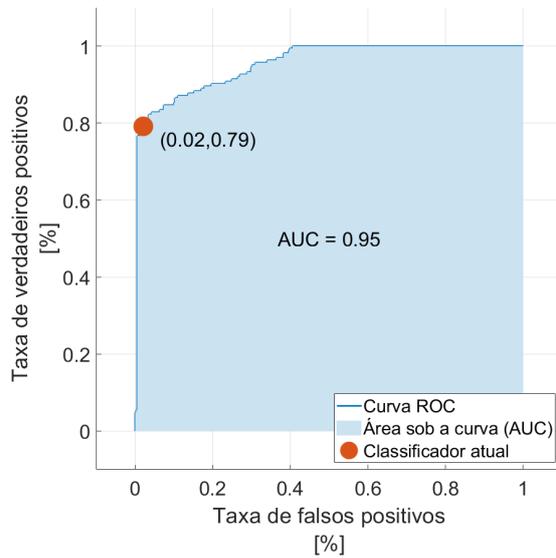


(d) *Linear Discriminant*

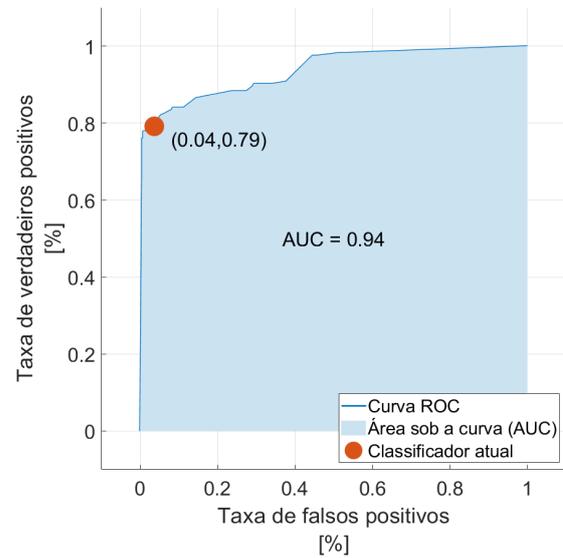
Fonte: Elaborada pelo próprio autor.

Os classificadores apresentam resultados semelhantes ao avaliarem os atributos pertencentes à classe de dano igual a 12 mm, porém nota-se o aumento da TFP para todos os classificadores. Portanto, pode-se afirmar que os atributos referentes aos danos de 12 mm são mais difíceis de serem distinguidos e são classificados incorretamente em uma proporção maior que os atributos de 0 e 6 mm. Na Figura 24 apresentada anteriormente, é possível confirmar tal hipótese devido à ausência de diferenças significativas entre os coeficientes de amortecimento dos cenários de dano iguais a 6 e 12 mm. A análise é concluída com os resultados obtidos ao considerar a classe de 18 mm como positiva na Figura 32:

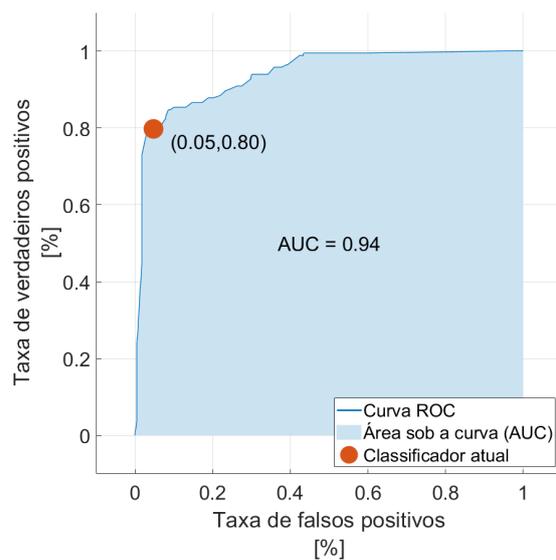
Figura 32 – Curvas ROC com 18 mm sendo a classe positiva



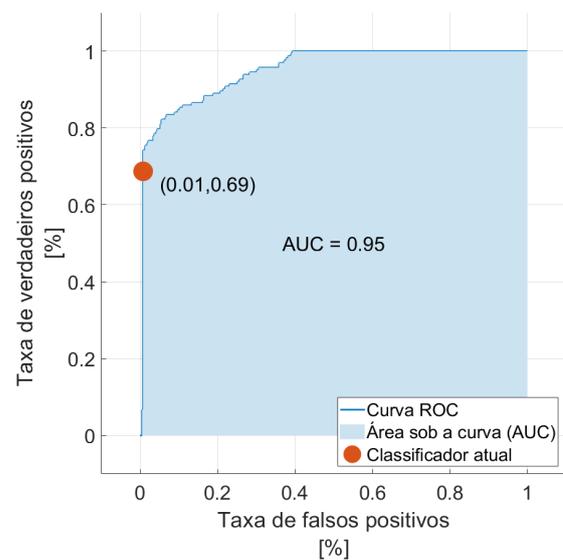
(a) *Medium SVM*



(b) *Medium KNN*



(c) *Medium Tree*



(d) *Linear Discriminant*

Fonte: Elaborada pelo próprio autor.

A diferença mais expressiva observada neste cenário de dano está na queda da TVP em todas as classificações, porém baixos valores de TFP. Isto significa que houve uma diminuição na capacidade de reconhecimento dos atributos pertencentes à classe de 18 mm, porém os atributos desta classe permanecem distinguíveis dos que percentem às demais condições de danos. Portanto, é possível concluir que os atributos considerados a partir das informações extraídas são suficientes para a aprendizagem dos algoritmos selecionados, possibilitando o monitoramento da integridade estrutural com técnicas de inteligência artificial.

6 CONCLUSÕES

A escolha do tema deste trabalho foi motivada pelo uso crescente de técnicas de reconhecimento de padrões em problemas associados à engenharia. O monitoramento da saúde estrutural através de MEMS foi abordado, considerando-se o baixo-custo e simplicidade dos materiais e equipamentos utilizados. Os diversos trabalhos publicados sobre este tópico confirmam a utilidade e eficiência deste tipo de sistema de sensoriamento para questões de SHM. Destaca-se que o presente estudo é considerado complementar às investigações conduzidas por (MELO, 2022) e (VASCONCELOS, 2023), cujo problema de SHM com sensoriamento de baixo-custo é abordado de maneiras distintas.

Com o intuito de avaliar a empregabilidade deste tipo de dispositivo para realizar o sensoriamento, uma bancada de experimentos foi projetada e construída, composta por uma estrutura de dois andares em escala. Foram feitas simulações computacionais da análise modal da estrutura, utilizadas como referências para os resultados esperados. Ao final do estudo, foi possível validar o modelo computacional elaborado, devido à proximidade entre os resultados das simulações e os reais.

As condições de dano induzidas à estrutura diferem entre si no quesito dimensão do dano, cuja expectativa é a influência proporcional sobre os valores dos atributos considerados. Com o aumento do comprimento de dano, variações foram manifestadas através do decréscimo do valor das frequências naturais, ao passo que houve um acréscimo nos valores dos coeficientes de amortecimento.

Ao revisar a literatura sobre os diferentes tipos de inteligência artificial, nota-se a disponibilidade de diversas técnicas. As possíveis variações de cada uma delas são amplamente utilizadas em problemas de SHM. No entanto, neste trabalho foram avaliadas apenas algumas delas e cujos algoritmos são fornecidos pelo aplicativo *Classification Learner* do *MATLAB*. Os algoritmos *Medium SVM* e *Medium KNN* apresentaram os melhores valores de acurácia, métricas extraídas da matriz de confusão e AUC, enquanto os demais classificadores *Medium Tree* e *Linear Discriminant* desempenharam similarmente entre si. Foi possível validar que o algoritmo *Naïve Bayes* não apresenta bons resultados quando os atributos escolhidos estão correlacionados. Destaca-se que a identificação dos danos é possível mesmo com um valor de acurácia máximo de 88,1%, pois as métricas secundárias apresentadas confirmam a capacidade de distinção entre as classes associadas às dimensões de danos. Conclui-se que, dependendo da dimensão do dano, foram observadas pequenas variações nos resultados de cada classificador que provavelmente surgiram de particularidades do conjunto de dados, como: estimativa de hipóteses, aproximações consideradas para simplificações e quantidade de amostras disponíveis.

Os objetivos do trabalho foram atingidos com a obtenção de resultados condizentes com

o esperado, validando a possibilidade de empregar as diferentes técnicas de aprendizado de máquina estudadas neste trabalho em problemas de SHM. É importante ressaltar que foram analisadas apenas técnicas de aprendizado supervisionado, que apresentam limitações quanto à classificação de novas amostras devido ao fato de que os conjuntos de treinamento e teste são baseados em observações previamente classificadas. Resultados melhores podem ser obtidos em estudos futuros com o uso de algoritmos de aprendizado de máquina não-supervisionado, validados em estruturas reais de maior escala, sujeitos às vibrações naturais e que não são excitadas por forças externas aplicadas manualmente. Os algoritmos podem ser otimizados com a escolha correta dos parâmetros da função *kernel*, assim como a construção de uma base de dados com múltiplos sensores implicaria na criação de um conjunto de dados de treinamento mais consistente para o aumento da eficiência dos algoritmos no reconhecimento de padrões.

REFERÊNCIAS

- ADAMS, D. **Health monitoring of structural materials and components: methods with applications**. [S.l.]: John Wiley & Sons, 2007. Citado 2 vezes nas páginas 14 e 33.
- ADDIN, O. et al. A naïve-bayes classifier for damage detection in engineering materials. **Materials & design**, Elsevier, v. 28, n. 8, p. 2379–2386, 2007. Citado na página 24.
- BALAGEAS, D.; FRITZEN, C.-P.; GÜEMES, A. **Structural health monitoring**. [S.l.]: John Wiley & Sons, 2010. v. 90. Citado na página 15.
- CHOLLET, F.; LIU, H. A (not so) short introduction to micro electro mechanical systems. **MEMS Encyclopedia**, 2013. Citado na página 17.
- COCHRAN, W. T. et al. What is the fast fourier transform? **Proceedings of the IEEE**, IEEE, v. 55, n. 10, p. 1664–1674, 1967. Citado na página 21.
- COOLEY, J. W.; TUKEY, J. W. An algorithm for the machine calculation of complex fourier series. **Mathematics of computation**, v. 19, n. 90, p. 297–301, 1965. Citado na página 21.
- DACKERMANN, U.; LI, J.; SAMALI, B. Identification of member connectivity and mass changes on a two-storey framed structure using frequency response functions and artificial neural networks. **Journal of Sound and Vibration**, Elsevier, v. 332, n. 16, p. 3636–3653, 2013. Citado na página 19.
- EFRON, B. Bayes' theorem in the 21st century. **Science**, American Association for the Advancement of Science, v. 340, n. 6137, p. 1177–1178, 2013. Citado na página 24.
- FAROOQ, M. et al. Damage detection and identification in smart structures using svm and ann. In: SPIE. **Smart Sensor Phenomena, Technology, Networks, and Systems Integration 2012**. [S.l.], 2012. v. 8346, p. 357–364. Citado na página 19.
- FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, The Royal Society London, v. 365, n. 1851, p. 303–315, 2007. Citado na página 14.
- FARRAR, C. R.; WORDEN, K. **Structural health monitoring: a machine learning perspective**. [S.l.]: John Wiley & Sons, 2012. Citado 2 vezes nas páginas 14 e 16.
- FIGUEIREDO, E.; SANTOS, A. Machine learning algorithms for damage detection. In: **Vibration-based techniques for damage detection and localization in engineering structures**. [S.l.]: World Scientific, 2018. p. 1–39. Citado na página 15.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, Wiley Online Library, v. 7, n. 2, p. 179–188, 1936. Citado na página 23.
- FLAH, M. et al. Machine learning algorithms in civil structural health monitoring: A systematic review. **Archives of computational methods in engineering**, Springer, v. 28, p. 2621–2643, 2021. Citado na página 18.
- HAK, M. Gad-el. **The MEMS handbook**. [S.l.]: CRC press, 2001. Citado na página 17.

- IBRAHIM, A. et al. A machine learning approach for structural health monitoring using noisy data sets. **IEEE Transactions on Automation Science and Engineering**, IEEE, v. 17, n. 2, p. 900–908, 2019. Citado na página 19.
- KHAN, A.; KIM, H. S. Classification and prediction of multidamages in smart composite laminates using discriminant analysis. **Mechanics of Advanced Materials and Structures**, Taylor & Francis, v. 29, n. 2, p. 230–240, 2022. Citado na página 19.
- KINGSFORD, C.; SALZBERG, S. L. What are decision trees? **Nature biotechnology**, Nature Publishing Group US New York, v. 26, n. 9, p. 1011–1013, 2008. Citado na página 23.
- KRAMER, O.; KRAMER, O. K-nearest neighbors. **Dimensionality reduction with unsupervised nearest neighbors**, Springer, p. 13–23, 2013. Citado 2 vezes nas páginas 26 e 27.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, SciELO Brasil, v. 35, p. 85–94, 2021. Citado na página 16.
- MACIOCE, P. Viscoelastic damping 101. **Sound and Vibration Magazine**, v. 4, p. 4–5, 2003. Citado na página 21.
- MARINIELLO, G. et al. Structural damage detection and localization using decision tree ensemble and vibration data. **Computer-Aided Civil and Infrastructure Engineering**, Wiley Online Library, v. 36, n. 9, p. 1129–1149, 2021. Citado na página 19.
- MELO, R. F. Monitoramento da integridade estrutural a partir de sensoriamento de baixo-custo: investigação de índices de dano e de efeitos de variáveis ambientais. Universidade Federal de São Carlos, 2022. Citado na página 51.
- MISHRA, S. et al. Regularized discriminant analysis for multi-sensor decision fusion and damage detection with lamb waves. In: SPIE. **Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016**. [S.l.], 2016. v. 9803, p. 728–741. Citado na página 23.
- MONARD, M. C.; BARANAUSKAS, J. A. Indução de regras e árvores de decisão. **Sistemas Inteligentes-fundamentos e aplicações**, sn, v. 1, p. 57–74, 2003. Citado 2 vezes nas páginas 22 e 23.
- NEWNHAM, R. E. **Properties of materials: anisotropy, symmetry, structure**. [S.l.]: Oxford university press, 2005. Citado na página 33.
- NICK, W. et al. A study of machine learning techniques for detecting and classifying structural damage. **International Journal of Machine Learning and Computing**, IACSIT Press, v. 5, n. 4, p. 313, 2015. Citado na página 19.
- NOBLE, W. S. What is a support vector machine? **Nature biotechnology**, Nature Publishing Group UK London, v. 24, n. 12, p. 1565–1567, 2006. Citado 3 vezes nas páginas 24, 25 e 26.
- PAPAGIANNPOULOS, G. A.; HATZIGEORGIOU, G. D. On the use of the half-power bandwidth method to estimate damping in building structures. **Soil Dynamics and Earthquake Engineering**, Elsevier, v. 31, n. 7, p. 1075–1079, 2011. Citado na página 21.
- PARK, S. et al. Pzt-based active damage detection techniques for steel bridge components. **Smart Materials and Structures**, IOP Publishing, v. 15, n. 4, p. 957, 2006. Citado na página 19.

- PEETERS, B.; MAECK, J.; ROECK, G. D. Vibration-based damage detection in civil engineering: excitation sources and temperature effects. **Smart materials and Structures**, IOP Publishing, v. 10, n. 3, p. 518, 2001. Citado na página 37.
- PÉREZ, D. G. et al. Diseño de una maqueta de bajo coste para shm. In: UNIVERSIDADE DA CORUÑA, SERVIZO DE PUBLICACIÓNS. **XL Jornadas de Automática**. [S.l.], 2019. p. 405–413. Citado na página 18.
- PETERSON, L. E. K-nearest neighbor. **Scholarpedia**, v. 4, n. 2, p. 1883, 2009. Citado na página 27.
- RAHAT, A. M.; KAHIR, A.; MASUM, A. K. M. Comparison of naive bayes and svm algorithm based on sentiment analysis using review dataset. In: IEEE. **2019 8th International Conference System Modeling and Advancement in Research Trends (SMART)**. [S.l.], 2019. p. 266–270. Citado na página 23.
- RIBEIRO, R. R.; LAMEIRAS, R. d. M. Evaluation of low-cost mems accelerometers for shm: Frequency and damping identification of civil structures. **Latin American Journal of Solids and Structures**, SciELO Brasil, v. 16, 2019. Citado na página 18.
- SABATO, A.; NIEZRECKI, C.; FORTINO, G. Wireless mems-based accelerometer sensor boards for structural vibration monitoring: A review. **IEEE Sensors Journal**, IEEE, v. 17, n. 2, p. 226–235, 2016. Citado na página 18.
- SAMMUT, C.; WEBB, G. I. **Encyclopedia of machine learning and data mining**. [S.l.]: Springer Publishing Company, Incorporated, 2017. Citado 2 vezes nas páginas 28 e 29.
- SHIKI, S. B.; FRANCO, V. R. Application of low-cost instrumentation and output-only modal identification techniques for the structural health monitoring of mechanical systems. **XLI Libero-Latin American Congress o Computational Methods in Engineering**, 2020. Citado na página 31.
- SOLBERG, H. E. Discriminant analysis. **CRC Critical Reviews in Clinical Laboratory Sciences**, Taylor & Francis, v. 9, n. 3, p. 209–242, 1978. Citado na página 23.
- SUN, L. et al. Review of bridge structural health monitoring aided by big data and artificial intelligence: From condition assessment to damage detection. **Journal of Structural Engineering**, American Society of Civil Engineers, v. 146, n. 5, p. 04020073, 2020. Citado 2 vezes nas páginas 18 e 37.
- SYSTEMS, E. **ESP32-WROOM-32 Datasheet**. [S.l.]: Espressif Systems Shanghai CN, 2021. Citado na página 35.
- TANIDA, R. et al. Wooden framed house structural health monitoring by system identification and damage detection under dynamic motion with artificial intelligence sensor using a model of house including braces. In: IEEE. **2018 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)**. [S.l.], 2018. p. 1–5. Citado na página 19.
- VARANIS, M. et al. Memes accelerometers for mechanical vibrations analysis: A comprehensive review with applications. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 40, p. 1–18, 2018. Citado na página 35.

VASCONCELOS, J. P. C. Monitoramento da integridade estrutural a partir de sensoriamento de baixo-custo: projeto e desenvolvimento de bancada experimental integrada a plataforma de computação em nuvem. Universidade Federal de São Carlos, 2023. Citado na página 51.

ZHANG, Z. Introduction to machine learning: k-nearest neighbors. **Annals of translational medicine**, AME Publications, v. 4, n. 11, 2016. Citado na página 27.

APÊNDICE A – ROTINA UTILIZADA PARA AQUISIÇÃO DE ACELERAÇÕES

```

#define Fs 128.0          // Frequência de amostragem
#define  NFFT 1024       // Número de pontos na amostra
float T = pow(10,6)/Fs; // Tempo de duração de cada amostra

int xpin = A0; // x-axis of the accelerometer

int i;
int temp;
unsigned long last_us = 0;

int xvalue;

void setup()
{
  Serial.begin(115200);
  Serial.println("Aceleração em X [g]");
}

void loop()
{

  Serial.println("");
  Serial.println("CONTAGEM REGRESSIVA PARA MEDICAO");
  Serial.println("5");
  delay(1000);
  Serial.println("4");
  delay(1000);
  Serial.println("3");
  delay(1000);
  Serial.println("2");
  delay(1000);
  Serial.println("1");
  delay(1000);
  Serial.println("FAZENDO MEDICAO (aprox. 8 segundos)");

  last_us=micros();

```

```
for (i=0;i<NFFT;i++)
{
    temp = micros()-last_us;
    // Tempo decorrido em relação ao início da aquisição
    if (temp>=T)
    // Se tempo é maior ou igual ao período de amostragem, captura dado do sensor
    {
        last_us += T;
        xvalue = analogRead(xpin);
        //Leitura da aceleração e registro da medida na direção X
        int x = map(xvalue, 1456, 2256, -100, 100);
        //Delimitação dos valores analógicos extremos para -100 e 100
        float xg = (float)x/(-100.00);
        //Conversão do valores mapeados para aceleração em termos de "g"
        Serial.print(xg);
        Serial.print(",");
    }
    else if (temp < T)
    // Se tempo for menor continua esperando ate dar o periodo de amostragem
    {
        i = i - 1;
    }
}
}
```

APÊNDICE B – ROTINA UTILIZADA NO *MATLAB* PARA PROCESSAMENTO E EXTRAÇÃO DE ATRIBUTOS

```

clc;
clear all;

Fs = 128;
NFFT = 1024;
T = 1/Fs;
t = (0:(NFFT-1))*T;
line = 1;

M_0 = readmatrix('C:\Users\Rodrigo\OneDrive\Área de Trabalho
\TCC\ESP32\0_mm_Post.csv');
M_6 = readmatrix('C:\Users\Rodrigo\OneDrive\Área de Trabalho
\TCC\ESP32\6_mm_Post.csv');
M_12 = readmatrix('C:\Users\Rodrigo\OneDrive\Área de Trabalho
\TCC\ESP32\12_mm_Post.csv');
M_18 = readmatrix('C:\Users\Rodrigo\OneDrive\Área de Trabalho
\TCC\ESP32\18_mm_Post.csv');

f = (Fs/NFFT)*(0:(NFFT/2));

%% Frequências naturais - 0 mm de dano

tam_0 = size(M_0);

for i = 1:tam_0(1,1)
    MFFT (i,:) = fft(M_0(i,:));
end

X_norm = abs(MFFT/NFFT);
P1_0 = X_norm(:,1:NFFT/2+1);
P1_0(:,2:end-1) = 2*P1_0(:,2:end-1);
peak_y = (max(P1_0, [], 2));

for j = 1:tam_0(1,1)

```

```
    faux1 = find(peak_y(j,1) == P1_0(j,:));
    peak_x_min (j,1) = min(faux1);
    wn0_aux (j,1) = f(peak_x_min(j));
end

figure(1);
plot(f,P1_0(line,:), "LineWidth",3)
title("Espectro de amplitude unilateral de X(t)")
xlabel("f (Hz)")
ylabel("|P1(f)|")

%% Cálculo do coeficiente de amortecimento - 0 mm de dano

for k = 1:tam_0(1,1)
    [bw_0(k,1),flo_0(k,1),fhi_0(k,1),power_0(k,1)] = powerbw(M_0(k,:),Fs);
    xi_0(k,1) = bw_0(k,1)/(2*wn0_aux(k,1));
end

MFFT_0_aux = MFFT(:,1:NFFT/2+1);
psdx = (1/(Fs*NFFT)) * abs(MFFT_0_aux).^2;
psdx(:,2:end-1) = 2*psdx(:,2:end-1);

figure(2);
powerbw(M_0(line,:),Fs)
grid on

figure(3);
plot(f,pow2db(psd(line,:)))
grid on
title("Periodograma utilizando a FFT")
xlabel("Frequência (Hz)")
ylabel("Potência/Frequência (dB/Hz)")

%% Criando o vetor de atributos - 0 mm de dano

wn0(:,1) = wn0_aux;
wn0(:,2) = xi_0;
wn0(:,3) = 0;
```

```

%% Frequências naturais - 6 mm de dano

tam_6 = size(M_6);

for i = 1:tam_6(1,1)
    MFFT (i,:) = fft(M_6(i,:));
end

X_norm = abs(MFFT/NFFT);
P1_6 = X_norm(:,1:NFFT/2+1);
P1_6(:,2:end-1) = 2*P1_6(:,2:end-1);
peak_y = (max(P1_6,[],2));

for j = 1:tam_6(1,1)
    faux1 = find(peak_y(j,1) == P1_6(j,:));
    peak_x_min (j,1) = min(faux1);
    wn6_aux (j,1) = f(peak_x_min(j));
end

figure(4);
plot(f,P1_6(line,:), "LineWidth",3)
title("Espectro de amplitude unilateral de X(t)")
xlabel("f (Hz)")
ylabel("|P1(f)|")

%% Cálculo do coeficiente de amortecimento - 6 mm de dano

for k = 1:tam_6(1,1)
    [bw_6(k,1),flo_6(k,1),fhi_6(k,1),power_6(k,1)] = powerbw(M_6(k,:),Fs);
    xi_6(k,1) = bw_6(k,1)/(2*wn6_aux(k,1));
end

MFFT_6_aux = MFFT(:,1:NFFT/2+1);
psdx = (1/(Fs*NFFT)) * abs(MFFT_6_aux).^2;
psdx(:,2:end-1) = 2*psdx(:,2:end-1);

figure(5);
powerbw(M_6(line,:),Fs)
grid on

```

```
figure(6);
plot(f,pow2db(psd(line,:)))
grid on
title("Periodograma utilizando a FFT")
xlabel("Frequência (Hz)")
ylabel("Potência/Frequência (dB/Hz)")

% Criando o vetor de atributos - 6 mm de dano

wn6(:,1) = wn6_aux;
wn6(:,2) = xi_6;
wn6(:,3) = 6;

% Frequências naturais - 12 mm de dano

tam_12 = size(M_12);

for i = 1:tam_12(1,1)
    MFFT (i,:) = fft(M_12(i,:));
end

X_norm = abs(MFFT/NFFT);
P1_12 = X_norm(:,1:NFFT/2+1);
P1_12(:,2:end-1) = 2*P1_12(:,2:end-1);
peak_y = (max(P1_12, [], 2));

for j = 1:tam_12(1,1)
    faux1 = find(peak_y(j,1) == P1_12(j,:));
    peak_x_min (j,1) = min(faux1);
    wn12_aux (j,1) = f(peak_x_min(j));
end

figure(7);
plot(f,P1_12(line,:), "LineWidth", 3)
title("Espectro de amplitude unilateral de X(t)")
xlabel("f (Hz)")
ylabel("|P1(f)|")
```

```
% Cálculo do coeficiente de amortecimento - 12 mm de dano

for k = 1:tam_12(1,1)
    [bw_12(k,1),flo_12(k,1),fhi_12(k,1),power_12(k,1)] = powerbw(M_12(k,:),Fs);
    xi_12(k,1) = bw_12(k,1)/(2*wn12_aux(k,1));
end

MFFT_12_aux = MFFT(:,1:NFFT/2+1);
psdx = (1/(Fs*NFFT)) * abs(MFFT_12_aux).^2;
psdx(:,2:end-1) = 2*psdx(:,2:end-1);

figure(8);
powerbw(M_12(line,:),Fs)
grid on

figure(9);
plot(f,pow2db(psd(line,:)))
grid on
title("Periodograma utilizando a FFT")
xlabel("Frequência (Hz)")
ylabel("Potência/Frequência (dB/Hz)")

%% Criando o vetor de atributos - 12 mm de dano

wn12(:,1) = wn12_aux;
wn12(:,2) = xi_12;
wn12(:,3) = 12;

%% Frequências naturais - 18 mm de dano

tam_18 = size(M_18);

for i = 1:tam_18(1,1)
    MFFT (i,:) = fft(M_18(i,:));
end

X_norm = abs(MFFT/NFFT);
P1_18 = X_norm(:,1:NFFT/2+1);
P1_18(:,2:end-1) = 2*P1_18(:,2:end-1);
```

```
peak_y = (max(P1_18, [], 2));

for j = 1:tam_18(1,1)
    faux1 = find(peak_y(j,1) == P1_18(j,:));
    peak_x_min (j,1) = min(faux1);
    wn18_aux (j,1) = f(peak_x_min(j));
end

figure(10);
plot(f,P1_18(line,:), "LineWidth",3)
title("Espectro de amplitude unilateral de X(t)")
xlabel("f (Hz)")
ylabel("|P1(f)|")

%% Cálculo do coeficiente de amortecimento - 18 mm de dano

for k = 1:tam_18(1,1)
    [bw_18(k,1),flo_18(k,1),fhi_18(k,1),power_18(k,1)] = powerbw(M_18(k,:),Fs);
    xi_18(k,1) = bw_18(k,1)/(2*wn18_aux(k,1));
end

MFFT_18_aux = MFFT(:,1:NFFT/2+1);
psdx = (1/(Fs*NFFT)) * abs(MFFT_18_aux).^2;
psdx(:,2:end-1) = 2*psdx(:,2:end-1);

figure(11);
powerbw(M_18(line,:),Fs)
grid on

figure(12);
plot(f,pow2db(psdx(line,:)))
grid on
title("Periodograma utilizando a FFT")
xlabel("Frequência (Hz)")
ylabel("Potência/Frequência (dB/Hz)")

%% Criando o vetor de atributos - 18 mm de dano

wn18(:,1) = wn18_aux;
```

```
wn18(:,2) = xi_18;
wn18(:,3) = 18;

%% Plotando as ffts de uma amostra x qualquer

figure(13);
plot(f,P1_0(line,:), "LineWidth",3)
hold on
plot(f,P1_6(line,:), "LineWidth",3)
hold on
plot(f,P1_12(line,:), "LineWidth",3)
hold on
plot(f,P1_18(line,:), "LineWidth",3)

set(gca,'fontsize',24)
xlabel("f (Hz)")
ylabel("|fft(X)|")
legend('FFT - 0 mm de dano', 'FFT - 6 mm de dano',
'FFT - 12 mm de dano', 'FFT - 18 mm de dano')

%% Plotando a variação dos coeficientes de amortecimento

figure(14);
plot((1:109),xi_0(:,1), "LineWidth",3)
hold on
plot((1:134),xi_6(:,1), "LineWidth",3)
hold on
plot((1:139),xi_12(:,1), "LineWidth",3)
hold on
plot((1:163),xi_18(:,1), "LineWidth",3)

set(gca,'fontsize',24)
xlabel("Número de amostras")
ylabel("Coeficiente de amortecimento")
legend('Coef. de amortecimento - 0 mm de dano',
'Coef. de amortecimento - 6 mm de dano',
'Coef. de amortecimento - 12 mm de dano',
'Coef. de amortecimento - 18 mm de dano')
```

```
%% Juntando tudo em apenas um vetor
```

```
wn = [wn0; wn6; wn12; wn18];
```

```
figure(14);
```

```
plot(t,M_0(line,:), "LineWidth",3)
```

```
set(gca, 'fontsize',24)
```

```
xlabel("t (s)")
```

```
ylabel("Aceleração (g)")
```