



**DANIELA SEDA SALGADO DE BRITO**

**METODOLOGIA PARA O MONITORAMENTO DE  
INTEGRIDADE ESTRUTURAL POR MEIO DE VIBRAÇÕES  
MECÂNICAS**

**LAVRAS - MG  
2025**

**DANIELA SEDA SALGADO DE BRITO**

**METODOLOGIA PARA O MONITORAMENTO DE INTEGRIDADE  
ESTRUTURAL POR MEIO DE VIBRAÇÕES MECÂNICAS**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para a obtenção do título de Doutora.

Orientador  
Prof. Dr. Fábio Lúcio Santos

Coorientador  
Prof. Dr. Paulo de Oliveira Lima Junior

**LAVRAS - MG  
2025**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Brito, Daniela Seda Salgado de.

Metodologia para o monitoramento de integridade estrutural por meio de vibrações mecânicas / Daniela Seda Salgado de Brito. – 2025.

96 p. : il.

Orientador: Fábio Lúcio Santos.

Coorientador: Paulo de Oliveira Lima Junior.

Tese (Doutorado) - Universidade Federal de Lavras, 2025.

Bibliografia.

1. Análise modal. 2. Redes neurais artificiais. 3. Detecção de danos. I. Santos, Fábio Lúcio. II. Lima Junior, Paulo de Oliveira. III. Título.

**DANIELA SEDA SALGADO DE BRITO**

**METODOLOGIA PARA O MONITORAMENTO DE INTEGRIDADE ESTRUTURAL  
POR MEIO DE VIBRAÇÕES MECÂNICAS**

**METHODOLOGY FOR STRUCTURAL HEALTH MONITORING THROUGH  
MECHANICAL VIBRATIONS**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para a obtenção do título de Doutora.

APROVADA em 30 de junho de 2025.

Dr. Paulo de Oliveira Lima Junior      CEFET/MG

Dr. Túlio de Almeida Machado      IFGoiano

Dr. Paulo Roberto Borges      UFLA

Dra. Nara Silveira Velloso      UFS

  
Orientador

Prof. Dr. Fábio Lúcio Santos

Coorientador

Prof. Dr. Paulo de Oliveira Lima Junior

**LAVRAS - MG  
2025**

*À minha mãe  
Maria Aparecida Seda  
pelo exemplo de vida e incentivo.*

*A minha filha  
Anna Elisa Sêda Tenório de Brito*

*Ao meu esposo  
Waldir Jr de Carvalho Tenório de Brito*

*Aos meus irmãos  
Juliana, Rita Helena, Teo e Giovana*

*Dedico*

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus, pela direção e força concedidas ao longo desta trajetória acadêmica.

À minha mãe, Maria Aparecida Seda, pelo exemplo de determinação, ética e pelo constante incentivo aos estudos.

À minha filha, Anna Elisa, cuja presença, ainda que à distância, foi fonte permanente de motivação durante todo o desenvolvimento deste trabalho.

Ao meu esposo, Waldir Júnior, pelo apoio direto na execução do protótipo e nos ensaios experimentais, fundamentais para a conclusão desta pesquisa.

Aos meus irmãos, Juliana, Rita Helena, Teo e Giovana, pelo suporte afetivo e encorajamento contínuo.

Ao meu orientador Fábio e ao meu coorientador Paulo, pela orientação técnica, pela confiança no projeto e pelas contribuições valiosas durante todas as etapas deste estudo.

Agradeço à Universidade Federal de Lavras (UFLA) pelo apoio institucional e pela oportunidade de desenvolvimento científico.

## RESUMO

A integridade estrutural de pontes é fundamental para garantir a segurança e a durabilidade das obras civis, especialmente em regiões sujeitas a condições adversas. No entanto, métodos tradicionais de inspeção muitas vezes são demorados, dispendiosos e invasivos, o que tem impulsionado o desenvolvimento de técnicas não destrutivas baseadas na análise dinâmica das estruturas. Nesse contexto, o Monitoramento da Integridade Estrutural (Structural Health Monitoring – SHM), que combina medições de vibração com inteligência artificial, surge como uma alternativa promissora para a detecção e classificação de danos de forma rápida, precisa e automatizada. Com base nessa abordagem, o objetivo principal deste trabalho foi desenvolver uma metodologia eficiente para a detecção de danos em pontes por meio da análise de vibrações mecânicas. Para alcançar esse propósito, foram estabelecidos protocolos de medição em laboratório, construído um modelo físico em escala reduzida de uma ponte, realizadas análises das respostas dinâmicas e aplicadas técnicas de inteligência artificial para a identificação e classificação da severidade dos danos estruturais. A metodologia proposta foi inicialmente validada por meio de ensaios em vigas de madeira com defeitos simulados, o que possibilitou a criação de um banco de dados robusto e representativo para o treinamento de Redes Neurais Artificiais (RNAs). Foram testadas três ponteiras (plástica, metálica e de borracha), com variações de dano por entalhes e diferentes configurações de neurônios na camada oculta (de 5 a 200). Os melhores resultados foram obtidos com a ponteira plástica, com acurácia variando entre 0,85 e 0,90 e coeficiente kappa entre 0,77 e 0,87, destacando-se as configurações com 25 a 35 neurônios. As ponteiras de borracha e metálica também apresentaram desempenho sólido, com acurácia entre 0,82 e 0,88, e kappa entre 0,70 e 0,87, dependendo da configuração adotada. Posteriormente, a abordagem foi aplicada a um protótipo de ponte em concreto armado, também em escala reduzida, equipado com 12 acelerômetros estrategicamente posicionados e submetido a excitações controladas com martelo de impacto. Essa aplicação prática permitiu avaliar o desempenho da metodologia em um sistema estrutural mais complexo e realista. Os ensaios modais revelaram que os valores máximos de resposta dos acelerômetros apresentaram variações importantes com a progressão dos defeitos induzidos. Por exemplo, o acelerômetro Ac2 mostrou aumento dos valores de resposta de 0,92 (intacto) para 1,17 (seção 4), enquanto o Ac7 variou de 0,54 (intacto) para 0,65 (seção 4). Em contrapartida, alguns sensores, como o Ac5, exibiram redução acentuada na resposta, com valores caindo de 1,45 (intacto) para 0,03 (seção 4), indicando perda de rigidez estrutural local. Apesar da metodologia demonstrar eficácia na identificação das alterações dinâmicas no protótipo, a rede neural artificial (RNA) apresentou desempenho inicial satisfatório (acurácia de 57,14% e Kappa de 0,36), com destaque para a correta identificação dos danos mais severos (Seção 4), cuja sensibilidade foi de 66,7% e valor preditivo positivo de 100%. A limitação nos resultados das demais classes está relacionada à pequena variedade de danos aplicados. A expectativa é que, com a introdução de novos cenários de dano, o modelo aprimore seu aprendizado e aumente sua acurácia de forma significativa.

**Palavras-chave:** análise modal; redes neurais artificiais; detecção de danos; monitoramento estrutural; estruturas em escala reduzida; protótipo.

## ABSTRACT

Structural integrity of bridges is essential to ensure the safety and durability of civil engineering works, especially in regions subject to adverse conditions. However, traditional inspection methods are often time-consuming, costly, and invasive, which has driven the development of non-destructive techniques based on dynamic structural analysis. In this context, Structural Health Monitoring (SHM), which combines vibration measurements with artificial intelligence, emerges as a promising alternative for rapid, accurate, and automated damage detection and classification. Based on this approach, the main objective of this study was to develop an efficient methodology for damage detection in bridges through the analysis of mechanical vibrations. To achieve this goal, laboratory measurement protocols were established, a physical scaled-down bridge model was constructed, dynamic response analyses were carried out, and artificial intelligence techniques were applied to identify and classify the severity of structural damage. The proposed methodology was initially validated through tests on wooden beams with simulated defects, which enabled the creation of a robust and representative dataset for training Artificial Neural Networks (ANNs). Three hammer tips (plastic, metal, and rubber) were tested, with damage simulated by notches and different numbers of hidden layer neurons (ranging from 5 to 200). The best results were obtained using the plastic hammer tip, with accuracy ranging from 0.85 to 0.90 and kappa coefficient between 0.77 and 0.87, particularly with configurations of 25 to 35 neurons. The rubber and metal tips also showed solid performance, with accuracy between 0.82 and 0.88, and kappa values between 0.70 and 0.87, depending on the configuration. Subsequently, the approach was applied to a reinforced concrete bridge prototype, also at a reduced scale, equipped with 12 strategically positioned accelerometers and subjected to controlled excitations using an impact hammer. This practical application allowed the methodology's performance to be assessed in a more complex and realistic structural system. Modal testing revealed that the peak response values of the accelerometers varied significantly with the progression of the notches. For example, accelerometer Ac2 showed an increase in response values from 0.92 (undamaged) to 1.17 (section 4), while Ac7 ranged from 0.54 (undamaged) to 0.65 (section 4). In contrast, some sensors such as Ac5 exhibited a sharp reduction in response, with values dropping from 1.45 (undamaged) to 0.03 (section 4), indicating localized loss of structural stiffness. Although the methodology proved effective in identifying dynamic changes in the prototype, the artificial neural network (ANN) showed an initially satisfactory performance (accuracy of 57.14% and Kappa of 0.36), with emphasis on the correct identification of the most severe damages (Section 4), which had a sensitivity of 66.7% and a positive predictive value of 100%. The limitation in the results of the other classes is related to the small variety of applied damages. It is expected that, with the introduction of new damage scenarios, the model will improve its learning and significantly increase its accuracy.

**Keywords:** modal analysis; artificial neural networks; damage detection; structural health monitoring; reduced-scale structures; prototype.

## INDICADORES DE IMPACTO

A presente tese desenvolveu uma metodologia para o monitoramento da integridade estrutural por meio de vibrações mecânicas associadas a técnicas de inteligência artificial, com o objetivo de identificar e classificar diferentes níveis de dano em estruturas civis, de forma não destrutiva, segura e replicável. Utilizando um protótipo em escala reduzida de concreto armado, instrumentado com sensores acelerométricos e submetido a ensaios de impacto controlados, foram obtidas respostas vibracionais que alimentaram modelos de Redes Neurais Artificiais capazes de reconhecer padrões associados à integridade estrutural. A pesquisa apresenta impacto tecnológico direto ao propor uma solução inovadora e de baixo custo para diagnóstico estrutural, especialmente útil em contextos com infraestrutura envelhecida ou sem acesso a tecnologias de inspeção mais avançadas. Embora realizada em ambiente laboratorial, a metodologia possui alto potencial de transferência para aplicações reais, podendo beneficiar profissionais da engenharia civil, técnicos de manutenção e gestores públicos ou privados ligados à conservação de obras de arte especiais. Trata-se de um avanço com capacidade de reduzir custos operacionais, aumentar a segurança de usuários e prevenir falhas estruturais com base em estratégias preditivas. Participaram diretamente da pesquisa um docente orientador, um docente coorientador e uma discente de pós-graduação. A proposta se insere nas áreas temáticas de tecnologia e produção, meio ambiente e trabalho, contribuindo ainda para os Objetivos de Desenvolvimento Sustentável da ONU, com destaque para o ODS 9 (Indústria, inovação e infraestrutura), ODS 11 (Cidades e comunidades sustentáveis) e ODS 13 (Ação contra a mudança global do clima), ao propor uma alternativa que fortalece a infraestrutura urbana de forma sustentável e resiliente. Ainda que os impactos observados sejam, neste momento, potenciais, a disseminação dos resultados poderá favorecer sua adoção em múltiplos contextos territoriais, ampliando os efeitos positivos para além do ambiente acadêmico. A pesquisa fortalece a cultura da prevenção, promove a inovação no ensino e na prática da engenharia, e propõe uma alternativa eficiente e escalável para o monitoramento de estruturas, evidenciando sua contribuição para a sociedade e o desenvolvimento sustentável.

## **IMPACT INDICATORS**

This thesis developed a methodology for structural health monitoring through mechanical vibrations combined with artificial intelligence techniques, aiming to identify and classify different levels of damage in civil structures in a non-destructive, safe, and replicable manner. Using a scaled reinforced concrete prototype, instrumented with accelerometer sensors and subjected to controlled impact tests, vibrational responses were collected and used to train Artificial Neural Networks capable of recognizing patterns associated with structural integrity. The research presents direct technological impact by proposing an innovative and low-cost solution for structural diagnostics, particularly useful in contexts with aging infrastructure or limited access to advanced inspection technologies. Although conducted in a laboratory setting, the methodology holds strong potential for real-world applications, benefiting civil engineering professionals, maintenance technicians, and public or private managers responsible for the conservation of special engineering structures. This advancement may reduce operational costs, increase user safety, and prevent structural failures through predictive strategies. The project involved one academic advisor, one co-advisor, and one graduate student. The proposal falls within the thematic areas of technology and production, environment, and labor, while also contributing to the United Nations Sustainable Development Goals (SDGs), notably SDG 9 (Industry, Innovation and Infrastructure), SDG 11 (Sustainable Cities and Communities), and SDG 13 (Climate Action), by promoting an alternative that strengthens urban infrastructure in a sustainable and resilient way. Although the impacts are currently potential, the dissemination of results may favor its adoption in multiple territorial contexts, extending positive effects beyond the academic environment. The research strengthens a culture of prevention, promotes innovation in engineering education and practice, and proposes an efficient and scalable alternative for structural monitoring, demonstrating its contribution to society and sustainable development.

## LISTA DE FIGURAS

Figura 1 - Exemplos de pontes com sistemas de monitoramento dinâmico. ....	25
Figura 2 - Fluxograma da metodologia proposta. ....	36
Figura 3 - Viga de Madeira e Base Ajustável.....	37
Figura 4 - Corpos de prova resultantes.....	38
Figura 5 - Componentes do Sistema de aquisição de dados.....	39
Figura 6 - Dispositivo para teste à flexão INSTRON EMIC 23-20. ....	40
Figura 7 - Denominação e Viga de Madeira com entalhe (6 – 1,8 cm) com marcações.....	41
Figura 8 - Representação do teste de impacto com seus equipamentos nas vigas de madeira biapoiadas. ....	42
Figura 9 - Fluxograma de Interpretação dos resultados dos testes de impacto. ....	44
Figura 10 - Fluxograma da etapa de interpretação de resultados do teste à flexão. ....	46
Figura 11 - Vista do Tabuleiro. ....	49
Figura 12 - Corte AA.....	49
Figura 13- Forma para concepção do Protótipo. ....	50
Figura 14 - Armação de Pilares. ....	51
Figura 15 - Armação de Vigas.....	52
Figura 16 - Armação do Tabuleiro. ....	52
Figura 17 - Concretagem e desforma do Protótipo. ....	53
Figura 18 - Cenário do Protótipo em condição de integridade.....	54
Figura 19 - Cenários do Protótipo em condição de defeitos nas seções 1, 2, 3 e 4.....	55
Figura 20 - Mapa mental da interpretação dos resultados para os ensaios no protótipo de concreto armado em escala reduzida. ....	60
Figura 21 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PP (frequência em Hz; magnitude em dB).....	61
Figura 22 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PM (frequência em Hz; magnitude em dB).....	62
Figura 23 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PB. (frequência em Hz; magnitude em dB).....	62
Figura 24 - Corpos de prova submetidos ao teste de flexão.....	65
Figura 25 - Resultado da classificação dos dados de resistência mecânica de vigas, a partir de ensaios de flexão, obtidos pela aplicação do algoritmo k-means. ....	67

Figura 26 - Superfície das redes neurais com configurações de neurônios de 5 a 50 (PP). ....	70
Figura 27 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PP). .....	70
Figura 28 - Superfície das redes neurais com configurações de neurônios de 0 a 50 (PM).....	71
Figura 29 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PM).....	71
Figura 30 - Superfície das redes neurais com configurações de neurônios de 0 a 50 (PB).....	72
Figura 31 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PB).....	72
Figura 32 - Gráfico tridimensional da resposta em frequência para os 12 acelerômetros.....	73
Figura 33 - Gráfico Amplitudes. ....	76
Figura 34 - Superfície das redes neurais.....	80

## LISTA DE TABELAS

Tabela 1 - Amostras correspondentes às classes demonstradas. ....	57
Tabela 2 - Classes utilizadas no treinamento da RNA.....	58
Tabela 3 - Resultados Médios dos parâmetros mecânicos obtido a partir do ensaio à flexão. ....	65
Tabela 4 - Estatísticas descritivas do ensaio à flexão. ....	66
Tabela 5 - Categorização do k-means para as vigas de madeira.....	68
Tabela 6 - Desempenho da RNA com diferentes ponteiras e faixas de neurônios.....	69
Tabela 7 - Picos observados nas Funções de resposta em frequência nas diferentes seções de avaliação do protótipo.....	75
Tabela 8 - Acurácia e Kappa da RNA. ....	79

## LISTA DE QUADROS

Quadro 1 - Resumo comparativo dos resultados obtidos com as três ponteiros.....	64
Quadro 2 - Grau de severidade envolvendo os danos. ....	77

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
<b>2</b>	<b>HIPÓTESE</b> .....	<b>19</b>
<b>3</b>	<b>OBJETIVOS</b> .....	<b>20</b>
<b>3.1</b>	<b>Objetivo Geral</b> .....	<b>20</b>
<b>3.2</b>	<b>Objetivos Específicos</b> .....	<b>20</b>
<b>4</b>	<b>REFERENCIAL TEÓRICO</b> .....	<b>21</b>
<b>4.1</b>	<b>Obras de Arte Especiais</b> .....	<b>21</b>
<b>4.2</b>	<b>Análise de manifestações patológicas em pontes</b> .....	<b>22</b>
<b>4.3</b>	<b>Análise estrutural por meio de inspeção visual</b> .....	<b>22</b>
<b>4.4</b>	<b>Sistemas de monitoramento aplicados em engenharia</b> .....	<b>23</b>
<b>4.5</b>	<b>Monitoramento de Estruturas a partir de Vibração Mecânica</b> .....	<b>24</b>
<b>4.6</b>	<b>Monitoramento de Integridade Estrutural - SHM</b> .....	<b>25</b>
<b>4.7</b>	<b>Análise Modal</b> .....	<b>26</b>
<b>4.8</b>	<b>Modelos Estatísticos para predição de falhas</b> .....	<b>27</b>
<b>4.9</b>	<b>Aprendizado de máquina e inteligência artificial</b> .....	<b>28</b>
<b>4.10</b>	<b>Redes Neurais Artificiais, Métricas de Desempenho e Análise de Erros</b> .....	<b>29</b>
<b>4.11</b>	<b>Rede Neural Multilayer Perceptron</b> .....	<b>30</b>
<b>4.12</b>	<b>Treinamento e Aprendizado em Redes Neurais</b> .....	<b>31</b>
<b>4.13</b>	<b>Aprendizado Supervisionado e Não Supervisionado em Redes Neurais</b> .....	<b>31</b>
<b>4.14</b>	<b>Algoritmo de Retropropagação de Erro (<i>Backpropagation</i>)</b> .....	<b>32</b>
<b>4.15</b>	<b>Teoria da Similitude Estrutural</b> .....	<b>33</b>
<b>4.16</b>	<b>Trem-tipo: Definição e Aplicação em Engenharia Estrutural</b> .....	<b>34</b>
<b>5</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>35</b>
<b>5.1</b>	<b>Vigas de Madeira</b> .....	<b>37</b>
<b>5.1.1</b>	<b>Sistemas de aquisição de dados</b> .....	<b>38</b>
<b>5.1.2</b>	<b>Ensaio utilizando o Testes de Impacto</b> .....	<b>40</b>
<b>5.1.3</b>	<b>Ensaio à Flexão</b> .....	<b>45</b>
<b>5.1.4</b>	<b>Análise dos dados e aplicação de técnicas para identificação e predição de defeitos</b> .....	<b>47</b>
<b>5.1.5</b>	<b>Treinamento de Redes Neurais Artificiais (RNA)</b> .....	<b>47</b>
<b>5.2</b>	<b>Protótipo em Escala reduzida</b> .....	<b>48</b>

5.2.1	Sistemas de aquisição de dados.....	53
5.2.2	Ensaio preliminar de Monitoramento do Protótipo .....	54
5.2.3	Teste de Impacto .....	56
5.2.4	Análise dos dados e aplicação de técnicas para identificação e predição de defeitos.....	57
5.2.5	Treinamento de Redes Neurais Artificiais (RNA) no Protótipo .....	57
6	RESULTADOS E DISCUSSÕES .....	61
6.1	Resultados e discussões obtidas nas vigas da madeira.....	61
6.1.1	Análise Modal.....	61
6.1.2	Ensaio à Flexão .....	64
6.1.3	K- means.....	66
6.1.4	Acurácia e Kappa – Avaliação do Desempenho da RNA nas Diferentes Condições de Excitação .....	68
6.2	Resultados e discussão obtidos nos ensaios do Protótipo .....	73
6.2.1	Análise Modal.....	73
6.2.2	Redes Neurais Artificiais .....	77
6.2.3	Acurácia e Kappa.....	78
7	CONCLUSÃO .....	81
	REFERÊNCIAS .....	82

## 1 INTRODUÇÃO

O grande interesse atual em técnicas de diagnóstico e prognóstico para monitoramento de integridade estrutural (SHM, do inglês Structural Health Monitoring) deve-se a diversos fatores interligados. Um dos principais é o envelhecimento das infraestruturas civis, como pontes, viadutos e edifícios, muitos dos quais operam além da vida útil originalmente prevista em projeto.

Isso gera a necessidade de ferramentas que permitam o acompanhamento contínuo do seu desempenho estrutural, prevenindo falhas e colapsos. Além disso, o SHM possibilita a implementação de estratégias de manutenção preditiva, otimizando recursos ao reduzir os custos associados à manutenção corretiva ou preventiva tradicional.

Outro fator relevante é o aumento das exigências em termos de segurança estrutural, uma vez que falhas podem resultar em prejuízos humanos, ambientais e financeiros significativos. Diversas estruturas, como pontes, galpões industriais, torres de transmissão, reservatórios, silos e viadutos, são amplamente utilizadas em áreas urbanas, industriais e agrícolas para diferentes finalidades.

Muitas dessas estruturas operam por longos períodos e são submetidas a variados tipos de carregamentos ao longo do tempo. Embora nem todas apresentem falhas evidentes, é comum que, com o passar dos anos, ocorram processos naturais de degradação, especialmente quando não há manutenção adequada.

Segundo Ricco et al. (2024), a ausência de manutenção preventiva pode levar ao surgimento de danos estruturais graves, incluindo colapsos e perdas financeiras consideráveis. No caso específico de pontes metálicas, os autores destacam que a corrosão é uma das principais formas de deterioração.

Esse fenômeno resulta de reações químicas entre o metal e agentes agressivos do ambiente, como a poluição atmosférica, o que reduz a resistência do material e compromete a segurança da estrutura. As pontes de madeira, por serem materiais biodegradáveis, estão naturalmente sujeitas a manifestações patológicas devido à ação de agentes biológicos, desgaste e fadiga causados pelo tráfego de veículos e influências climáticas.

Esses fatores podem resultar no aparecimento de fissuras, descolamento de elementos, variações dimensionais, degradação do material e alterações na resistência mecânica. Vogel e Rosas (2024) destacam que as principais manifestações patológicas encontradas em pontes de madeira incluem ataques de fungos que comprometem as propriedades físicas e mecânicas da madeira, fendas longitudinais decorrentes da expansão e retração do material exposto às

intempéries, e desgaste por abrasão gerado pelo atrito entre os pneus dos veículos e a superfície da madeira.

De acordo com Lima et al. (2024), em pontes de concreto armado, a falta de manutenção pode ocasionar diversos problemas que, em casos críticos, colocam em risco a segurança pública. Entre essas falhas, destacam-se a corrosão das armaduras, fissuração e desgaste da superfície do concreto, deterioração das juntas de dilatação, bem como a erosão dos pilares e fundações, fatores que podem levar ao colapso da estrutura.

Complementarmente, Garcia et al. (2023) ressaltam que a manutenção não deve ser realizada apenas com base no tempo de uso da ponte, mas também deve levar em conta outros elementos, como condições ambientais, padrões de uso e o histórico de manutenções anteriores.

A utilização de tecnologias modernas como monitoramento remoto, sensores de vibração e análise de dados permite a detecção precoce de eventuais problemas e a otimização dos intervalos de manutenção. Dessa forma, a manutenção pode ser executada de maneira mais eficiente e econômica, garantindo tanto a integridade das estruturas quanto a segurança das pessoas e do meio ambiente.

O transporte de produtos agrícolas até os locais de comercialização representa um desafio significativo para os produtores, especialmente quando as estradas rurais estão em más condições. O tráfego de veículos pesados nessas vias contribui para sua degradação, dificultando a circulação de caminhões e prejudicando o escoamento da produção.

A manutenção inadequada das estradas rurais pode elevar os custos logísticos e o tempo de transporte, afetando diretamente a qualidade dos produtos agrícolas e a competitividade no mercado, (ROTAFLUX 2024). Além disso, a atividade agrícola está sujeita a diversos riscos, incluindo condições climáticas adversas, flutuações de preços e mudanças no mercado externo, que podem causar grandes prejuízos econômicos para o agricultor.

A gestão de riscos agrícolas é, portanto, indispensável para o desenvolvimento sustentável e rentável da agricultura moderna, (AGRO BAYER, 2024). Em áreas agrícolas, o transporte dos produtos das propriedades rurais é realizado por meio de estradas internas que se conectam às vias vicinais e, destas, à malha viária principal.

Essas ligações frequentemente envolvem pontes, geralmente de pequeno porte, cuja relevância econômica e social é inegável, Silva e Oliveira (2022) ressaltam a importância desses elementos de infraestrutura, destacando que eles são fundamentais para garantir a eficiência logística e o escoamento dos produtos, contribuindo para o desenvolvimento regional e a sustentabilidade da atividade agrícola.

Adicionalmente, Oliveira et al. (2023) ressaltam que as estradas rurais devem garantir não apenas o acesso eficiente de insumos às propriedades agrícolas, mas também facilitar o livre deslocamento das comunidades do meio rural. Essa infraestrutura é essencial para promover a integração entre áreas produtivas e centros urbanos, contribuindo para o desenvolvimento sustentável e a melhoria da qualidade de vida no campo.

Em uma propriedade rural, as atividades vão além do plantio, colheita, cuidados com os animais e venda da produção. A logística rural envolve o planejamento, administração e execução de tarefas relacionadas ao escoamento da produção agropecuária, abrangendo desde a aquisição de insumos até a entrega do produto final ao consumidor (TOTVS, 2023), o entendimento conceitual dessa dinâmica implica na definição do termo “logística” e onde ela atua como elemento que permite a eficiência da cadeia produtiva.

Nos últimos anos, diversos pesquisadores têm concentrado seus estudos nos aspectos econômicos e de segurança estrutural. Nesse contexto, as técnicas de Monitoramento da Integridade Estrutural (SHM) têm sido amplamente investigadas para aumentar a segurança e reduzir os custos de manutenção.

Para esse fim, uma variedade de novos métodos de monitoramento estrutural, como redes de sensores sem fio, transdutores piezoelétricos, sistemas de monitoramento de saúde estrutural, métodos baseados em fibra óptica e técnicas de aprendizado de máquina, têm sido desenvolvidos para detectar e caracterizar danos estruturais, (Kot Engenharia 2020). Além disso, a análise de danos também tem se beneficiado da aplicação de técnicas modernas de inteligência artificial, amplamente utilizada para ajudar na detecção de danos estruturais (MO e YANG, 2018).

Como forma de coadjuvar na detecção de danos estruturais, Chen et al., (2020) enuncia que a tecnologia de monitoramento de saúde estrutural tem sido amplamente utilizada para desenvolver sistemas inteligentes que as técnicas de monitoramento de saúde estrutural modernas abrangem uma variedade de técnicas de monitoramento, incluindo monitoramento de vibração, de temperatura de deformação de vibração não linear de falhas por meio de vídeo e por meio de sensores robóticos, métodos que fornecem informações em tempo real sobre o estado estrutural, o que é essencial para o gerenciamento de riscos e manutenção preventiva.

De acordo com Li et al. (2024), os sistemas avançados de monitoramento de integridade estrutural podem ser implementados através de: 1) detecção da presença de danos; 2) localização dos danos na estrutura; 3) identificação do tipo de dano; 4) avaliação da extensão do dano; 5) estimativa da vida útil remanescente da estrutura. Liu & Pereira (2023) desenvolveram uma abordagem inovadora de inspeção para pontes, baseada na análise de

vibração, que incorpora os parâmetros dinâmicos da estrutura para uma avaliação mais precisa de sua integridade.

A maioria dos estudos SHM não incorpora modelos estatísticos para quantificar as alterações observadas nos parâmetros que indicam falha (Lee & Kim, 2023). Embora algumas técnicas estatísticas como a análise de séries temporais para a detecção de anomalias ou a análise de componentes principais para redução de dimensionalidade possam ser aplicadas nas análises de SHM, o emprego de modelos estatísticos para mensurar as variações nos indicadores de falha ainda é pouco comum (Cheng, 2023).

No entanto, o aprendizado de máquina e técnicas de inteligência artificial ganharam espaço como promessas no SHM, permitindo o processamento eficiente de grandes volumes de dados e a identificação. Testes de padrões e anomalias que podem indicar falhas estruturais. Diante do cenário apresentado, é de suma importância o monitoramento de estruturas visando a detecção de defeitos, em especial, pontes em área agrícolas que possuem significativa importância estratégica, econômica e social.

Portanto, esse trabalho será desenvolvido visando a proposição de uma metodologia para monitoramento da estrutura de um protótipo em escala reduzida, permitindo a realização da análise da integridade estrutural para se determinar quando e como será o melhor método preventivo a ser utilizado.

## **2 HIPÓTESE**

O monitoramento da integridade de estruturas pode ser feito por vibrações, podendo metodologias serem desenvolvidas considerando-se o uso de modelos em escala reduzida. Ademais, outros métodos também podem ser utilizados, como a inspeção visual e aplicação de sensores.

Estes métodos permitem avaliar o estado de integridade das estruturas, enviando sinais que podem ser monitorados em tempo real para detectar anomalias e prevenir problemas antes que eles ocorram.

### **3 OBJETIVOS**

#### **3.1 Objetivo Geral**

Este trabalho foi desenvolvido com o objetivo de elaborar uma metodologia destinada ao monitoramento da integridade estrutural de pontes, empregadas em áreas agrícolas, por meio de vibrações mecânicas.

#### **3.2 Objetivos Específicos**

- a) Desenvolver um protocolo para a realização de medições de vibração mecânica, que possibilite a coleta de dados precisos e confiáveis a partir de estudos em laboratório;
- b) Desenvolver um modelo em escala reduzida de uma ponte para a aplicação e validação da metodologia proposta;
- c) Avaliar as Funções de Resposta em Frequência (FRF) em estruturas íntegras e com defeitos induzidos em condições de laboratório;
- d) Correlacionar as FRF com diferentes níveis de defeito observados nas estruturas testadas;
- e) Treinar uma Rede Neural Artificial com os dados coletados, visando identificar a severidade dos defeitos estruturais.

## 4 REFERENCIAL TEÓRICO

### 4.1 Obras de Arte Especiais

As Obras de Arte Especiais (OAEs), como pontes, viadutos, túneis e passarelas, são estruturas que apresentam características singulares em termos de função, forma, materialidade e distribuição de esforços, exigindo competências técnicas e criativas específicas para seu projeto, execução e manutenção (SILVA *et al.*, 2023; OLIVEIRA, 2021).

Essas obras são cruciais para a mobilidade urbana e rural, além de impactarem diretamente o crescimento econômico, a coesão social e a sustentabilidade ambiental (PAVIDEZ ENGENHARIA, 2024). No Brasil, estima-se que existam cerca de 140 mil pontes, com valor patrimonial superior a R\$ 270 bilhões.

No entanto, há significativa deficiência na destinação de recursos para inspeção e monitoramento, em contraste com países como os Estados Unidos, que investem aproximadamente 2,5% do valor total da infraestrutura nessas atividades (SILVA; ALMEIDA, 2023).

Entre os elementos críticos dessas estruturas estão as juntas de dilatação, frequentemente reparadas de forma inadequada, o que pode acarretar sobrecargas adicionais e comprometimento da capacidade portante (SILVA; ALMEIDA, 2023).

Esses problemas geram elevados custos de manutenção e refletem a ausência de práticas preventivas, as quais são essenciais para a preservação e segurança estrutural. A adoção de inspeções regulares, associadas a correções técnicas fundamentadas, é apontada como medida eficaz para evitar colapsos e preservar o patrimônio (OLIVEIRA *et al.*, 2024).

Segundo o DNIT (2024), Minas Gerais possui cerca de 1.357 OAEs, das quais 73,25% são pontes, evidenciando a relevância desse tipo de estrutura no cenário estadual. No entanto, muitas dessas construções operam próximas ao limite de estabilidade devido à falta de manutenção preventiva, o que acelera a deterioração e promove o surgimento de patologias estruturais (PAIXÃO *et al.*, 2020).

Para prolongar a vida útil dessas obras e garantir sua integridade, o uso de técnicas modernas de inspeção e monitoramento é essencial (SILVA *et al.*, 2024; OLIVEIRA *et al.*, 2023).

Tais técnicas incluem ensaios não destrutivos, modelagem computacional, uso de sensores e integração de dados por meio da computação em nuvem, que permite o compartilhamento e a análise eficiente das informações estruturais (NI *et al.*, 2020).

Além disso, metodologias avançadas, como ultrassom, termografia e radar de penetração no solo, permitem detecção precoce de defeitos internos sem comprometer a estrutura (LORENZI *et al.*, 2020). Dessa forma, a utilização de ferramentas tecnológicas para o diagnóstico precoce e monitoramento contínuo das OAEs contribui diretamente para a segurança, a economia de recursos e a eficiência na gestão da infraestrutura (ALMEIDA *et al.*, 2023).

#### **4.2 Análise de manifestações patológicas em pontes**

A partir da década de 1990, a Associação Brasileira de Normas Técnicas (ABNT) iniciou um processo de atualização das normas brasileiras, com o objetivo de aprimorar a qualidade dos projetos de vias de tráfego e garantir maior segurança aos usuários (Almeida *et al.*, 2023).

De acordo com Oliveira *et al.* (2022), em pontes com vãos de até 60 metros, a carga operacional pode ser até 62,5% superior em comparação com os critérios estabelecidos nas normas ABNT NBR 7188:1982 e ABNT NBR 7188:2013. Esse aumento considera um trem-tipo de 36 toneladas, utilizado para avaliar a resistência estrutural de pontes, viadutos e passarelas.

Além disso, o crescimento das cargas móveis nas OAEs brasileiras, impulsionado pelo aumento do fluxo viário e da capacidade de carga dos veículos, pode estar diretamente relacionado ao surgimento de patologias estruturais observadas ao longo dos anos (MENDES; FERREIRA, 2021).

Mascarenhas *et al.* (2024) analisaram dados do banco de informações do DNIT sobre o tipo de estrutura das OAEs no Brasil, identificando que 77,5% dessas estruturas foram construídas em concreto armado, 14,8% em concreto protendido, 1,1% em aço, 2,4% em estrutura mista e 4,2% em madeira. Esses números indicam que as pontes de concreto armado são as mais suscetíveis a intervenções estruturais, principalmente devido ao desgaste progressivo causado pelas cargas ao longo do tempo.

#### **4.3 Análise estrutural por meio de inspeção visual**

Atualmente, técnicas convencionais de inspeção visual e métodos de Avaliação não Destrutiva (*Nondestructive Evaluation* – NDE) continuam sendo amplamente utilizadas na análise estrutural, conforme destacado por Oliveira *et al.* (2023). Segundo Wang *et al.* (2023),

aproximadamente 61% das inspeções estruturais em aeronaves ainda são realizadas visualmente, enquanto 31% utilizam outras formas de NDE de maneira não planejada, e apenas 8% incorporam técnicas de NDE em estratégias de manutenção programada. No entanto, a inspeção visual apresenta limitações significativas, pois depende exclusivamente da experiência e da acuidade do observador.

A detecção de danos por NDE envolve diversas técnicas, como ultrassom, vibração, líquido penetrante, radiografia, termografia e inspeção visual. Esses métodos são projetados para identificar diferentes tipos de falhas, incluindo trincas, fissuras, corrosão, desgaste, falhas na solda, defeitos de material, deformações e alterações dimensionais (GONÇALVES, 2024). Técnicas mais avançadas de NDE possibilitam a detecção de danos internos e descontinuidades não visíveis, reduzindo a necessidade de inspeções invasivas e aumentando a confiabilidade na identificação de pequenas falhas.

Além disso, o monitoramento estrutural tem papel fundamental na segurança e na otimização de custos, pois permite a detecção precoce de danos e reduz o risco de colapsos inesperados. A utilização de dados coletados por meio dessas técnicas possibilita a implementação de programas de manutenção preventiva, prolongando a vida útil das estruturas e minimizando tanto os custos diretos de intervenção quanto os custos indiretos decorrentes de restrições operacionais (BARBOSA *et al.*, 2024).

#### **4.4 Sistemas de monitoramento aplicados em engenharia**

Pesquisadores e engenheiros estruturais, baseados na norma ABNT NBR 8802:2023, têm utilizado ensaios de ultrassom como método para avaliar a existência de danos em estruturas de concreto. Esse ensaio não destrutivo é amplamente reconhecido na comunidade científica por sua eficácia na detecção de fissuras e outros defeitos estruturais. No entanto, conforme destacado por Chies (2022) e Silva (2023), essa técnica demanda tempo e recursos financeiros consideráveis, pois uma análise confiável exige monitoramento contínuo.

Técnicas de Monitoramento de Integridade Estrutural (SHM – *Structural Health Monitoring*) têm sido amplamente estudadas para aumentar a segurança e reduzir custos de manutenção (FARRAR *et al.*, 2021). O SHM pode ser realizado em tempo real ou de forma periódica e consiste na implementação de estratégias para identificação de danos ou caracterização mecânica de estruturas nas indústrias aeroespacial, mecânica, naval e de infraestrutura na Engenharia Civil. O dano pode ser definido como qualquer alteração nas

propriedades mecânicas desses sistemas, incluindo mudanças nas condições de contorno e conectividade, que comprometam negativamente o desempenho estrutural (Farrar *et al.*, 2021).

Sohn (2020) aponta que diversas ferramentas eficazes de avaliação não destrutiva estão disponíveis para o monitoramento estrutural. Li *et al.* (2022) descreveram avanços recentes na detecção de danos utilizando *Structural Health Monitoring* (SHM). Wang *et al.* (2021) propuseram uma abordagem para classificação de falhas estruturais por meio de SHM, enquanto Wang *et al.* (2023) exploraram o uso de modelos preditivos baseados em aprendizado de máquina para monitoramento estrutural.

A utilização de drones na inspeção de estruturas tem ganhado destaque, conforme demonstrado pelo investimento de US\$ 6,5 milhões na startup Prenav (COSTA, 2023). Essa empresa desenvolveu drones altamente automatizados, guiados por algoritmos de inteligência artificial (*Machine Learning*), para inspecionar pontes, barragens, usinas elétricas e torres de transmissão.

O sistema é capaz de identificar defeitos previamente reportados, como rachaduras em concreto, fraturas em aço, corrosão de elementos estruturais e falhas em conexões mecânicas segundo Li *et al.*, 2022.

O crescente interesse pelo SHM tem impulsionado numerosos estudos recentes, devido aos benefícios proporcionados em termos de segurança, aumento da vida útil das estruturas e economia de recursos. Embora essas tecnologias possam ser aplicadas em diversas áreas da engenharia, sua utilização na construção civil ainda enfrenta desafios técnicos e operacionais significativos.

Estudos de inspeção conduzidos pela *American Association of State Highway and Transportation Officials* (AASHTO), nos Estados Unidos, pela *European Association for Bridge Maintenance and Safety* (EABMS), na Europa e pela Associação Brasileira de Normas Técnicas (ABNT), no Brasil indicam que grande parte das pontes construídas em décadas passadas está atingindo sua idade crítica. Isso evidencia a necessidade urgente de procedimentos de reparo e monitoramento contínuo para garantir a segurança estrutural e a funcionalidade dessas infraestruturas (SILVA, 2023).

#### **4.5 Monitoramento de Estruturas a partir de Vibração Mecânica**

O SHM é essencial para a manutenção preventiva e a segurança de diversas infraestruturas, como pontes, edifícios e equipamentos industriais. Segundo Kamariotis *et al.*

(2024), o SHM deve apoiar a tomada de decisões e tradicionalmente utiliza métodos visuais e localizados como os ultrassônicos, que exigem conhecimento prévio da localização dos danos.

Para superar essa limitação, avançaram-se métodos baseados em vibrações, que permitem avaliação mais ampla e contínua da estrutura.

Estudos recentes apontam a necessidade de uma abordagem holística, considerando fatores estruturais, ambientais e operacionais ao longo do tempo. A integração de sensores inteligentes, análise em tempo real e modelagem avançada amplia a capacidade de detecção e resposta a danos, aumentando a segurança e a durabilidade das estruturas (BOLLER *et al.*, 2009).

Figura 1 - Exemplos de pontes com sistemas de monitoramento dinâmico.



Ponte Oresund - Dinamarca  
50 acelerômetros



Ponte Samcheonpo - Korea  
22 acelerômetros tri - axiais



Ponte Stonecutters - Hong Kong - 58 acelerômetros

Fonte: adaptado de Boller *et al.* (2009).

#### 4.6 Monitoramento de Integridade Estrutural - SHM

O SHM tem avançado consideravelmente nos últimos anos, impulsionado pelo desenvolvimento de novas tecnologias e metodologias computacionais. Estudos recentes demonstram que a aplicação de inteligência artificial e aprendizado de máquina tem sido essencial para aprimorar a detecção de danos e otimizar a manutenção preditiva de estruturas (Li *et al.*, 2024).

A introdução de *autoencoders* informados por mecânica tem permitido a detecção e localização automatizada de danos não previstos, promovendo estratégias de manutenção mais

eficazes e reduzindo o risco de falhas estruturais (Li *et al.*, 2024). Além disso, métodos semissupervisionados, como a combinação de *Variational Autoencoders* (VAE) e máquinas de vetor de suporte de uma classe (*One-Class Support Vector Machine* – OC-SVM), têm sido utilizados para identificar anomalias estruturais de forma mais eficiente, permitindo uma discriminação aprimorada entre diferentes condições de integridade estrutural (POLLASTRO *et al.*, 2022).

No Brasil, pesquisas têm se concentrado no desenvolvimento de sistemas de baixo custo para monitoramento estrutural, utilizando sensores conectados por redes de comunicação para coletar dados em tempo real e avaliar modelos de comportamento estrutural (ALVES *et al.*, 2023). Esses sistemas facilitam a manutenção preditiva e a prevenção de falhas, reduzindo custos operacionais e aumentando a segurança das edificações e infraestruturas críticas.

A integração de sensores inteligentes tem revolucionado o monitoramento estrutural, permitindo a detecção antecipada de deformações, tensões e outras irregularidades que possam comprometer a segurança e longevidade das construções (REDAÇÃO BdE, 2024). Esses sensores, combinados com algoritmos avançados de análise de dados, fornecem informações em tempo real para tomada de decisões, tornando a gestão da integridade estrutural mais eficiente e confiável.

Os avanços recentes no SHM demonstram o potencial das novas tecnologias para melhorar a detecção precoce de danos, otimizar processos de manutenção e garantir maior confiabilidade às estruturas monitoradas.

Com a contínua evolução das técnicas de inteligência artificial e a ampliação do uso de sensores inteligentes, espera-se que o monitoramento estrutural se torne cada vez mais preciso e acessível, contribuindo para a segurança e sustentabilidade das infraestruturas modernas.

#### **4.7 Análise Modal**

A identificação de danos estruturais por meio de análises modais continua sendo um tema relevante, com métodos que atuam nos domínios do tempo e da frequência. Zague *et al.* (2024) propuseram combinar algoritmos de Análise Modal Operacional (*OMA*) para estimar parâmetros modais com maior precisão e baixos custos computacionais.

Apesar da eficácia dessas técnicas, Bravo (2020) ressalta que métodos de monitoramento estrutural podem ter limitações devido ao alto custo computacional, o que pode ser mitigado pelo uso de Modelos de Superfície de Resposta (*MSR*), que são eficientes em problemas lineares e não lineares.

A análise modal, segundo Kim *et al.* (2021), envolve estudar as propriedades dinâmicas da estrutura a partir de excitações por vibração, utilizando Funções de Resposta em Frequência (FRF). A FRF relaciona a causa e o efeito de vibrações em diferentes pontos da estrutura e pode ser obtida experimentalmente, conforme Jones e Taylor (2020).

Técnicas de otimização e análise de sensibilidade auxiliam na identificação de parâmetros críticos. Estudos recentes, como os de Zhang *et al.* (2022) e Mai *et al.* (2022), continuam expandindo o uso da FRF em novas aplicações, reforçando sua importância no monitoramento e análise estrutural.

#### 4.8 Modelos Estatísticos para predição de falhas

De acordo com Carvalho *et al.* (2022), grande parte das metodologias de *Structural Health Monitoring (SHM)* ainda se baseia em inspeções locais, como os métodos ultrassônicos, que possibilitam a coleta de dados de vibração para identificar anomalias. Outra estratégia importante é o monitoramento em tempo real, que, segundo Almeida e Ferreira (2021), permite a detecção precoce de alterações estruturais por meio da aquisição contínua de dados vibracionais. A análise do espectro de frequência também é consolidada, pois facilita a identificação de falhas mecânicas e elétricas (BARROS *et al.*, 2022).

Métodos baseados em vibração podem ser classificados de várias formas, como abordagens baseadas em modelos (utilizam um modelo matemático analítico ou numérico, como *finite element methods – FEM*) ou não-modelos (não exigem um modelo físico explícito) da estrutura saudável, lineares (assumem que a estrutura responde linearmente às excitações) ou não-lineares (consideram que a resposta da estrutura não é proporcional à excitação), e formulações globais (sensíveis a grandes danos) ou locais (detectam danos específicos em uma parte da estrutura), (SHARMA, 2017).

Estudos recentes têm integrado algoritmos de *machine learning* com técnicas estatísticas para aprimorar a detecção e predição de falhas. Muitos algoritmos ainda dependem da modelagem por *finite element methods* e da análise modal experimental. A *Modal Analysis* é destacada por identificar frequências naturais e modos de vibração (SANTOS *et al.*, 2021), enquanto os *Finite Element Models (FEM)* são usados para simular comportamentos dinâmicos (LIMA e COSTA, 2022).

Já os métodos não-modelos analisam dados diretamente, sem exigir um modelo físico detalhado. A *Principal Component Analysis (PCA)*, por exemplo, permite extrair características relevantes ao transformar variáveis correlacionadas em componentes não correlacionadas

(GOMES *et al.*, 2021), embora sua aplicação enfrente desafios operacionais e ambientais. Além disso, muitas vezes é necessário operar de forma não supervisionada, pois nem sempre há dados de falha disponíveis para definir limiares (OLIVEIRA e SOUZA, 2020).

Liu *et al.* (2022) ressaltam que faltam modelos estatísticos robustos para quantificar mudanças indicativas de falha. Como os processos baseados em vibração apresentam incertezas, torna-se essencial usar análises estatísticas para diferenciar danos reais de variações ambientais e operacionais (STROH e NACHTIGAL, 2021).

Diante disso, Costa *et al.* (2023) propuseram uma metodologia baseada exclusivamente em sinais de vibração, usando dados de estruturas sem dano como referência. O método baseia-se na análise do erro residual de *Autoregressive (AR) Models*, cuja ordem ótima e limiares estatísticos são cuidadosamente definidos. Esses modelos, conforme Box *et al.* (2021), relacionam valores atuais com observações passadas, sendo o erro residual um importante indicador de falhas.

#### 4.9 Aprendizado de máquina e inteligência artificial

Além das abordagens tradicionais, técnicas de *machine learning* e *artificial intelligence* têm sido amplamente exploradas na detecção de falhas em estruturas e máquinas, por sua capacidade de reconhecer padrões complexos nos dados de vibração e permitir uma detecção precoce e precisa de anomalias. Entre os métodos de aprendizado supervisionado, destacam-se os algoritmos *Random Forest*, *Support Vector Machine (SVM)* e *Multi-Layer Perceptron (MLP)*.

O *Random Forest* é um método de aprendizado de máquina que utiliza múltiplas árvores de decisão e combina suas previsões para aumentar a precisão e reduzir o *overfitting*. Essa abordagem é robusta para detecção de falhas em conjuntos de dados volumosos e heterogêneos (SILVA *et al.*, 2022).

Já a SVM é eficaz na identificação de padrões complexos de vibração, separando condições normais e anômalas como trincas e desgastes (MARTINS e OLIVEIRA, 2021; LIMA *et al.*, 2022). O MLP, uma rede neural com múltiplas camadas, modela relações não lineares por meio do *backpropagation* e reconhece falhas como folgas e desalinhamentos (CARVALHO *et al.*, 2023).

Em aprendizado não supervisionado, técnicas como análise de agrupamento (*cluster analysis*) e decomposição em valores singulares (*singular value decomposition*) são utilizadas. (SVD) são empregadas para identificar comportamentos anômalos sem rótulos prévios,

oferecendo flexibilidade frente a variações operacionais e contribuindo para a manutenção preditiva (FERNANDES *et al.*, 2022).

Modelos de séries temporais como os *Hidden Markov Models (HMMs)* e as *Recurrent Neural Networks (RNNs)* também são promissores na previsão de falhas com base em padrões históricos, antecipando tendências e promovendo uma manutenção proativa (GOMES e RIBEIRO, 2023).

A integração dessas técnicas tem aumentado a eficiência da manutenção e prevenido danos catastróficos, assegurando a integridade e longevidade das estruturas e máquinas monitoradas (MARTINS *et al.*, 2023).

#### **4.10 Redes Neurais Artificiais, Métricas de Desempenho e Análise de Erros**

As Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de reconhecer padrões e executar tarefas complexas de aprendizado (CHOLLET, 2021). Elas são compostas por neurônios artificiais organizados em camadas, onde cada neurônio realiza uma soma ponderada das entradas e aplica uma função de ativação, como *ReLU* ou *sigmoid*, para gerar uma saída (ZHANG, LIU e CHEN, 2021).

Arquiteturas avançadas, como o *Transformer*, têm ampliado significativamente as capacidades das Redes Neurais Artificiais (RNAs), especialmente em tarefas de Processamento de Linguagem Natural (PLN) (DOS SANTOS, DE OLIVEIRA e LIMA, 2022). As Redes Neurais Convolucionais (CNNs) continuam sendo referência na classificação de imagens, superando métodos tradicionais de processamento visual (KUMAR, LI e SINGH, 2022).

Já as Redes Neurais Recorrentes (RNNs), e suas variantes LSTM (*Long Short-Term Memory*) e GRU (*Gated Recurrent Units*), são eficazes na modelagem de dados sequenciais, como previsão de séries temporais e geração de texto (LI e ZHAO, 2022; KIM, PARK e LEE, 2022).

O desempenho das RNAs depende de treinamento adequado e ajuste de hiperparâmetros, exigindo conhecimento técnico e compreensão detalhada do problema.

A acurácia é uma métrica central para avaliação em tarefas de classificação, representando a proporção de acertos sobre o total de previsões (ZHANG, LIU e CHEN, 2021). Entretanto, em conjuntos de dados desbalanceados, a acurácia pode ser enganosa, já que prever sempre a classe majoritária pode resultar em valores altos sem detectar a classe minoritária (BOWLES e SNEDECOR, 2022).

Por isso, métricas como *precision*, *recall* e *F1-score* são essenciais para uma avaliação mais equilibrada (ZHANG, LIU e CHEN, 2021; LEE e CHOI, 2022).

A análise por meio da matriz de confusão é indispensável, pois permite visualizar os Verdadeiros Positivos (TP), Falsos Positivos (FP), Verdadeiros Negativos (TN) e Falsos Negativos (FN) e, em casos com múltiplas classes, identificar padrões de erro que orientam ajustes no modelo (PEREIRA, SANTOS e ALMEIDA, 2022). Estudos recentes (ZHANG e WANG, 2023) reforçam que a matriz de confusão é fundamental não apenas para medir a acurácia geral, mas também para compreender a distribuição dos erros.

A utilização da curva ROC (*Receiver Operating Characteristic*) e da AUC (*Area Under the Curve*) complementa essa avaliação, contribuindo para o desenvolvimento de sistemas de classificação mais precisos e robustos.

#### 4.11 Rede Neural Multilayer Perceptron

A Rede Neural *Multilayer Perceptron* (MLP) é uma das arquiteturas mais clássicas e amplamente utilizadas no campo da inteligência artificial. Consiste em múltiplas camadas de neurônios organizadas sequencialmente, geralmente compostas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Essa configuração permite à MLP realizar tanto tarefas de classificação quanto de regressão, com destaque para sua capacidade de modelar relações não lineares entre variáveis (AGARWAL *et al.*, 2021).

Cada neurônio em uma camada está tipicamente totalmente conectado aos neurônios da camada seguinte. Funções de ativação como *ReLU* ou *sigmoid* são empregadas para introduzir não linearidades e permitir o aprendizado de padrões complexos. O processo de treinamento da MLP é realizado por meio do algoritmo de *backpropagation*, o qual ajusta os pesos sinápticos com base no erro entre a saída prevista e a real. Esse ajuste é feito de forma iterativa com algoritmos de otimização como o *gradient descent* (GARCIA *et al.*, 2022).

Entre suas principais vantagens estão a flexibilidade e a capacidade de generalização para problemas com estruturas variadas. No entanto, essa flexibilidade também traz desafios, como a necessidade de grandes volumes de dados para evitar *overfitting*, especialmente em contextos com alta dimensionalidade (ZOU *et al.*, 2022). Além disso, em tarefas de processamento de imagens, a MLP tende a ser menos eficiente do que arquiteturas modernas como as Redes Neurais Convolutional (CNNs), que aproveitam o compartilhamento de pesos para capturar padrões espaciais com maior eficácia (LEE *et al.*, 2023).

Apesar dessas limitações, a MLP permanece como uma ferramenta poderosa e versátil. Quando bem configurada e acompanhada de técnicas para controle de *overfitting*, como *regularization* ou *cross-validation*, continua a oferecer bons resultados em diversas aplicações de inteligência artificial.

#### **4.12 Treinamento e Aprendizado em Redes Neurais**

No campo das redes neurais artificiais, os conceitos de treinamento e aprendizado, embora interligados, possuem funções distintas.

O treinamento consiste no processo técnico de ajuste iterativo dos pesos sinápticos da rede, realizado por meio de algoritmos como a retropropagação e otimizadores baseados em gradiente (GOODFELLOW *et al.*, 2016), esse ajuste utiliza dados rotulados para reduzir os erros entre as saídas previstas e os valores reais, promovendo a calibração progressiva dos parâmetros da rede (CHEN *et al.*, 2021).

Em contrapartida, o aprendizado representa a capacidade adquirida pela rede de generalizar a partir dos dados e realizar inferências corretas em situações não vistas anteriormente (LIU, KUMAR e GUPTA, 2022). Esse processo pode ocorrer em diferentes paradigmas de aprendizagem supervisionada, não supervisionada ou por reforço, conforme a natureza dos dados e a tarefa proposta (LECUN, BENGIO e HINTON, 2015).

A distinção entre ambos é essencial, o treinamento ajusta os parâmetros e o aprendizado representa a melhoria na performance da rede. Estudos recentes mostram que o desempenho melhora com mais dados e mais épocas de treinamento (SUN *et al.*, 2023), e que a eficiência do processo depende também da qualidade dos dados e da arquitetura da rede (WANG *et al.*, 2021).

Em síntese, o treinamento é o “como” e o aprendizado é o “resultado”. Entender essa diferença é fundamental para o desenvolvimento de modelos eficazes em inteligência artificial.

#### **4.13 Aprendizado Supervisionado e Não Supervisionado em Redes Neurais**

No campo das redes neurais e do aprendizado de máquina, os paradigmas de aprendizado supervisionado e não supervisionado são amplamente utilizados, oferecendo abordagens distintas para diferentes problemas.

No aprendizado supervisionado, o modelo é treinado com dados rotulados, buscando mapear corretamente entradas para saídas, generalizando esse conhecimento para novos dados.

Durante o treinamento, os pesos da rede são ajustados para minimizar uma função de perda, como o erro quadrático médio, conforme destacado por Géron (2019), Silva, Oliveira e Souza (2022) e Goodfellow, Bengio e Courville (2016). Um exemplo é a classificação de imagens com rótulos como “gato” ou “cachorro”, como ilustrado por Russell e Norvig (2021).

Por outro lado, no aprendizado não supervisionado, a rede é treinada com dados não rotulados para identificar padrões e estruturas ocultas. Técnicas como o  $k$ -means e a Análise de Componentes Principais ( $PCA$ ) são comuns nesse paradigma, permitindo identificar agrupamentos naturais nos dados (PEREIRA e ALMEIDA, 2020). Um exemplo é a segmentação de clientes com base em seus hábitos de compra, sem necessidade de rótulos, como discutido por Hastie, Tibshirani e Friedman (2019).

A principal diferença entre os dois está na necessidade de rótulos no aprendizado supervisionado, que orienta a rede a prever saídas específicas, enquanto o não supervisionado explora os dados de forma autônoma. O primeiro requer grande volume de dados rotulados, enquanto o segundo apresenta desafios na interpretação dos resultados por não haver uma “resposta correta” (MURPHY, 2021; ALPAYDIN, 2020).

Em resumo, a escolha entre os paradigmas depende da disponibilidade de rótulos, da natureza do problema e dos objetivos do modelo. Ambos desempenham papéis essenciais no desenvolvimento de sistemas de inteligência artificial e no avanço das aplicações tecnológicas.

#### **4.14 Algoritmo de Retropropagação de Erro (*Backpropagation*)**

O algoritmo de retropropagação de erro, ou *backpropagation*, permanece como um dos métodos fundamentais para o treinamento de redes neurais artificiais. Pesquisas recentes têm destacado melhorias que aprimoram sua eficácia, especialmente em arquiteturas profundas onde desafios como o gradiente desaparecendo ou explodindo podem comprometer o treinamento (ZHANG, LI e CHEN, 2023; LIU *et al.*, 2022).

No processo de retropropagação, os dados de entrada são inicialmente propagados pela rede até alcançarem a camada de saída, onde a discrepância entre a saída prevista e a saída desejada é calculada, geralmente utilizando funções de perda como o erro quadrático médio (LIU *et al.*, 2022). Em seguida, esse erro é propagado de volta pelas camadas da rede, permitindo o cálculo dos gradientes em relação aos pesos sinápticos. Com base nesses gradientes, os pesos são ajustados na direção oposta para minimizar a função de perda ao longo das iterações (ZHANG, LI e CHEN, 2023).

Melhorias recentes incorporam técnicas de otimização avançadas para potencializar o desempenho do *backpropagation*. Por exemplo, estudos têm demonstrado que abordagens adaptativas podem reduzir os efeitos adversos de gradientes instáveis, otimizando o treinamento de redes neurais profundas (WANG, ZHAO e LI, 2021). Contudo, desafios como a necessidade de grandes volumes de dados rotulados e o elevado custo computacional ainda impulsionam novas pesquisas e inovações no campo (ZHANG, LI e CHEN, 2023).

Em síntese, embora o *backpropagation* tenha suas raízes consolidadas, as inovações dos últimos anos reforçam sua relevância e demonstram que o algoritmo continua em evolução, contribuindo significativamente para os avanços em aplicações de inteligência artificial.

#### 4.15 Teoria da Similitude Estrutural

A teoria da similitude estrutural é amplamente empregada na engenharia civil para análises em modelos em escala reduzida, possibilitando a extrapolação dos resultados para estruturas em tamanho real. Segundo Silva *et al.* (2022), essa teoria fundamenta-se na manutenção de relações geométricas, cinemáticas e dinâmicas entre o modelo e o protótipo, assegurando precisão experimental e aplicabilidade prática.

Conforme Galego *et al.* (2023), a similitude envolve três formas principais: semelhança geométrica, que exige proporção entre as dimensões do modelo e da estrutura real; semelhança cinética, que garante proporcionalidade entre velocidades e acelerações; e semelhança dinâmica, que estabelece equivalência entre as forças atuantes.

Para assegurar essas condições, Donato *et al.* (2017) ressaltam a importância de parâmetros adimensionais como o número de *Reynolds* e o número de *Froude*, essenciais para representar adequadamente efeitos de viscosidade e gravidade entre o modelo e o protótipo. A aplicação precisa dessa teoria confere confiabilidade aos experimentos em escala reduzida.

Galego *et al.* (2023) destacam a utilidade dessa abordagem em projetos de grande porte, como pontes e edifícios, onde ensaios em escala real são inviáveis por razões financeiras e práticas. Os números adimensionais citados são fundamentais para garantir a representação fiel dos fenômenos físicos em diferentes escalas, como também apontado por Silva *et al.* (2022).

Além da engenharia civil, a teoria da similitude estrutural é aplicada em outras áreas científicas, conforme indicado por Zhang *et al.* (2021), demonstrando sua versatilidade e importância para pesquisas experimentais. Galego *et al.*, (2023) reforçam sua indispensabilidade na compreensão e modelagem de fenômenos complexos.

Em síntese, a teoria da similitude estrutural permanece com o uma ferramenta essencial na engenharia e na ciência, permitindo análises confiáveis com modelos em escala reduzida e a extrapolação eficaz dos resultados para estruturas reais.

#### **4.16 Trem-tipo: Definição e Aplicação em Engenharia Estrutural**

O trem-tipo é uma representação padronizada de cargas móveis utilizadas no dimensionamento de pontes rodoviárias. Ele simula os efeitos estáticos e dinâmicos provocados por veículos pesados, considerando eixos com cargas concentradas, espaçamentos fixos e uma carga distribuída adicional ao redor do veículo, conforme determina a norma brasileira ABNT NBR 7188:2024.

O modelo padrão é o TB-450 (ou TB-45), correspondendo a um carregamento total de 450 kN distribuído em três eixos de 75 kN cada, espaçados entre si por 1,5 m, e cercados por uma carga uniformemente distribuída de 5 kN/m<sup>2</sup>. A ABNT NBR 7188:2024 orienta que esses carregamentos sejam posicionados de forma a gerar os maiores efeitos possíveis sobre a estrutura.

Estudos de caso recentes, como o de Filgueira (2023), avaliam o desempenho de pontes submetidas a diferentes classes de trem-tipo (TB-36 x TB-91-26,5), onde se tem a comparação entre dois trens-tipo rodoviários o TB-36, que representa veículos antigos de 36 toneladas, e o TB-91-26,5, que simula composições modernas mais longas e pesadas, com 91 toneladas distribuídas em 26,5 metros.

Essa comparação avalia o impacto de cargas mais recentes sobre estruturas projetadas para cargas menores, demonstrando aumentos significativos nos esforços de momento fletor maior que 68 % e esforço cortante em até 24 %, decorrentes de cargas superiores às previstas originalmente. Esses resultados evidenciam que muitas pontes dimensionadas para trens-tipo mais antigos podem estar subdimensionadas para as classes atuais de tráfego.

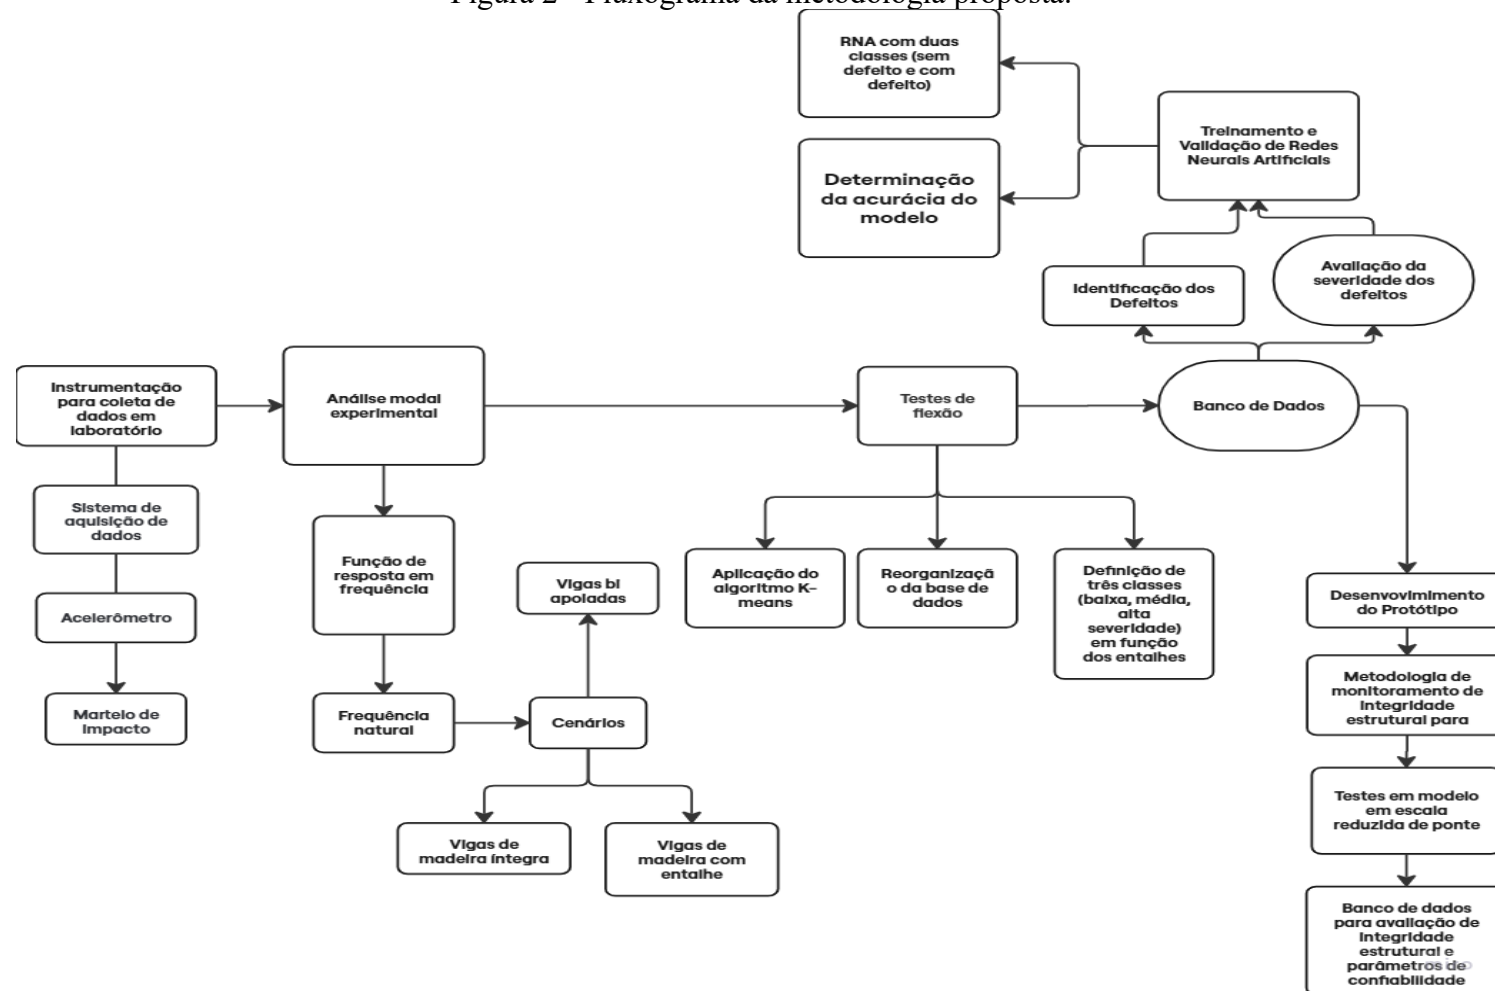
A utilização adequada dos trens-tipo, combinada com coeficientes de amplificação por número de faixas (CNF), impacto vertical (CIV) e carga adjacente (CIA), é fundamental para garantir que o dimensionamento estrutural seja conservador e realista, conforme analisado por Lima e Figueiredo (2023) e pela ABNT (2024).

## 5 MATERIAIS E MÉTODOS

A pesquisa foi desenvolvida a partir de duas frentes experimentais complementares. Inicialmente, foram utilizadas vigas de madeira com danos simulados para construção e validação do banco de dados para treinamento da inteligência artificial. Em seguida, a metodologia foi aplicada a um protótipo em concreto armado, em escala reduzida, permitindo avaliar a eficácia do modelo em uma estrutura mais complexa e representativa de uma ponte real.

Os trabalhos foram desenvolvidos no Laboratório de Vibrações Mecânicas da Universidade Federal de Lavras. Na Figura 2 é apresentada uma sistematização da metodologia proposta.

Figura 2 - Fluxograma da metodologia proposta.



Fonte: Da autora (2025).

## 5.1 Vigas de Madeira

Foram utilizadas 14 unidades de vigas de madeira para a realização da análise modal. Na Figura 3A, está representada uma dessas vigas, com espessura de 1,0 cm, largura de 4,5 cm e comprimento de 100 cm. Essas vigas foram apoiadas em uma base de madeira ajustável (Figura 3B) para permitir um suporte bi apoiado.

Figura 3 – Viga de Madeira e Base Ajustável.




Fonte: Da autora (2023).

Para os ensaios de flexão, foram extraídos corpos de prova das 14 vigas utilizadas na análise modal. Foram 4 unidades de igual tamanho extraídas de cada viga, totalizando 56 corpos de prova (Figura 4). As 56 unidades de corpos de prova foram avaliadas com base no comportamento estrutural das vigas de madeira. As especificações para avaliação incluíram fatores como resistência à flexão, como carga máxima, carga de ruptura e deslocamento.

O objetivo dos ensaios de flexão foi estabelecer uma correlação entre a progressão dos entalhes e a resistência mecânica das vigas, ajudando a entender como as vigas se comportam sob diferentes condições de carga e quais são os fatores que mais influenciam sua resistência.

Para a análise dos dados coletados na análise modal, foi empregado o *software LabVIEW* da *National Instruments*, uma ferramenta de programação gráfica amplamente utilizada para desenvolvimento de aplicativos de teste e medição, aquisição de dados, controle de processos, análise de sinais e desenvolvimento de sistemas embarcados (*NATIONAL INSTRUMENTS*, 2020).

Figura 4 - Corpos de prova resultantes.



Fonte: Da autora (2023).


### 5.1.1 Sistemas de aquisição de dados

Foi utilizado um sistema de aquisição de dados composto por um Chassi *CompactDAQ* cDAQ-9174 de 4 slots, projetado para operar em temperaturas entre  $-20^{\circ}\text{C}$  e  $55^{\circ}\text{C}$  e alimentado por USB. Esse chassi é ideal para sistemas portáteis de pequeno porte que realizam medições com sensores. Além disso, foi empregado um módulo de entrada de som e vibração de 4 canais NI9234, que oferece 4 canais de entrada analógica com uma faixa de tensão de  $-5$  a  $5\text{V}$  e uma taxa de amostragem máxima de  $51,2\text{ kS/s/ch}$ . Este módulo é capaz de medir sinais de sensores piezoelétricos com eletrônica embarcada (IEPE) e outros tipos de sensores.

Para os ensaios mecânicos, foi utilizado um computador portátil (Figura 5A), acelerômetros uniaxiais de alta sensibilidade fabricados pela PCB (Figura 5C), e um martelo de impacto fornecido com três ponteiros (metal, borracha e plástico), utilizado para excitar a estrutura e obter respostas dinâmicas (Figura 5B), da *National Instruments*, com as seguintes especificações: marca PCB *Piezotronics*<sup>TM</sup> e modelo PCB 086C03 com sensor de força.

Para a análise dos dados coletados, foi empregado o *software LabVIEW* da *National Instruments*, uma ferramenta de programação gráfica amplamente utilizada para desenvolvimento de aplicativos de teste e medição, aquisição de dados, controle de processos, análise de sinais e desenvolvimento de sistemas embarcados (*National Instruments*, 2020). Na Figura 5, estão ilustrados alguns componentes do sistema de aquisição de dados, incluindo o Chassi *CompactDAQ* cDAQ-9174, o módulo de entrada de som e vibração NI9234 e o computador portátil utilizado para controle e análise dos dados.

Figura 5 - Componentes do Sistema de aquisição de dados.




Legenda: (A) Sistema de Aquisição de Dados National Instruments; (B) Martelo de Impacto National Instruments; (C) Acelerômetro Uniaxial National Instruments.

Fonte: *National Instruments - AI (2020)*.

Para os ensaios mecânicos de flexão, foi utilizado um dispositivo para teste à flexão INSTRON EMIC 23-20, *Tension and Compression* da INSTRON BRASIL EQUIPAMENTOS CIENTÍFICOS LTDA, com célula de carga modelos CCE produzidas no Brasil, recomendadas para ensaios estáticos de tração, compressão e flexão. Na Figura 6, é apresentado o dispositivo para teste à flexão, que foi utilizado para realizar ensaios mecânicos de flexão. Para análise dos dados coletados no teste de impacto, foi empregado o software *LabVIEW* da *National Instruments*. O *LabVIEW* é uma ferramenta de programação gráfica amplamente utilizada para desenvolvimento de aplicativos de teste e medição, aquisição de dados, controle de processos, análise de sinais e desenvolvimento de sistemas embarcados (*National Instruments, 2020*).

Figura 6 - Dispositivo para teste à flexão INSTRON EMIC 23-20.



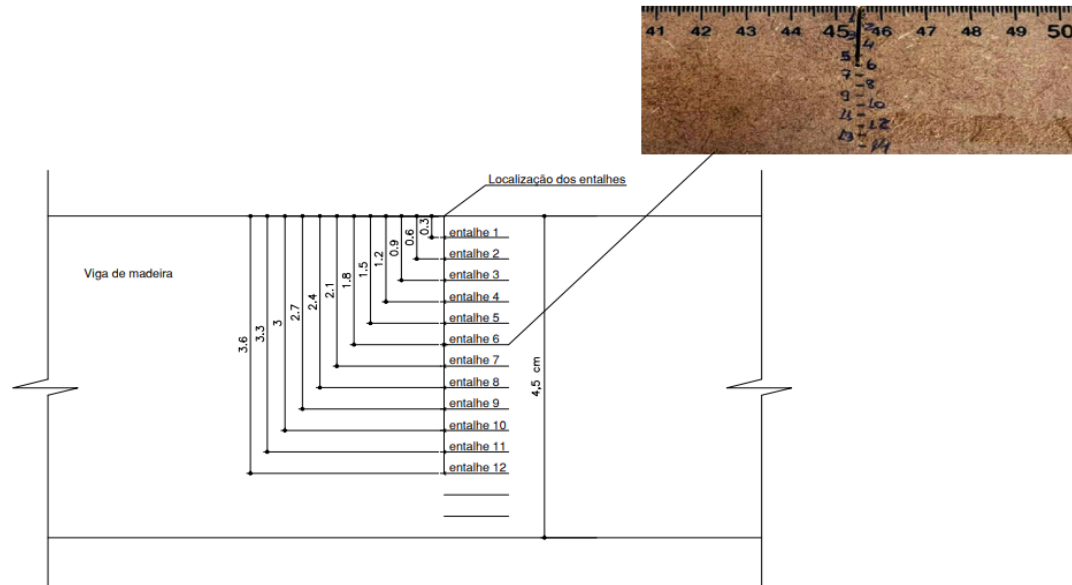
Fonte: Da autora (2023).

### 5.1.2 Ensaio utilizando o Testes de Impacto

Por meio de aferições diretas na viga, obteve-se a espessura de 1,0 cm, largura de 4,5 cm e comprimento de 100 cm, foram utilizadas 14 vigas, conforme demonstrada na Figura 3 A. O primeiro ensaio foi realizado na viga íntegra, sem entalhes. Os demais ensaios realizados nas vigas com defeitos induzidos, ou seja, entalhes ao longo da sua seção transversal a cada 0,3 cm, desta forma os entalhes considerados, foram respectivamente: 0,3 cm, 0,6 cm, 0,9 cm, 1,2 cm, 1,5 cm, 1,8 cm, 2,1 cm, 2,4 cm, 2,7 cm, 3,00 cm, 3,3 cm e 3,6 cm (FIGURA 7). Foram realizados ensaios de impacto com as três ponteiros (metal, borracha e plástico), em cada uma das 14 vigas com todos os entalhes e a média de 5 impactos para cada entalhe obtida.

Considerando o teste modal *Single Input and Single Output* (SISO), um acelerômetro para determinação da resposta da estrutura foi posicionado a  $\frac{1}{4}$  da viga, também a  $\frac{1}{4}$  do vão foi realizada uma excitação impulsiva a partir de martelo de impacto (FIGURA 8) considerando-se três ponteiros (FIGURA 3C). Foram realizados 5 impactos, para cada ponteira, em cada uma das condições da viga, sem defeito e com os defeitos induzidos em diferentes níveis a partir dos entalhes.

Figura 7 - Denominação e Viga de Madeira com entalhe (6 – 1,8 cm) com marcações.



Fonte: Autora (2023).

Para a obtenção dos dados, foram realizados testes de impacto (média de 5 impactos para cada entalhe), obtendo-se os dados das FRF com o software de pós-processamento, ao realizar testes de impacto, podemos obter as respostas dinâmicas da estrutura em diferentes pontos de medição. Esses dados poderão ser utilizados para identificar os modos naturais de vibração da estrutura, suas frequências naturais e formas modais associadas. Isso foi fundamental para entender o comportamento dinâmico da estrutura, podendo ser utilizado para diversos fins, como análise de vibração, projeto de sistemas de controle, entre outros.


A análise modal envolveu a realização de uma análise SISO (single input, single output), onde um único ponto é excitado e a resposta é medida em um único ponto, permitindo uma caracterização precisa dos modos modais da estrutura. Esses modos modais podem então ser utilizados para desenvolver modelos matemáticos que representam o comportamento dinâmico da estrutura.

Os dados de aceleração no domínio do tempo foram obtidos, armazenados e tratados por meio do software LabView®, a partir de um programa elaborado para a realização da aquisição de dados, com a função de apresentá-los enquanto lidos em tela na forma gráfica e numérica, em tempo real. As Funções de Resposta em Frequências (FRF) foram obtidas a partir de ensaios de impacto, utilizando o martelo de impacto e o pacote de processamento de sinais Sound and Vibration.

Foram utilizadas 14 réplicas nas diferentes condições propostas e submetidas à 5 impactos, onde a média foi obtida, com cada ponteira, onde a coerência do sinal como parâmetro de rejeição ou aceitação do teste foi utilizada, considerando-se as vigas em condição íntegra e não íntegras (com danos induzidos) de 0,3 cm a 3,6 cm.

Os pontos de excitação e medição da resposta foram determinados de forma a se obter as frequências de resposta (FRF) necessárias para a realização da análise modal. Os pontos de excitação tanto do acelerômetro, quanto dos impactos, foram posicionados a  $\frac{1}{4}$  do vão monitorado das respectivas vigas na condição biapoiada, conforme Figura 8.

Figura 8 - Representação do teste de impacto com seus equipamentos nas vigas de madeira biapoiadas.



Fonte: Da autora (2024).

Durante os ensaios de análise modal SISO, utilizou-se a coerência das funções como critério de aceitação dos resultados. Valores próximos de 1 indicaram boa correlação entre entrada e resposta do sistema, validando os dados coletados. As propriedades dinâmicas das vigas, como frequências naturais e modos de vibração, foram identificadas a partir de excitação com martelo de impacto e resposta registrada com acelerômetro de alta sensibilidade. Os sinais foram processados no *software Sound and Vibration*, que aplicou transformadas de *Fourier* para gerar as Funções de Resposta em Frequência (FRF), permitindo análise precisa dos parâmetros modais.

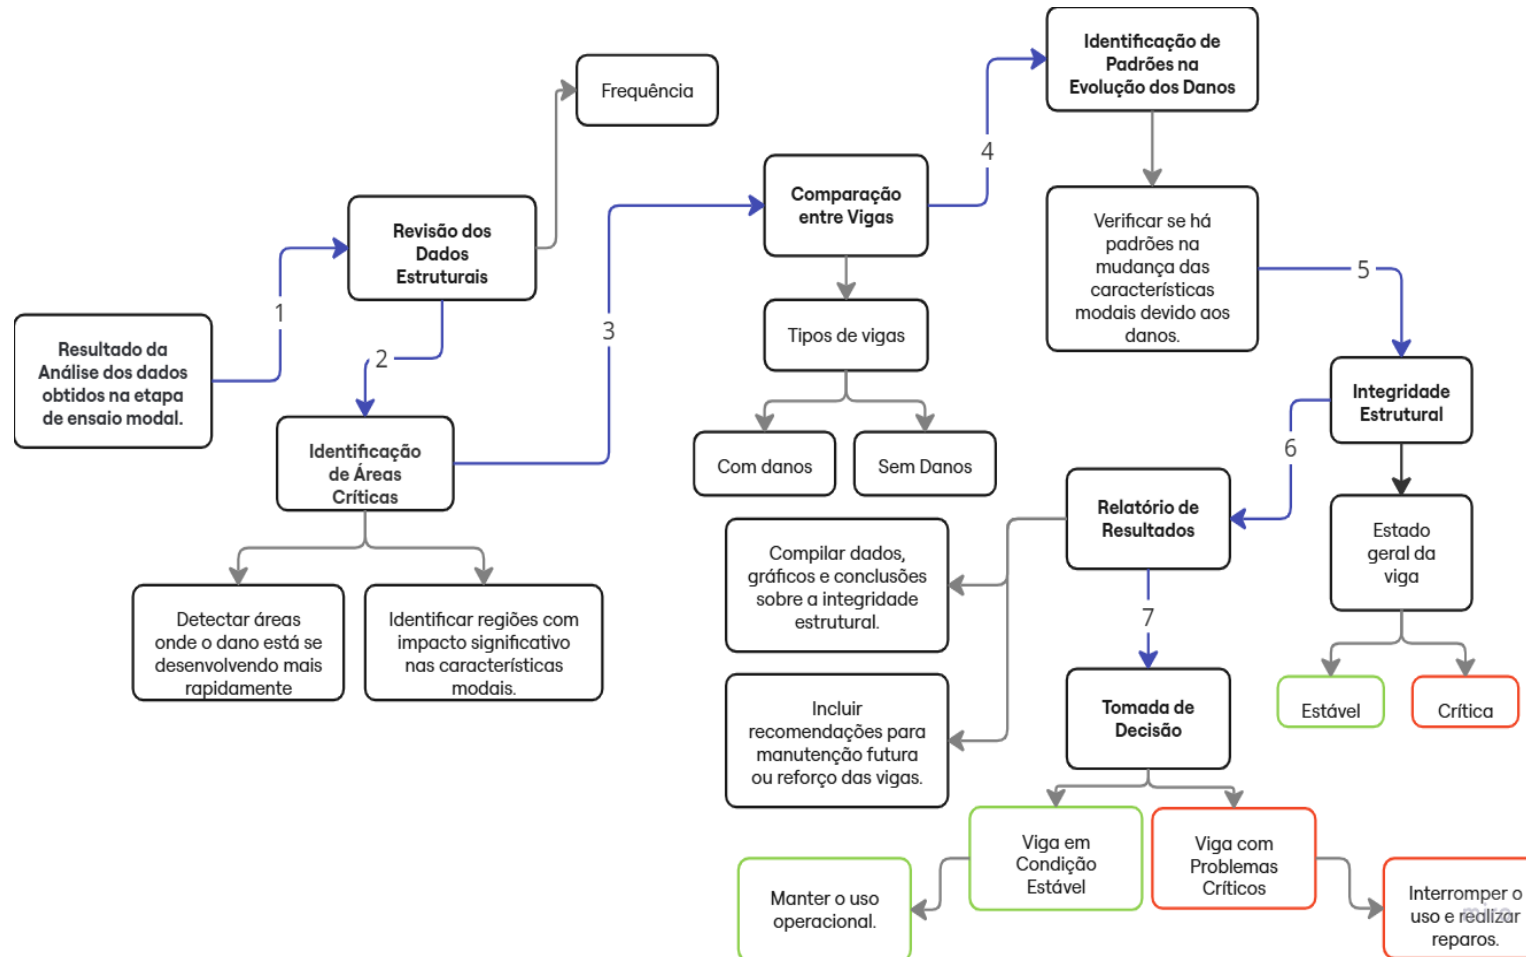
As vigas foram inicialmente testadas sem danos, servindo como referência. Em seguida, danos foram induzidos por entalhes progressivos, e novos ensaios foram realizados com diferentes ponteiras, possibilitando a obtenção de FRFs para cada condição. A evolução dos defeitos pôde ser observada após cada etapa de dano, conforme ilustrado na figura 7, que mostra a posição e profundidade crescente dos entalhes realizados na viga para indução progressiva de

danos estruturais, bem como uma imagem de apoio com a marcação real utilizada na peça ensaiada.

A análise envolveu etapas de pré-processamento (verificação da qualidade dos sinais e remoção de ruídos), identificação dos modos modais (frequências naturais, formas modais e amortecimento), e comparação entre as vigas intactas e danificadas. Essas comparações revelaram como as características modais foram alteradas pela presença e progressão dos danos.

A interpretação final focou na integridade estrutural das vigas, destacando regiões críticas e efeitos significativos dos defeitos nas propriedades dinâmicas. Os resultados foram consolidados em um relatório técnico com implicações práticas para o monitoramento e a operação segura das estruturas.

Figura 9 - Fluxograma de Interpretação dos resultados dos testes de impacto.



Fonte: Da autora (2024).

Essa estrutura, forneceu um caminho que pôde ser seguido para realizar uma análise modal eficaz e informativa das vigas, ajudando a entender melhor a condição estrutural das mesmas em diferentes estado, indicando um conjunto organizado de etapas que foram seguidas para realizar a análise modal experimental das vigas, para a análise dos dados obtidos da análise modal experimental, tanto as sem danos quanto as danificadas.

A interpretação dos resultados foi feita com cuidado, levando em consideração todos os aspectos relevantes do experimento e das condições de teste.

### **5.1.3 Ensaio à Flexão**

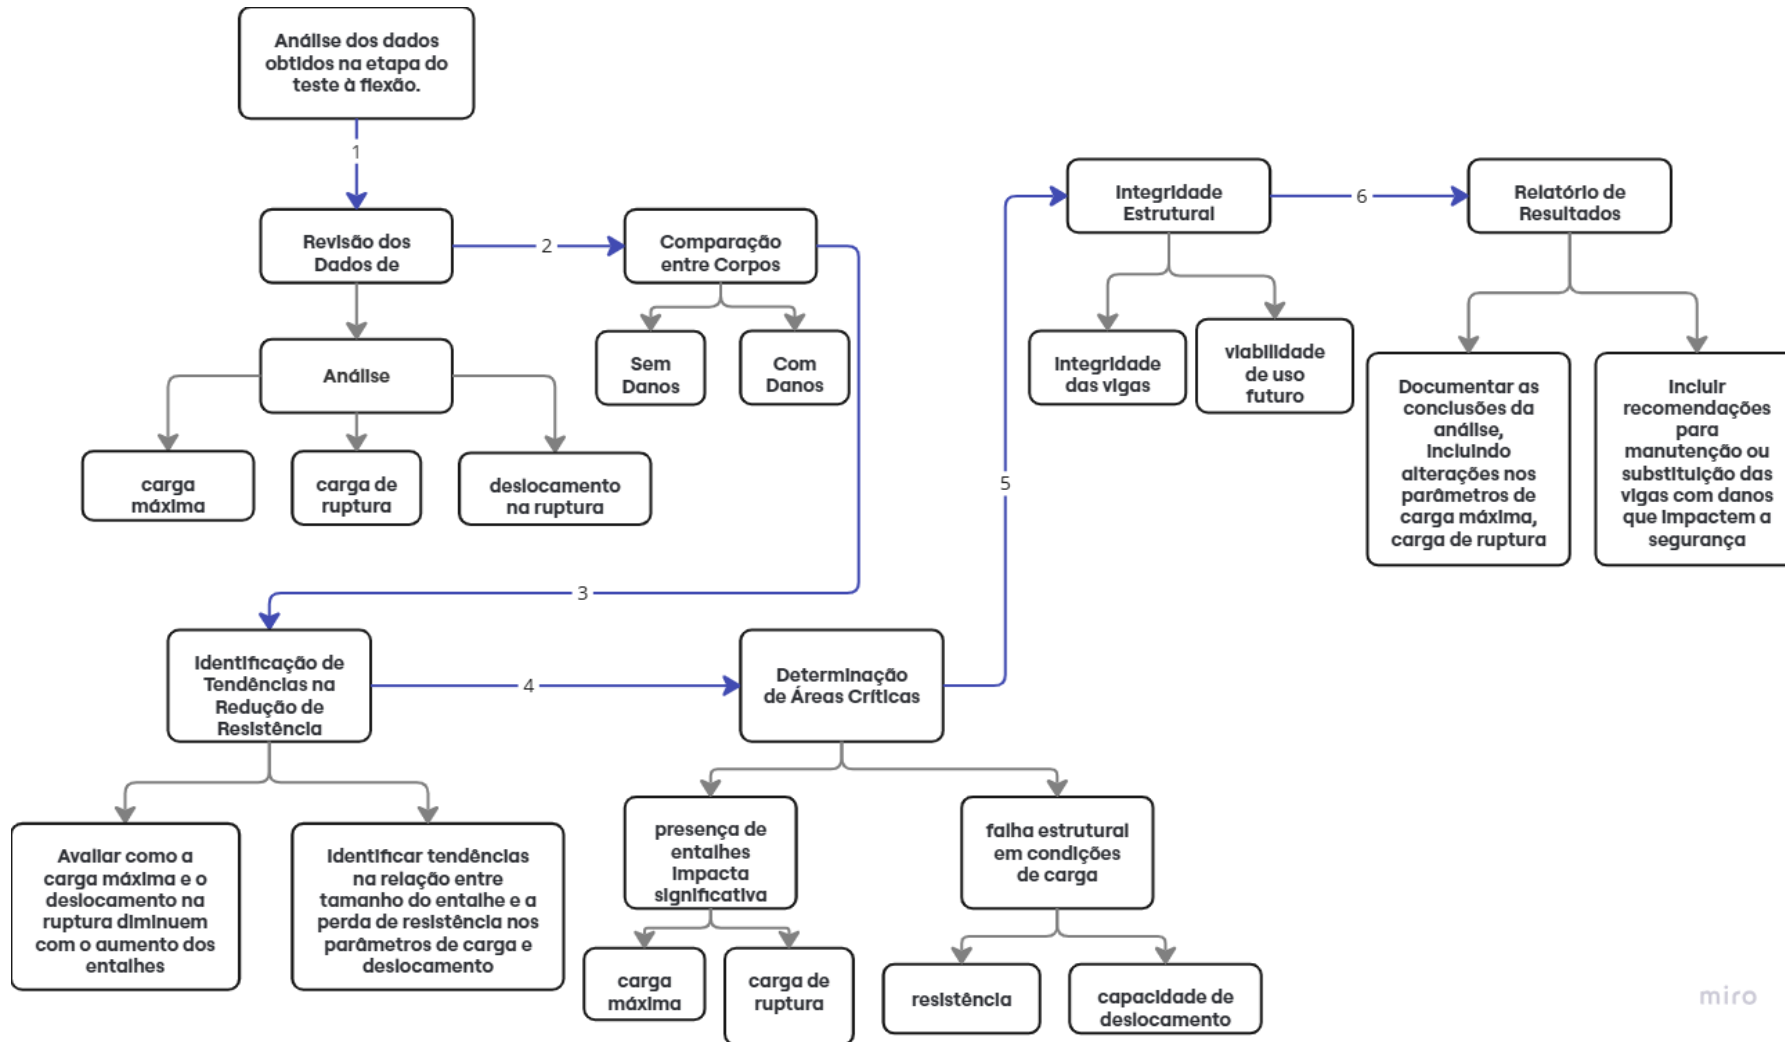
Foram utilizadas 14 vigas de madeira ( $1,0 \times 4,5 \times 100$  cm) apoiadas em base ajustável para análise modal. De cada viga, foram extraídos quatro corpos de prova com 22,5 cm, totalizando 56 unidades (FIGURA 4), usadas em ensaios de flexão para obtenção da carga máxima, carga de ruptura e deslocamento. Quatro corpos foram testados sem danos; os demais receberam entalhes progressivos de 0,30 cm.

O objetivo foi correlacionar as características modais com a resistência mecânica, avaliando como os danos afetam frequências naturais, formas modais, amortecimento e capacidade de carga. A análise das Funções de Resposta em Frequência (FRF) permitiu comparar vigas intactas e danificadas, evidenciando alterações nas propriedades dinâmicas e identificando áreas críticas.

A evolução dos danos nas vigas foi avaliada, analisando como as características modais variaram com o aumento do nível do defeito, como o aumento do tamanho dos entalhes progressivos.

Foi feita uma análise detalhada para identificar possíveis padrões ou tendências na evolução das danos. A interpretação dos resultados foi realizada, considerando todos os aspectos do experimento e das condições de teste.

Figura 10 - Fluxograma da etapa de interpretação de resultados do teste à flexão.



Fonte: Da autora (2024).

#### 5.1.4 Análise dos dados e aplicação de técnicas para identificação e predição de defeitos

Os principais fatores obtidos foram comparados às diferentes condições estruturais para desenvolver uma metodologia de monitoramento da integridade de um protótipo em escala. Foram analisados dados de vibração, imagens e falhas de material. A partir dessas análises, foi possível identificar causas de defeitos.

Foram utilizadas 14 vigas de madeira ( $1,0 \times 4,5 \times 100$  cm), inicialmente íntegras, apoiadas em base de madeira. Após o primeiro ensaio sem danos, foram introduzidos entalhes de 0,3 a 3,6 cm, em incrementos de 0,3 cm (FIGURA 7). Cada condição foi submetida a ensaios de impacto com três ponteiros (metal, borracha e plástico), com cinco impactos por entalhe para garantir repetibilidade. As respostas vibracionais coletadas permitiram calcular funções de resposta em frequência (FRF) e avaliar a integridade estrutural.

Em seguida, foram realizados ensaios de flexão em 56 corpos de prova extraídos das mesmas vigas. As variáveis analisadas incluíram carga máxima, carga de ruptura e deslocamento. Os dados foram utilizados para treinar Redes Neurais Artificiais (RNA), classificando as vigas em dois grupos (com e sem defeito) nos testes de impacto. Para os ensaios de flexão, utilizou-se o algoritmo *k*-means, classificando a severidade dos defeitos em três níveis (baixa, média e alta).

A uniformidade das dimensões das vigas garantiu a comparabilidade entre os ensaios. A metodologia permitiu correlacionar a profundidade dos entalhes com a resposta dinâmica e mecânica, fornecendo uma base sólida para aplicação de aprendizado de máquina na identificação e predição de falhas estruturais.

#### 5.1.5 Treinamento de Redes Neurais Artificiais (RNA)

Os dados coletados nos ensaios de impacto foram utilizados para treinar uma rede neural artificial (RNA), com o objetivo de classificar as vigas em duas categorias: “sem defeito” e “com defeito”, bem como identificar a severidade dos defeitos em três níveis: baixa, média e alta.

Para o treinamento da RNA, foram coletados dados de 14 vigas, cada uma com 13 entalhes progressivos, totalizando 71. 694 registros por tipo de ponteiro (plástico, borracha e metal), com 5. 121 medições de frequência por registro. Esses dados foram normalizados e divididos em 60% para treinamento e 40% para teste.

A arquitetura da RNA foi definida com base em testes sucessivos. Inicialmente, utilizou-se uma única camada oculta, variando o número de neurônios entre 5 e 200, de forma a identificar a configuração com melhor desempenho. Em seguida, foi adotada uma arquitetura com duas camadas ocultas, também com variação do número de neurônios em cada camada, para avaliar possíveis melhorias na capacidade de generalização da rede.

A camada de entrada continha 5.121 amostras (correspondentes às frequências registradas), e a camada de saída era composta por três classes, representando os níveis de integridade das vigas. Utilizou-se a função de ativação *ReLU* nas camadas ocultas, *Softmax* na saída, a função de perda *categorical\_crossentropy* e o otimizador *Adam*. O treinamento foi realizado por 200 épocas, com lotes de 40 amostras e validação de 20% dos dados de treino.

A performance dos modelos foi avaliada com base na acurácia, índice Kappa e análise da matriz de confusão, permitindo verificar os casos de erros de classificação (falsos positivos e falsos negativos). Esses procedimentos foram repetidos separadamente para cada tipo de ponteira (plástico, borracha e metal), permitindo analisar o desempenho da RNA em diferentes condições de excitação.


Além disso, foi utilizado o algoritmo *k-means* para realizar o agrupamento dos resultados dos ensaios de flexão, com base na carga máxima, carga de ruptura e deslocamento, classificando a severidade dos defeitos nos três mesmos níveis (baixa, média e alta), de acordo com a profundidade dos entalhes.

A abordagem desenvolvida para as vigas de ensaio foi aplicada também ao modelo em escala reduzida (protótipo), visando verificar a capacidade da RNA em prever a integridade de estruturas em condições mais próximas à realidade, com base nas respostas de vibração.

## 5.2 Protótipo em Escala reduzida


Um protótipo em escala de uma ponte foi utilizado para cobrir um vão livre de 12,00 m, representando uma versão reduzida da estrutura de uma ponte projetada. O projeto da ponte conta com quatro pilares de 0,50 x 0,50 m, duas vigas de 1,20 m x 0,50 m e um tabuleiro de 12,00 x 4,20 m, com a altura até o espelho d'água de 4,5 m até a viga em concreto armado de 1,20 m até o tabuleiro também em concreto armado, de acordo com a Figura 11 e 12. O trem-tipo padrão para pontes e viadutos atualmente é o TB-45, detalhado pela ABNT NBR 7188:2013. O carregamento consiste em um veículo tipo de 450 kN com três eixos, seis rodas, 75 kN cada. Os eixos são afastados 1,5 m entre si.

Figura 11 - Vista do Tabuleiro.



Fonte: Da autora (2023).

Figura 12 - Corte AA.



Fonte: Da autora (2023).

A ponte foi dimensionada segundo a ABNT NBR 7188 para suportar um trem-tipo TB-45 (450 kN), com estrutura composta por pilares de  $0,50 \times 0,50 \times 5,70$  m, vigas de  $1,20 \times 0,50$  m e tabuleiro de  $12,00 \times 4,20 \times 0,30$  m.

As formas foram planejadas para resistir à pressão do concreto fresco, utilizando compensado plastificado, escoramentos e travamentos adequados.

A armadura foi projetada conforme a ABNT NBR 6118, com barras de aço CA-50 e CA-60 em configurações específicas para pilares, vigas e tabuleiro.


O concreto, com resistência de 50 Mpa, foi dosado com cimento CP V-ARI, brita 1, areia, água e aditivo superplastificante, mantendo abatimento de  $8 \pm 2$  cm.

Foram adotados cobrimentos de 3,0 cm (pilares e vigas) e 2,5 cm (tabuleiro), com controle rigoroso da qualidade do concreto e montagem adequada das armaduras.

Para a construção do protótipo da ponte em escala reduzida (1:10), aplicou-se o conceito de semelhança estrutural, garantindo que o modelo representasse fielmente o comportamento da estrutura real. A escala foi adotada para todas as dimensões lineares, com redução proporcional das áreas (1/100) e volumes (1/1000), incluindo a adaptação das cargas aplicadas ao fator cúbico. O modelo manteve as proporções geométricas e estruturais da ponte original, possibilitando a realização de ensaios experimentais com fidelidade às condições reais.

O protótipo foi construído com materiais compatíveis e dimensões proporcionais: os pilares (Figura 13A) possuem  $0,05 \times 0,05 \times 0,57$  m, as vigas principais (Figura 13B) medem  $0,12 \times 0,05$  m, e o tabuleiro 1,20 m de comprimento  $\times$  0,42 m de largura  $\times$  0,03 m de espessura. Essas figuras ilustram a configuração física e os detalhes construtivos do modelo utilizado nos testes.

Figura 13- Forma para concepção do Protótipo.



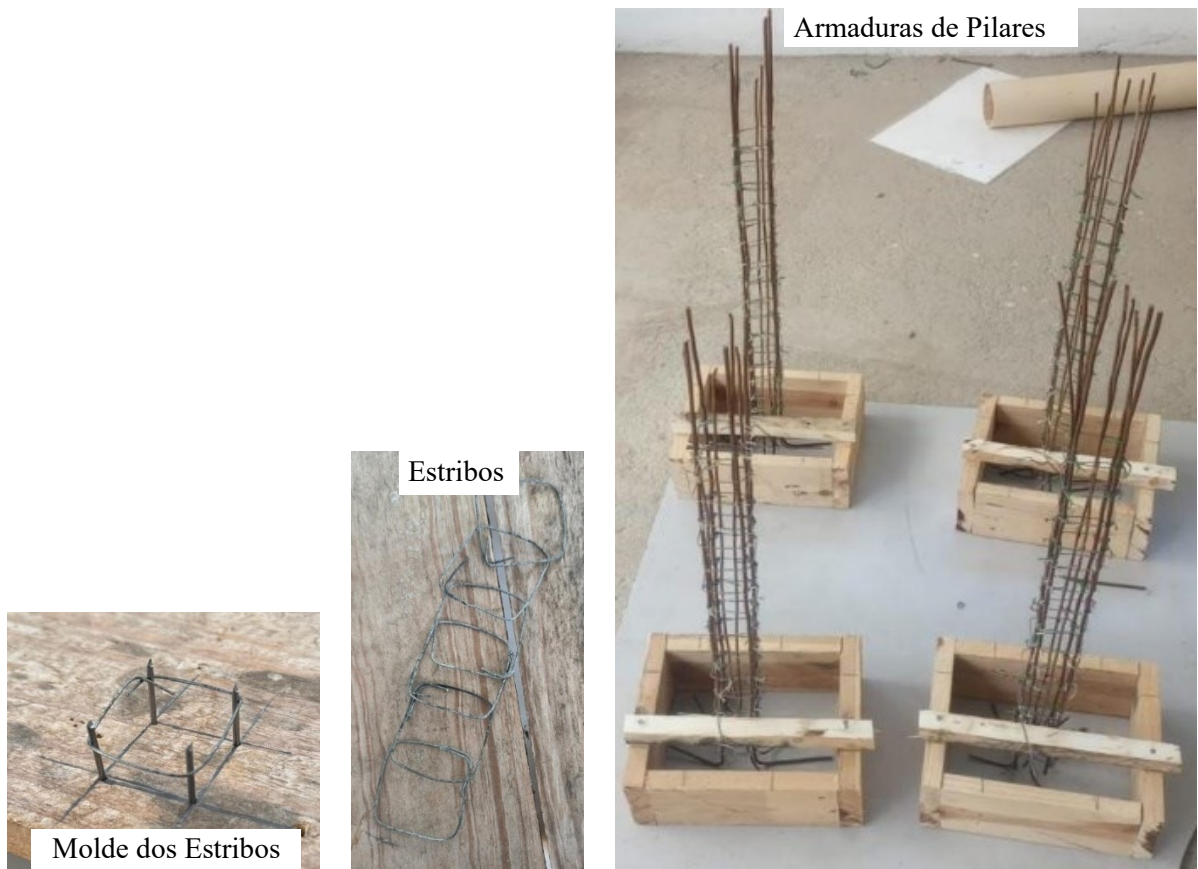
Legenda: (A) Forma dos Pilares e Blocos da fundação, (B) Forma das Vigas e Tabuleiro.

Fonte: Da autora (2025).

As formas do protótipo foram dimensionadas para suportar o peso reduzido do concreto e garantir a precisão geométrica. Utilizaram-se compensados de 6 mm nos pilares ( $0,05 \times 0,05 \times 0,57$  m), vigas ( $0,12 \times 0,05$  m) e tabuleiro ( $1,20 \times 0,42 \times 0,03$  m), conforme ilustrado na Figura 13B. Os apoios (blocos de fundação) foram executados com  $0,10 \times 0,10 \times 0,05$  m, como mostra a Figura 13A, proporcionando estabilidade ao conjunto.

A armadura foi adaptada proporcionalmente à escala, com fios de aço compatíveis. Nos pilares (FIGURA 14), utilizaram-se 8 fios CA-50 de  $\varnothing$  1,6 mm na armadura longitudinal e estribos de  $\varnothing$  0,8 mm espaçados a 2 cm. Nas vigas (FIGURA 15), foram usados 6 fios CA-50 de  $\varnothing$  2,0 mm (superior e inferior) e estribos de  $\varnothing$  1,0 mm a cada 2 cm. O tabuleiro (FIGURA 16) foi armado com fios  $\varnothing$  1,6 mm (malha superior),  $\varnothing$  1,2 mm (inferior), ambos a cada 2 cm, e  $\varnothing$  0,8 mm (camada de precisão) a cada 1,5 cm.

Figura 14 - Armação de Pilares.



Fonte: Da autora (2025).

Figura 15 - Armação de Vigas.



Fonte: Da autora (2025).

Figura 16 - Armação do Tabuleiro.



Fonte: Da autora (2025).


Para a dosagem do concreto no protótipo em escala reduzida, foram feitos ajustes que garantiram resistência e trabalhabilidade compatíveis. A brita convencional foi substituída por brita 0 (granulometria  $< 6$  mm), e foi utilizada areia com granulometria mais uniforme, favorecendo uma mistura mais coesa e fluida.

A relação água/cimento foi mantida em torno de 0,40, com uso de superplastificantes para preservar a fluidez sem comprometer a resistência.

Devido à escala, a cura exigiu controle rigoroso da umidade para evitar fissuras. A concretagem foi realizada em camadas finas para evitar segregação, conforme ilustrado na Figura 17. Os cobrimentos foram de 3,0 mm (pilares e vigas) e 2,5 mm (tabuleiro).

A dosagem para 10 litros incluiu: 4,5 kg de cimento, 6,5 kg de areia fina, 11 kg de areia grossa, 1,8 litros de água e 0,54 kg de aditivo. No total, foram utilizados aproximadamente 42 litros de concreto no protótipo, correspondendo a 18,90 kg de cimento, 27,3 kg de areia fina, 46,2 kg de areia grossa, 7,56 litros de água e 2,268 kg de aditivo.

Figura 17 - Concretagem e desforma do Protótipo.



Legenda: (A) Concretagem da Fundação; (B) Concretagem das Vigas, pilares e Tabuleiro, (C) Desforma do Protótipo.

Fonte: Da autora (2025).

### 5.2.1 Sistemas de aquisição de dados

O sistema de aquisição de dados para o protótipo também utilizou o Chassi *CompactDAQ* cDAQ-9174 com módulo NI9234 para captação de sinais de acelerômetros IEPE. Ensaios foram realizados com martelo de impacto com a ponteira de plástico e acelerômetros uniaxiais da PCB, com análise dos dados no software *LabVIEW*, demonstrado na Figura 3.


### 5.2.2 Ensaios preliminares de Monitoramento do Protótipo

O monitoramento do protótipo foi realizado em dois pontos de excitação, denominados IA e IB (FIGURA 18). Para isso, foram utilizados acelerômetros posicionados em 12 pontos distintos, também indicados na Figura 18.

Cada ponto foi submetido a cinco repetições de impacto, totalizando 20 ciclos de monitoramento por ponto. Em cada ciclo, os impactos foram realizados nos pontos A e B, com os acelerômetros fixados em um dos 12 pontos de medição. Os dados foram coletados a cada cinco impactos, garantindo a repetição e confiabilidade das medições.

As seções de monitoramento foram demarcadas dividindo-se o protótipo em quatro seções no sentido da largura. No sentido longitudinal, os pontos foram marcados a 10 cm das extremidades em direção ao centro, e a 10 cm para os lados esquerdo e direito do eixo central, permitindo um mapeamento preciso da resposta dinâmica da estrutura. Esse monitoramento foi realizado com o protótipo em condição de integridade.

Figura 18 - Cenário do Protótipo em condição de integridade.



Legenda: (Ac) Acelerômetro; (I) Impacto.

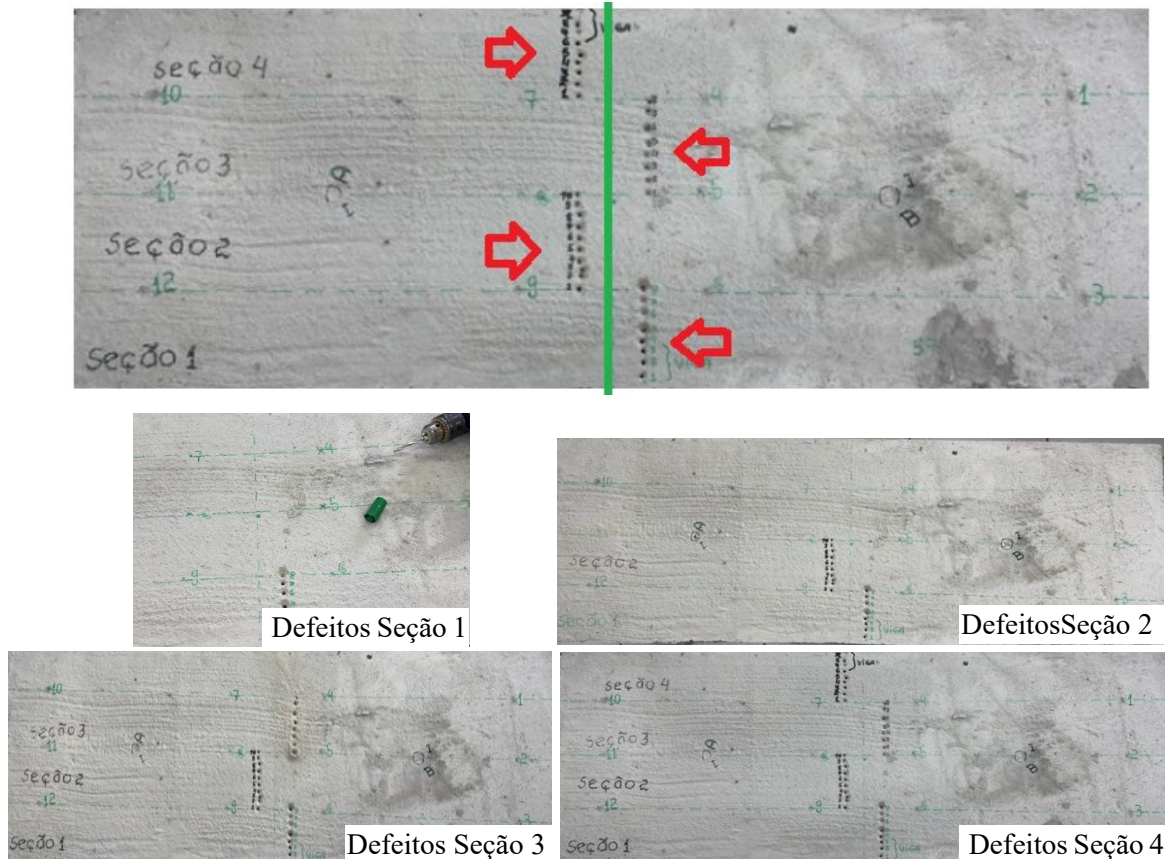
Fonte: Da autora (2025).

O monitoramento do protótipo em condições de defeitos induzidos foi realizado com a introdução de defeitos progressivos ao longo da estrutura. Para isso, foram feitos furos em cada uma das quatro seções do protótipo conforme ilustrado na figura 19, localizados ao longo do eixo central. Os furos foram intercalados entre as seções e executados com uma furadeira Bosch equipada com broca específica para concreto de 10 mm de diâmetro.

A introdução dos defeitos seguiu quatro níveis de progressão, do nível inicial até o nível crítico, com o objetivo de avaliar como a integridade estrutural era afetada em diferentes estágios de dano.

Em cada estágio, foram realizadas medições dinâmicas semelhantes às do cenário de integridade, permitindo o acompanhamento sistemático da evolução dos defeitos e da resposta da estrutura à medida que se intensificavam.

Figura 19 - Cenários do Protótipo em condição de defeitos nas seções 1, 2, 3 e 4.



Fonte: Da autora (2025).

Na análise modal experimental por excitação impulsiva, foram realizados impactos controlados nos pontos IA e IB do protótipo, com repetições de cinco impactos por ponto de medição, totalizando 20 coletas por ponto (Ac). As respostas dinâmicas foram captadas por acelerômetros de alta sensibilidade, posicionados em 12 pontos diferentes da estrutura, conforme o plano de monitoramento.

Os dados coletados foram processados no *software Sound and Vibration*, que permitiu a obtenção das FRF, necessárias para a realização da análise modal, onde a coerência do sinal como parâmetro de rejeição ou aceitação do teste foi utilizada. A partir dessas funções, foi possível identificar os modos de vibração, incluindo frequências naturais, formas modais e amortecimento da estrutura, tanto em condição íntegra quanto sob diferentes níveis de falha induzida por furos progressivos de 10 mm de diâmetro.

Em seguida, os dados foram utilizados em algoritmos de aprendizado de máquina supervisionado, com o objetivo de reconhecer padrões e prever a progressão dos defeitos estruturais. A precisão das medições foi essencial para garantir a eficácia dos modelos, possibilitando uma avaliação confiável da integridade estrutural do protótipo ao longo dos ensaios.

### 5.2.3 Teste de Impacto

O modelo em escala foi submetido a ensaios de impacto com o objetivo de gerar um conjunto robusto de dados para o treinamento de redes neurais artificiais (RNA). Para garantir a precisão das medições, foram instalados acelerômetros de alta sensibilidade em 12 pontos estratégicos do protótipo. Os impactos foram aplicados com martelo instrumentado nos pontos IA e IB, e cada ponto (Ac) foi monitorado com repetições controladas de cinco impactos, em 20 coletas, totalizando uma base de dados rica e confiável.

Durante os ensaios, foi utilizada a ponteira de plástico (PP) no martelo de impacto, por apresentar melhor desempenho em comparação às ponteiros de borracha (PB) e de metal (PM) no tipo de estrutura ensaiada, proporcionando uma resposta mais estável e compatível com o comportamento dinâmico do protótipo.

As respostas dinâmicas da estrutura, como frequências naturais, amplitudes e formas modais, foram processadas com o *software Sound and Vibration*, resultando nas Funções de Resposta em Frequência (FRF).

Esses dados permitiram identificar com clareza as alterações provocadas pelos defeitos induzidos, comprovando a eficácia da metodologia baseada em vibração na caracterização do comportamento estrutural.

Os dados foram organizados em formato compatível com algoritmos de aprendizado supervisionado e também utilizados no treinamento de uma rede neural artificial (RNA). A partir das respostas dinâmicas obtidas por meio de excitações com martelo de impacto, foi possível identificar com clareza as alterações estruturais provocadas pelos defeitos induzidos, demonstrando a eficácia da análise modal baseada em vibração na detecção de mudanças na integridade da estrutura.

### 5.2.4 Análise dos dados e aplicação de técnicas para identificação e predição de defeitos

Os dados obtidos nos ensaios de impacto no protótipo, com diferentes níveis de integridade estrutural, foram processados por meio do *software Sound and Vibration*, resultando nas Funções de Resposta em Frequência (FRF).

A partir dessas respostas dinâmicas, foi possível identificar alterações associadas à presença e progressão dos defeitos. Parte desse conjunto de dados também foi aproveitada para treinar modelos computacionais capazes de reconhecer padrões vibratórios relacionados aos níveis de dano.

### 5.2.5 Treinamento de Redes Neurais Artificiais (RNA) no Protótipo

Os dados coletados nos ensaios de impacto foram utilizados para treinar uma rede neural artificial (RNA), com o objetivo de classificar os danos induzidos “graus” conforme Tabela 1: “Intacto – defeito grau 0 (sem dano)”, “Seção 1 - defeito grau 1 (dano leve)”, “Seção 2 - defeito grau 2 (dano leve/médio)”, “Seção 3 - defeito grau 3 (dano moderado)” e “Seção 4 - defeito grau 4 (dano severo)”.

Tabela 1 - Amostras correspondentes às classes demonstradas.

Grau	Condição Estrutural
0	Intacto - defeito grau 0 (sem dano)
1	Seção 1 - defeito grau 1 (dano leve)
2	Seção 2 - defeito grau 2 (dano leve/médio)
3	Seção 3 - defeito grau 3 (dano moderado)
4	Seção 4 - defeito grau 4 (dano severo)

Fonte: Da autora (2025).

Para a construção do banco de dados utilizado no treinamento da Rede Neural Artificial (RNA), foram realizadas coletas de resposta dinâmica por meio de doze acelerômetros (Ac), instalados em quatro seções distintas ao longo do protótipo em escala reduzida de uma ponte de concreto armado. As condições estruturais sob as quais os dados foram obtidos estão ilustradas na Figura 18, representando o estado intacto da estrutura, e na Figura 19, que apresenta os defeitos induzidos progressivamente nas seções 1, 2, 3 e 4.

Os impactos foram aplicados com um martelo dotado de ponteira plástica, em dois pontos previamente definidos na estrutura, denominados IA e IB. Cada acelerômetro foi

submetido a cinco impactos repetidos em cada coleta, totalizando vinte coletas por ponto. O conjunto completo resultou em 2.400 registros, cada um contendo 5.121 medições espectrais.

Para o treinamento da RNA, foram selecionados os dados provenientes de quatro acelerômetros (Ac2, Ac5, Ac8 e Ac11), escolhidos com base em sua localização e sensibilidade às variações estruturais. A análise espectral considerou as frequências compreendidas entre 1 e 2.560 Hz, intervalo no qual se concentram as respostas modais mais relevantes observadas durante os ensaios.

As condições estruturais utilizadas para o treinamento, foram 3 classes: classe 1, correspondente à estrutura intacta (grau 0); classe 2, referente ao defeito de (grau 2) induzido na seção 2 (representando dano leve/médio); e classe 3, associada ao defeito de grau 4 induzido na seção 4 (dano severo), conforme definido na Tabela 1. A Tabela 2, mostra as classes utilizadas.

Tabela 2 - Classes utilizadas no treinamento da RNA.

Classe	Condição Estrutural
1	Intacto - defeito grau 0 (sem dano)
2	Seção 2 - defeito grau 2 (dano leve/médio)
3	Seção 4 - defeito grau 4 (dano severo)

Fonte: Da autora (2025).

Os dados extraídos foram organizados em uma matriz contendo vetores espectrais obtidos pelos quatro sensores selecionados. Cada vetor foi normalizado individualmente e rotulado com a respectiva classe estrutural, totalizando 5.120 amostras. Os rótulos de classe foram posteriormente convertidos em codificação do tipo one-hot, possibilitando o treinamento supervisionado da rede. A implementação foi realizada na linguagem R, com o uso dos pacotes keras 3 e tensorflow.

Foram testadas duas abordagens de arquitetura, a primeira, com uma única camada oculta, variando o número de neurônios de 5 a 50 em incrementos de 5 e a segunda, com duas camadas ocultas, também com variações no mesmo intervalo. Em ambas as configurações, utilizaram-se camadas densas com função de ativação do tipo ReLU (Rectified Linear Unit), além de uma camada de saída com três neurônios e ativação softmax, correspondente às três classes analisadas.

O conjunto de dados foi aleatoriamente particionado em 60 % para treinamento e 40 % para teste, sendo que 20 % do conjunto de treinamento foi reservado para validação interna em

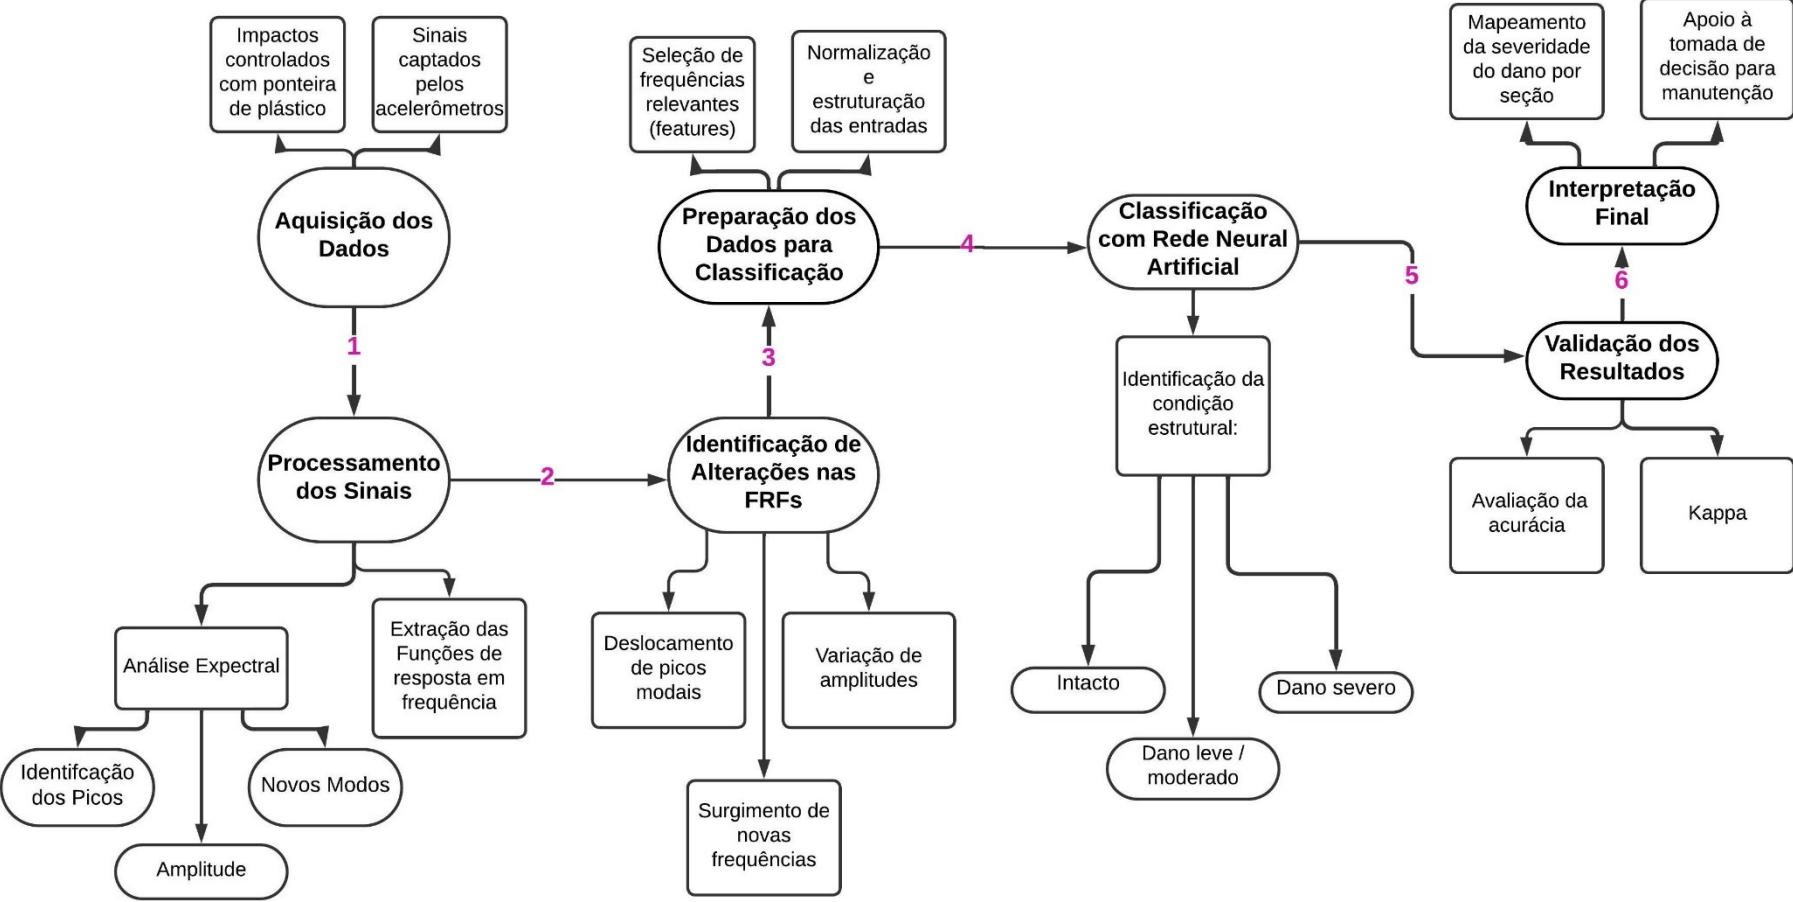
cada época. O treinamento foi realizado com a função de perda `categorical_crossentropy`, utilizando o otimizador `adam`, com um total de 200 épocas e tamanho de lote (batch size) igual a 40.

Ao final do treinamento, os modelos foram avaliados com base no conjunto de teste, sendo as previsões decodificadas da codificação one-hot para rótulos inteiros graus (0, 2 e 4), o que permitiu a comparação direta com os valores reais.

As métricas de avaliação consideradas foram a acurácia global, o índice Kappa e a matriz de confusão, permitindo a identificação de falsos positivos e falsos negativos. Os cálculos foram realizados com o pacote `caret`. Os resultados de acurácia e Kappa para cada arquitetura testada foram organizados em matrizes estruturadas conforme o número de neurônios por camada, sendo posteriormente consolidados em uma matriz única de resultados, utilizada para análise comparativa do desempenho entre os modelos de RNA avaliados.

A Figura 20 mostra um mapa mental da interpretação dos resultados para os ensaios no Protótipo de Concreto armado em escala reduzida.

Figura 20 - Mapa mental da interpretação dos resultados para os ensaios no protótipo de concreto armado em escala reduzida.



Fonte: Da autora (2025).


## 6 RESULTADOS E DISCUSSÕES

### 6.1 Resultados e discussões obtidas nas vigas da madeira

#### 6.1.1 Análise Modal


As Figuras 21, 22 e 23 apresentam a resposta espectral das vigas submetidas à excitação com as três ponteiros do martelo de impacto (MI): plástico (PP), metal (PM) e borracha (PB), em diferentes estágios de entalhes. Cada tipo de ponteira influenciou de maneira distinta a qualidade do sinal obtido e o desempenho do modelo de rede neural artificial (RNA) utilizado para a classificação da integridade estrutural das vigas.

Figura 21 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PP (frequência em Hz; magnitude em dB).




Fonte: Da autora (2024).

Figura 22 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PM (frequência em Hz; magnitude em dB).



Fonte: Da autora (2024).

Figura 23 - Resposta obtida no ensaio de impacto das vigas submetidas ao MI para as PB. (frequência em Hz; magnitude em dB).



Fonte: Da autora (2024).

A ponteira de plástico (PP) gerou excitações de baixa energia, com maior resolução nas frequências naturais de baixa ordem. Isso favoreceu a identificação de alterações sutis no comportamento dinâmico das vigas, especialmente nos estágios iniciais de dano. As respostas espectrais foram limpas e apresentaram variações claras e progressivas conforme o aumento dos entalhes, facilitando o aprendizado da RNA.

Como resultado, o modelo treinado com esses dados teve excelente desempenho na identificação de defeitos de baixa severidade, demonstrando que a ponteira de plástico é particularmente eficaz para aplicações que exigem detecção precoce de falhas.

Por sua vez, a ponteira de metal (PM) produziu excitações mais energéticas, capazes de ativar modos vibracionais superiores. Isso se refletiu em deslocamentos mais intensos no espectro e no surgimento de novos picos em faixas de frequência mais altas, o que tornou essa ponteira ideal para a detecção de danos mais severos.

Apesar de o sinal gerado apresentar maior nível de ruído, o modelo de RNA treinado com esses dados demonstrou bom desempenho na identificação de danos estruturais avançados, evidenciando a utilidade dessa ponteira para avaliações de integridade em estágios mais críticos. No entanto, foi necessário um maior cuidado no pré-processamento dos dados para garantir a eficácia do treinamento.

A ponteira de borracha (PB), por sua vez, apresentou resposta espectral mais atenuada e concentrada nas baixas frequências. Sua menor rigidez gerou excitações suaves, resultando em espectros com menor amplitude e menor excitação dos modos vibracionais superiores. Essa condição dificultou a diferenciação entre os diferentes níveis de dano apenas com base nas respostas espectrais, já que houve maior sobreposição dos espectros entre os ensaios.

Apesar disso, os sinais gerados apresentaram baixo ruído e boa estabilidade, o que contribuiu para aumentar a robustez e a capacidade de generalização do modelo de RNA, especialmente em contextos que simulam condições operacionais mais suaves. Dessa forma, verifica-se que nenhuma das ponteiras, isoladamente, é ideal para todas as situações de detecção de defeitos.

A ponteira de plástico mostrou-se mais eficaz para detectar danos iniciais, a ponteira de metal teve melhor desempenho em casos de falhas severas e a ponteira de borracha complementou o modelo com dados menos agressivos, favorecendo a estabilidade da rede. A combinação dos três conjuntos de dados foi fundamental para o treinamento de um modelo de RNA robusto, capaz de identificar diferentes níveis de integridade estrutural com maior confiabilidade.

O Quadro 1 mostra um resumo comparativo dos resultados obtidos com as três ponteiros (plástico, metal e borracha), para as contribuições e limitações na identificação de defeitos estruturais via redes neurais.

Quadro 1 - Resumo comparativo dos resultados obtidos com as três ponteiros.

<b>Característica</b>	<b>Ponteira de Plástico</b>	<b>Ponteira de Metal</b>	<b>Ponteira de Borracha</b>
<b>Conteúdo energético do</b>	Médio	Alto	Baixo
<b>Frequências excitadas</b>	Baixas a médias	Baixas a altas	Predominantemente baixas
<b>Diferenciação entre entalhes</b>	Moderada	Alta	Baixa
<b>Ruído de alta frequência</b>	Controlado	Elevado	Muito baixo
<b>Sensibilidade a danos severos</b>	Moderada	Alta	Baixa
<b>Sensibilidade a danos iniciais</b>	Boa	Moderada	Boa
<b>Qualidade da resposta espectral</b>	Boa, com picos nítidos	Ótima, porém ruidosa	Suave e limpa, mas com menor variação entre estados
<b>Desempenho esperado da RNA</b>	Bom equilíbrio entre generalização e precisão	Alta precisão para danos significativos	Melhor generalização para pequenos danos

Fonte: Da autora (2025).

### 6.1.2 Ensaios à Flexão

A partir dos ensaios de flexão em 56 corpos de prova representados na Figura 24, foram obtidos parâmetros como força máxima à flexão, força de ruptura e deslocamento na ruptura, demonstrados na Tabela 3, esses dados oriundos dos ensaios de flexão foram empregados na determinação das classes utilizadas para classificação da severidade de falha em três níveis: baixo, médio e alto para aplicação na técnica de aprendizado não-supervisionado.

Figura 24 - Corpos de prova submetidos ao teste de flexão.



Fonte: Da autora (2023).

Tabela 3 - Resultados Médios dos parâmetros mecânicos obtido a partir do ensaio à flexão.

Vigas	Máxima Carga (N)	Carga em Ruptura (N)	Deslocamento à flexão em Ruptura (mm)
Sem Entalhe	773,82	405,98	5,42
Entalhe - 0,3 cm	688,46	326,63	4,24
Entalhe - 0,6 cm	647,07	330,62	3,89
Entalhe - 0,9 cm	576,71	309,45	4,06
Entalhe - 1,2 cm	522,19	267,85	3,81
Entalhe - 1,5 cm	442,58	240,96	4,17
Entalhe - 1,8 cm	423,56	223,16	4,14
Entalhe - 2,1 cm	368,07	184,73	3,89
Entalhe - 2,4 cm	298,79	147,47	3,89
Entalhe - 2,7 cm	274,53	131,43	3,88
Entalhe - 3,0 cm	221,00	120,55	3,57
Entalhe - 3,3 cm	189,76	105,48	3,02
Entalhe - 3,6 cm	189,76	78,79	2,95
Entalhe - 3,9 cm	84,11	43,36	3,42

Fonte: Da autora (2024).

Na Tabela 4 estão as estatísticas descritivas calculadas para os dados do ensaio à flexão a partir dos dados obtidos.

Tabela 4 - Estatísticas descritivas do ensaio à flexão.

Medida	Máxima Carga (N)	Carga em Ruptura (N)	Deslocamento à Flexão em Ruptura (mm)
Média	407,17	208,53	3,89
Desvio padrão (std)	211,05	109,16	0,59
Coef. de variação (cv %)	51,83%	52,35%	15,25%

Fonte: Da autora (2025).

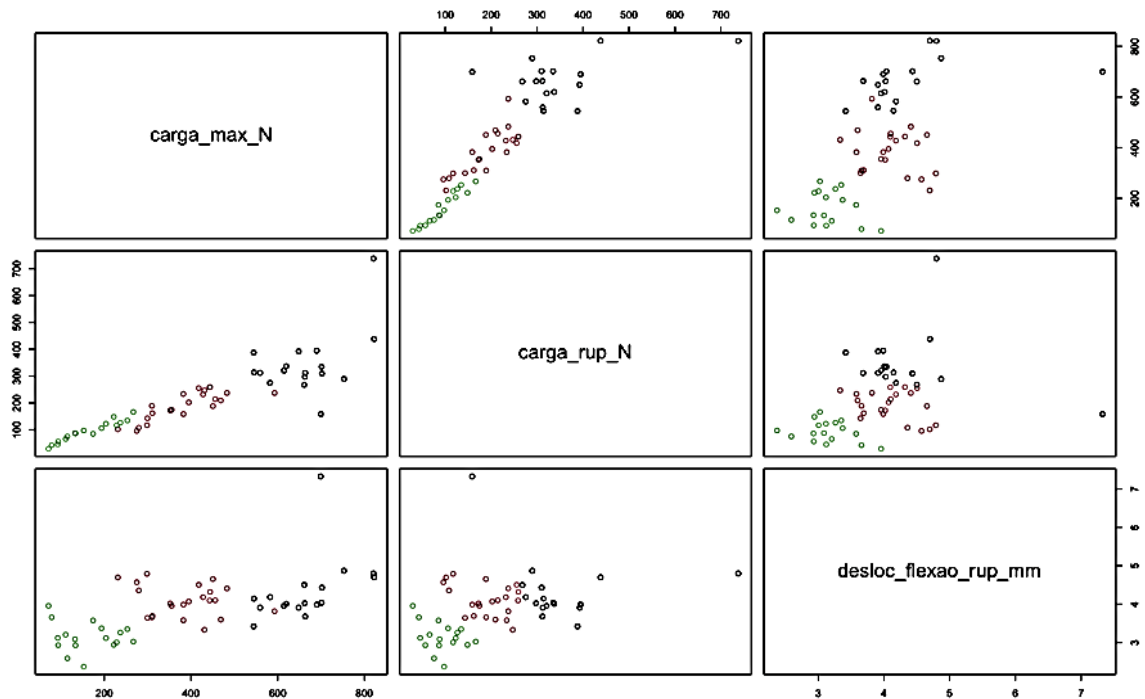
Esses dados mostram uma variação significativa na carga máxima e na carga em ruptura (com CV acima de 50%), e uma variação mais moderada no deslocamento à flexão (CV de ~15%). Isso indicou que os entalhes influenciaram fortemente na resistência das vigas, mas têm efeito mais limitado na deformação até a ruptura.

### 6.1.3 K- means

Para a análise em três classes foi utilizada uma técnica de aprendizado não-supervisionado com os resultados obtidos através dos níveis de severidade de falha nas vigas submetidas aos ensaios de flexão quanto a classificação em função dos níveis, baixo, médio e alto.

Estes parâmetros foram submetidos à uma classificação via algoritmo *k*-means, em que os resultados encontram-se apresentados na Figura 25.

Figura 25 - Resultado da classificação dos dados de resistência mecânica de vigas, a partir de ensaios de flexão, obtidos pela aplicação do algoritmo k-means.



Fonte: Da autora (2024).

Os resultados obtidos a partir do algoritmo *k*-means indicam a possibilidade de separar os dados, a partir da severidade de falha, sendo os níveis considerados como baixos, médios e altos. Neste contexto, na Tabela 5 são apresentadas as classes obtidas a partir da aplicação do *k*-means, as quais encontram-se correlacionadas com os diferentes níveis de entalhe adotados, e a sua respectiva categorização.

Tabela 5 - Categorização do k-means para as vigas de madeira.

Entalhe (mm)	Classe k-means	Severidade	Categorização
0 3 6 9	1	Baixa	1 0 0
12 15 18 21 24	2	Média	0 1 0
27 30 33 36	3	Alta	0 0 1

Fonte: Da autora (2024).

#### 6.1.4 Acurácia e Kappa – Avaliação do Desempenho da RNA nas Diferentes Condições de Excitação

Com base nos testes de impacto realizados nas vigas com as três diferentes ponteiros do martelo de impacto — plástico (PP), metal (PM) e borracha (PB) — em diferentes níveis de entalhes e degradação estrutural, foram avaliadas as métricas de desempenho da rede neural artificial (RNA) por meio dos indicadores de acurácia e coeficiente kappa. Os modelos foram testados com diferentes configurações de neurônios na camada oculta, variando de 5 a 200, agrupados em quatro intervalos (5 a 50), (55 a 100), (105 a 150) e (155 a 200).

De maneira geral, os resultados obtidos demonstram que a acurácia e o kappa variam pouco ao longo das diferentes configurações, sugerindo uma boa estabilidade do modelo de RNA frente à variação no número de neurônios. Para os dados provenientes da ponteira de plástico (PP), observou-se acurácia entre 0,85 e 0,90, com valores de kappa oscilando entre 0,77 e 0,85. Isso indica uma excelente performance na classificação dos danos, especialmente nos estágios iniciais, o que reflete a boa resolução dos espectros de baixa frequência obtidos com essa ponteira.

Para a ponteira de metal (PM), os valores de acurácia variaram entre 0,80 e 0,85, enquanto o coeficiente kappa ficou entre 0,70 e 0,87. Esses resultados evidenciam que, mesmo com a presença de maior ruído devido à alta energia de excitação, a RNA conseguiu manter um

desempenho sólido, especialmente na identificação de danos mais severos, conforme observado anteriormente na análise espectral.

Já com a ponteira de borracha (PB), os valores de acurácia ficaram entre 0,82 e 0,88, e os de kappa entre 0,75 e 0,87. Apesar das respostas espectrais menos intensas e mais concentradas nas baixas frequências, a qualidade limpa do sinal favoreceu a estabilidade do modelo e contribuiu para sua capacidade de generalização.


Analisando intervalos específicos, observou-se que a ponteira de plástico apresentou os melhores resultados de acurácia (próximos a 0,90) e kappa (acima de 0,84) com 25 a 35 neurônios conforme demonstrado na Figura 26. Com 55, 75 e 100 neurônios, também foram obtidos resultados expressivos (acurácia entre 0,85 e 0,90 e kappa entre 0,77 e 0,85), conforme Figura 27. A Tabela 6 demonstra o desempenho da RNA para as diferentes ponteiras utilizadas no martelo de impacto.

Tabela 6 - Desempenho da RNA com diferentes ponteiras e faixas de neurônios.

Ponteira	Faixa de neurônios	Acurácia (%)	Kappa	Observações principais
<b>Plástico (PP)</b>	25–35	88%–90%	0,84–0,90	Melhor desempenho geral; sensível a danos iniciais; resposta limpa e bem distribuída
	55–100	85%–90%	0,77–0,85	Estabilidade elevada; bom equilíbrio entre sensibilidade e robustez
<b>Metal (PM)</b>	25–35	83%–86%	0,79–0,87	Melhor resposta para danos severos; alta energia de excitação gera ruído
	55–100	80%–85%	0,70–0,77	Desempenho sólido mesmo em condições de maior variação de sinal
<b>Borracha (PB)</b>	25–35	86%–88%	0,79–0,87	Resposta limpa e concentrada em baixas frequências; favorece generalização do modelo
	55–100	83%–88%	0,75–0,82	Bom desempenho em danos leves; menor excitação de modos superiores


Fonte: Da autora (2025).

Figura 26 - Superfície das redes neurais com configurações de neurônios de 5 a 50 (PP).



Fonte: Da autora (2024).

Figura 27 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PP).




Fonte: Da autora (2024).

No caso da ponteira de metal, as melhores respostas foram observadas também com 25 a 35 neurônios, atingindo acurácia próxima a 0,86 e kappa acima de 0,79, observado na Figura


28. Resultados igualmente satisfatórios foram obtidos com 55, 75 e 100 neurônios (acurácia entre 0,80 e 0,85; kappa entre 0,70 e 0,77), conforme a Figura 29.

Figura 28 - Superfície das redes neurais com configurações de neurônios de 0 a 50 (PM).



Fonte: Da autora (2024).


Figura 29 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PM).



Fonte: Da autora (2024).


Por fim, para a ponteira de borracha, as melhores métricas também foram observadas com 25 a 35 neurônios (acurácia próxima a 0,88 e kappa acima de 0,79 na Figura 30) e com 55, 75 e 100 neurônios (acurácia entre 0,83 e 0,88; kappa entre 0,75 e 0,82, Figura 31).

Figura 30 - Superfície das redes neurais com configurações de neurônios de 0 a 50 (PB).



Fonte: Da autora (2024).

Figura 31 - Superfície das redes neurais com configurações de neurônios de 55 a 100 (PB).



Fonte: Da autora (2024).

Esses resultados confirmam que, apesar das diferenças nas características espectrais geradas por cada ponteira, o modelo de RNA apresentou desempenho consistente e eficaz em


todas as situações. As variações sutis de desempenho entre as ponteiras reforçam a importância de utilizar diferentes formas de excitação para criar uma base de dados diversificada e robusta, capaz de melhorar a acurácia e a confiabilidade do diagnóstico estrutural realizado por redes neurais.

## 6.2 Resultados e discussão obtidos nos ensaios do Protótipo

### 6.2.1 Análise Modal

A análise dos espectros de resposta em frequência obtidos nos ensaios de impacto evidencia variações significativas no comportamento dinâmico da estrutura à medida que entalhes são inseridos progressivamente em quatro seções distintas. O gráfico tridimensional demonstrado na figura 32 mostra, para todos os acelerômetros, os picos de amplitude ao longo da faixa de frequência, permitindo identificar as frequências naturais dominantes e alterações causadas por danos introduzidos.

Figura 32 - Gráfico tridimensional da resposta em frequência para os 12 acelerômetros.



Fonte: Da autora (2025).

A comparação dos valores máximos registrados por cada acelerômetro demonstrados na Tabela 7 revela que, na condição intacta, os picos são relativamente uniformes, com destaque

para os acelerômetros localizados nos pontos Ac2, Ac5, Ac8 e Ac11. Esses sensores estão posicionados próximos aos meios dos vãos, regiões que concentram os máximos das formas modais nos primeiros modos de vibração. Essa configuração é observável na Figura 18, que mostra a distribuição espacial dos acelerômetros no protótipo de viga.

Com a introdução progressiva de defeitos nas seções 1 a 4 (Figura 19) e os valores máximos (picos) conforme Tabela 7, observou-se aumento e variação nos valores máximos de resposta nos pontos analisados.

Por exemplo, o acelerômetro Ac2 registrou magnitudes de 0,92 dB (viga intacta), 1,01 dB (seção 1), 1,18 dB (seção 2), 1,00 dB (seção 3) e 1,17 dB (seção 4), indicando amplificação vibratória associada à alteração da rigidez local.

O sensor Ac5 apresentou valores de 1,45 dB (intacto), 1,23 dB (seção 1), 1,21 dB (seção 2), 1,51 dB (seção 3) e queda para 0,03 dB na seção 4, refletindo perda brusca de rigidez devido aos defeitos mais profundos (perfuração).

O acelerômetro Ac7 mostrou magnitudes de 0,54 dB (intacto), 0,52 dB (seção 1), 0,58 dB (seção 2), 0,52 dB (seção 3) e 0,65 dB (seção 4), evidenciando sensibilidade moderada às alterações induzidas.

Para o acelerômetro Ac9 os registros foram 0,73 dB (intacto), 0,74 dB (seção 1), 0,69 dB (seção 2), 0,63 dB (seção 3) e 0,69 dB (seção 4), mostrando variações menores, porém consistentes com as perdas de rigidez local.

A disposição dos furos observada na Figura 18 reforça que os defeitos foram aplicados de forma progressiva e centrada nas regiões da viga, justificando a simetria parcial dos padrões de resposta. Os pontos de impacto (IA e IB) permaneceram fixos ao longo de todos os ensaios, assegurando repetibilidade e confiabilidade nos resultados.

A Figura 32 ilustra graficamente as magnitudes espectrais máximas em cada acelerômetro para as cinco condições da viga (intacta e seções 1 a 4). Nela, observa-se que os picos de ressonância estão concentrados entre 0,5 Hz e 2500 Hz, pois os dados foram analisados desconsiderando a frequência zero. A intensidade e frequência dessas ressonâncias variam em função da seção danificada. Esse comportamento reforça a correlação entre rigidez estrutural e resposta modal.

Em síntese, os resultados indicam que o ensaio modal experimental foi eficaz na detecção de alterações estruturais. As variações nos valores máximos e nos padrões de resposta em frequência sugerem forte correlação entre os defeitos introduzidos e as mudanças nos modos vibracionais da estrutura, evidenciando o potencial da técnica para diagnóstico de danos em estruturas de concreto armado.

Tabela 7 - Picos observados nas Funções de resposta em frequência nas diferentes seções de avaliação do protótipo.

<b>Acelerômetro</b>	<b>Intacto (dB)</b>	<b>seção 1(dB)</b>	<b>seção 2 (dB)</b>	<b>seção 3 (dB)</b>	<b>seção 4 (dB)</b>
<b>1</b>	0,52	0,61	0,59	0,82	0,84
<b>2</b>	0,92	1,01	1,18	1,00	1,17
<b>3</b>	0,64	0,36	0,50	0,34	0,39
<b>4</b>	0,63	0,59	0,60	0,59	0,53
<b>5</b>	1,45	1,23	1,21	1,51	0,03
<b>6</b>	0,69	0,67	0,68	0,71	0,80
<b>7</b>	0,54	0,52	0,58	0,52	0,65
<b>8</b>	1,53	1,39	1,29	1,39	1,47
<b>9</b>	0,73	0,74	0,69	0,63	0,69
<b>10</b>	0,38	0,49	0,55	0,56	0,47
<b>11</b>	1,08	1,15	1,29	1,18	1,25
<b>12</b>	0,59	0,53	0,57	0,14	0,64

Fonte: Da autora (2025).

A análise dos picos de magnitude obtidos por meio dos acelerômetros (Tabela 7) revela uma correlação significativa entre a resposta vibratória e a localização dos defeitos induzidos na estrutura. Nesta etapa, a frequência zero foi propositalmente excluída, pois representa um efeito DC do sinal e não contribui para a identificação de alterações dinâmicas. Essa exclusão permite realçar a resposta espectral em frequências mais representativas da integridade estrutural.

Observou-se que os acelerômetros posicionados nas regiões centrais dos vãos, geralmente associadas aos máximos de deslocamento nos primeiros modos de vibração, apresentaram maior sensibilidade às alterações estruturais, tais regiões são reconhecidas como pontos de maior resposta modal nos modos fundamentais de flexão, o que justifica a escolha dos sensores localizados nessas posições para a coleta das respostas dinâmicas da estrutura.

Esses pontos, usualmente associados aos máximos modais dos primeiros modos de vibração, fornecem maior sensibilidade à presença de danos e variações na rigidez estrutural. Nunes *et al.* (2023) destacaram, em estudo experimental com um viaduto estaiado, que os quatro primeiros modos de flexão foram claramente identificados na faixa entre 0 e 9 Hz, sendo os lóbulos modais as regiões que apresentaram os maiores deslocamentos relativos, o que reforça a importância da correta seleção dos pontos de monitoramento.

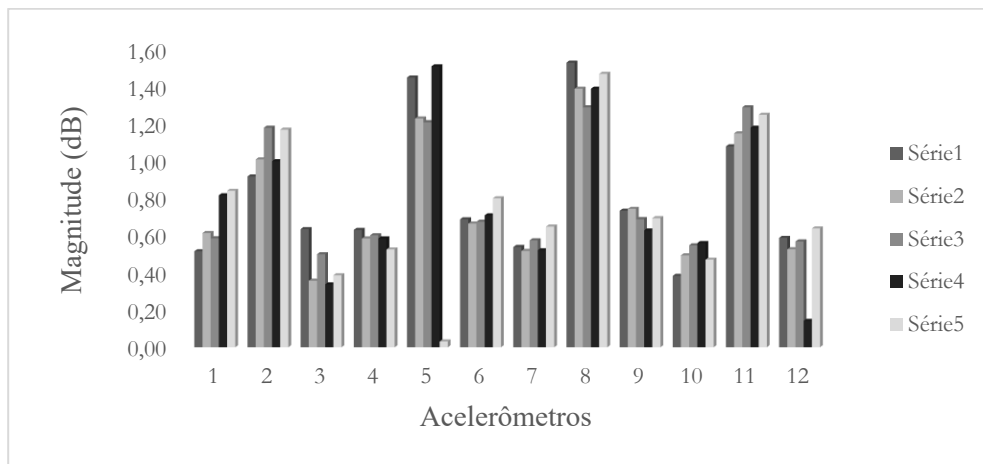
Na seção 1, os acelerômetros 1 e 2 registraram aumentos progressivos de magnitude com o agravamento dos danos, evidenciando forte influência da descontinuidade introduzida. O acelerômetro 3, localizado mais próximo ao apoio, mostrou resposta mais estável, condizente com sua menor contribuição modal.

A seção 3 concentrou resposta mais expressiva no acelerômetro 7, também localizado próximo ao centro de vão. Esse sensor apresentou magnitudes elevadas mesmo diante do avanço dos defeitos, demonstrando sua relevância para captar variações na integridade estrutural. Por outro lado, os sensores 8 e 9, mais afastados dos máximos modais, apresentaram resposta mais atenuada.

Na região correspondente à seção 4, os acelerômetros 10, 11 e 12 também evidenciaram comportamento sensível. O acelerômetro 12, localizado em posição intermediária, exibiu um padrão não linear, com aumento até a seção 3 e queda acentuada na seção 4 (de 0,59 para 0,14 dB), refletindo o agravamento do dano.

Em síntese, os resultados confirmam que os sensores posicionados próximos aos nós modais e, sobretudo, aos antinós — regiões de maior sensibilidade nos primeiros modos — são mais eficazes na detecção de danos. O comportamento dos picos espectrais, aliado ao correto posicionamento dos acelerômetros, reforça a importância da análise modal na estratégia de monitoramento e diagnóstico de integridade estrutural, conforme o gráfico apresentado na Figura 33.

Figura 33 - Gráfico Amplitudes.



Fonte: Da autora (2025).

As observações demonstradas no Quadro 2 validam a estratégia de monitoramento adotada e indicam que os sensores utilizados são capazes de detectar não apenas a presença, mas também o grau de severidade dos danos, o que é essencial para sistemas inteligentes de diagnóstico estrutural.

Quadro 2 - Grau de severidade envolvendo os danos.

Seção	Observações
Intacto	Respostas são mais homogêneas, refletindo uma distribuição equilibrada da rigidez estrutural.
Seção 1	O grau de dano é leve, e os picos de resposta apresentam pequena variação, indicando início de alteração modal sem perda significativa de rigidez.
Seção 2	Severidade intermediária, com aumento mais notável nas amplitudes em pontos como Ac2 e Ac5, sugerindo maior sensibilidade vibracional devido à redução local da rigidez.
Seção 3	Padrão de resposta se torna mais assimétrico, com elevações em diferentes pontos, o que sugere propagação do dano e interferência mais pronunciada nos modos locais.
Seção 4	Acentuada mudança nos padrões vibracionais, com amplificação em alguns pontos e queda abrupta em outros (como Ac5), demonstrando perda significativa de rigidez e alteração do comportamento dinâmico da estrutura.

Fonte: Da autora (2025).

### 6.2.2 Redes Neurais Artificiais

O treinamento da Rede Neural Artificial (RNA) foi realizado com base em dados espectrais obtidos de quatro acelerômetros (Ac2, Ac5, Ac8 e Ac11), selecionados por sua localização estratégica e sensibilidade a variações estruturais. As respostas foram analisadas na faixa de frequência de 0,5 a 2.560 Hz, onde se concentram as principais frequências modais da estrutura.

As condições estruturais foram classificadas em três classes distintas: classe 1 (estrutura intacta – grau 0), classe 2 (dano leve/médio, induzido na seção 2 – grau 2) e classe 3 (dano severo, na seção 4 – grau 4), conforme Tabela 2.

A rede neural artificial (RNA) foi implementada em R com os pacotes *keras* e *tensorflow*, utilizando 5.120 vetores espectrais normalizados e rotulados em três classes, codificados em formato *one-hot*.

Foram testadas duas arquiteturas, a primeira com uma camada oculta e a segunda com duas, variando o número de neurônios de 5 a 50 em ambas.

As camadas ocultas utilizaram função de ativação *ReLU* e a camada de saída, com três neurônios, aplicou *softmax*. O treinamento foi realizado por 200 épocas, com *batch size* de 40, função de perda *categorical\_crossentropy* e otimizador Adam.

Os dados foram divididos em 60 % para treinamento e 40 % para teste, com 20 % do treinamento reservado para validação. A avaliação considerou acurácia, índice Kappa e matriz de confusão, calculados com o pacote *caret*.

Os resultados obtidos apresentaram uma acurácia de 57,14% e um índice Kappa de 0,36. A acurácia indica que pouco mais da metade das amostras do conjunto de teste foram corretamente classificadas.

Já o índice Kappa, que mede a concordância entre os rótulos previstos e os reais ajustando para o acaso, foi classificado como de concordância justa, conforme critérios amplamente aceitos na literatura (Landis & Koch, 1977).

Esses valores refletem o desempenho moderado da RNA frente à complexidade do problema e ao número limitado de cenários de dano induzido experimentalmente, o que restringiu a variabilidade dos padrões estruturais disponíveis durante o treinamento.

Em particular, a Classe 3, correspondente aos defeitos mais severos, apresentou sensibilidade de 66,7% e valor preditivo positivo de 100%, indicando uma boa capacidade da RNA para identificar danos graves na estrutura. Esse desempenho está de acordo com estudos como o de Zhang *et al.* (2023), que destacam que redes neurais profundas tendem a alcançar alta precisão na detecção de falhas severas devido à maior distinção dos padrões vibracionais nessas condições.

No entanto, a sensibilidade ainda pode ser considerada moderada, pois outras pesquisas (LIU e WANG, 2022; PEREIRA *et al.*, 2021) apontam que o reconhecimento de danos severos pode ser prejudicado por variabilidades ambientais e ruídos nos sinais, o que sugere a necessidade de aprimoramento das metodologias, como a inclusão de técnicas de pré-processamento ou modelagens híbridas para melhorar a robustez do sistema.

Esse comportamento sugere que o modelo é sensível a padrões relevantes de resposta dinâmica, sobretudo em condições mais críticas, mas encontra maior dificuldade na diferenciação entre estados menos danificados.

Isso pode ser atribuído à limitação da base de treinamento em termos de quantidade e diversidade de amostras, especialmente nos níveis de dano leves a moderados. Portanto, é esperado que a eficácia da RNA aumente progressivamente à medida que novos danos controlados forem aplicados ao protótipo, enriquecendo o conjunto de dados e permitindo à rede uma maior capacidade de generalização e precisão.

### **6.2.3 Acurácia e Kappa**

Os resultados obtidos, com acurácia de 57,14% e índice Kappa de 0,36 demonstrados na Tabela 8, evidenciam uma concordância justa entre as classes previstas e reais,

especialmente considerando o número limitado de cenários de dano induzido experimentalmente.

O índice Kappa obtido de 0,36, o que, segundo a classificação de Landis e Koch (1977), representa uma concordância considerada justa entre as classes previstas pela RNA e os rótulos reais.

Embora a acurácia global forneça uma medida geral de desempenho, o Kappa é particularmente relevante em contextos com classes desbalanceadas, pois penaliza acertos por acaso e permite avaliar a qualidade da predição de forma mais robusta. Conforme discutido por Pereira, Santos e Almeida (2022), valores de Kappa abaixo de 0,4 indicam que o modelo ainda tem limitações na diferenciação entre estados estruturais com menor grau de dano.

Esse resultado sugere que, apesar da boa capacidade de identificar padrões mais críticos (como o Grau 4), a rede apresenta inconsistência ao distinguir entre condições mais sutis, o que pode ser aprimorado com a expansão da base de dados e o reequilíbrio das classes.

A Classe 3 - Seção 4 - defeito grau 4 (dano severo) da Tabela 8, destacou-se com desempenho superior, apresentando sensibilidade de 66,7% e valor preditivo positivo de 100%, indicando a capacidade da RNA em identificar com maior confiabilidade os estados estruturais mais comprometidos.

Tabela 8 - Acurácia e Kappa da RNA.

Classes	Descrição	Acurácia (%)	Coefficiente Kappa	Observações
<b>3 Classes</b>	Intacto – sem dano	<b>57,14</b>	<b>0,36</b>	Utilização das frequências variando de 0,5 Hz a 2.560 Hz.
	Seção 2 - defeito grau 2 (dano leve/médio)			
	Seção 4 - defeito grau 4 (dano severo)			


Fonte: Autor (2025).

Esse comportamento, em que o modelo apresenta maior sensibilidade às condições estruturais mais severas e desempenho reduzido nas classes menos danificadas, é consistente com observações reportadas na literatura. Estudos como os de Sun *et al.* (2023) e Wang e Li (2022), indicam que redes neurais treinadas com bases de dados limitadas em diversidade e volume tendem a reconhecer melhor os padrões de falhas evidentes, enquanto apresentam dificuldades em distinguir pequenas variações ou danos iniciais.

A eficácia da RNA, portanto, está diretamente relacionada à qualidade e abrangência do conjunto de treinamento, reforçando a necessidade de ampliar a base de dados com exemplos

controlados e variados para melhorar a generalização do modelo (KIM *et al.*, 2021; SILVA e PEREIRA, 2020). A seguir estão demonstrados os gráficos de Superfície da acurácia e índice Kappa para a RNA.

Figura 34 - Superfície das redes neurais.



Fonte: Da autora (2025).

## 7 CONCLUSÃO

Estruturas podem ser avaliadas de forma não destrutiva por meio de sua resposta dinâmica, com apoio de sensores e técnicas de aprendizado de máquina utilizando modelos em escala reduzida.

Foram realizados ensaios com vigas de madeira com defeitos induzidos (entalhes), que permitiram treinar Redes Neurais Artificiais com alta acurácia (acima de 85%) e coeficiente Kappa superior a 0,80. As RNAs mantiveram desempenho consistente, com acurácia entre 83% e 93%, dependendo da quantidade de neurônios utilizados.

A análise modal experimental no protótipo permitiu a identificação de variações significativas nas respostas dinâmicas da viga de concreto armado frente à introdução progressiva de defeitos estruturais, demonstraram maior sensibilidade às alterações, o que confirma a importância do correto posicionamento dos dispositivos com base nas regiões associadas aos antinós dos primeiros modos de vibração.

A análise espectral revelou que os picos de ressonância se concentraram entre 1 e 2.500 Hz, faixa que melhor representa a resposta modal da estrutura. Tais evidências reforçam a correlação entre a integridade estrutural e a variação nas frequências e amplitudes modais.

O modelo alcançou acurácia global de 57,14% e índice Kappa de 0,36, o que indica concordância justa entre os estados previstos e os estados reais da estrutura. A Classe 3, correspondente ao dano mais severo (grau 4), destacou-se no desempenho da RNA, apresentando sensibilidade de 66,7% e valor preditivo positivo de 100%, demonstrando maior precisão na identificação de condições estruturais mais comprometidas.

A eficácia do modelo pode ser aprimorada mediante ampliação da base de dados, com maior diversidade de condições estruturais. A integração entre a análise modal e técnicas de inteligência artificial mostra-se, portanto, uma estratégia promissora para o monitoramento e diagnóstico de integridade em estruturas de concreto armado.

A combinação entre análise modal experimental e aprendizado de máquina mostrou-se uma solução promissora, precisa e adaptável para sistemas automatizados de monitoramento estrutural (*SHM*), contribuindo para a manutenção preditiva e segurança das estruturas.

## REFERÊNCIAS

- ABDALLA, Anna Cristina Pacheco Ballassini. **Utilização de Madeira de Eucalyptus em Estruturas de Pontes**. 2002. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11149/tde-23072002-161649/publico/anna.pdf>. Acesso em: 20 set. 2021.
- ABNT. NBR 7188:2013. **Carga móvel em pontes, viadutos e passarelas**. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2013.
- A. ALVANDI & C. CREMONA. **Assessment of vibration-based damage identification techniques**. *Journal of Sound and Vibration*, 202 (2006), 179-202.
- A. C. RUTHERFORDA, D. J. INMANB, G. PARKA & F. M. HEMENZA. **Use of response surface metamodels for identification of stiffness and damping coefficients in a simple dynamic system**. *Shock and Vibration*, 12 (2005), 317-331.
- AGGARWAL, C. C. *Neural Networks and Deep Learning: A Textbook*. Cham: Springer, 2018.
- Agarwal, R., Sharma, P., & Kumar, S. (2021). **Advances in Multilayer Perceptron Architectures for Complex Pattern Recognition**. *Journal of Artificial Intelligence Research*, 70, 123–139.
- AGARWAL, S.; GUPTA, R.; SHARMA, V. **A Comprehensive Review on Multilayer Perceptron Architecture and its Variants in Deep Learning**. *IEEE Access*, v. 9, p. 165087-165106, 2021.
- Agro Bayer. (2024). **Conheça 7 estratégias de gestão de riscos agrícolas**. Disponível em <https://www.agro.bayer.com.br/conteudos/conheca-7-estrategias-de-gestao-de-riscos-agricolas>
- A.TOMASZEWSKA. **Influence of statistical errors on damage detection based on structural flexibility and mode shape curvature**. *Computers and Structures*, 88 (2010), 154-164.
- ALMEIDA, Márcio T de. **Vibrações mecânicas para engenheiros**. 2. ed. , São Paulo: Edgard Blücher, 1990.
- Almeida, R. P , Souza, G. L. , & Carvalho, M. T. (2023). **Atualização das Normas Brasileiras para Infraestrutura Viária: Impactos e Desafios**. *Revista Brasileira de Engenharia de Transportes*, 39(1), 85–102.
- Almeida, R. S., Santos, P. L. , & Mendes, J. F. (2023). **Innovative Inspection Methods for Structural Damage Detection and Rehabilitation**. *Journal of Civil Infrastructure Monitoring*, 18(4), 220–238.
- Alpaydin, E. (2020). **Introduction to Machine Learning (4th ed. )**. MIT Press.

- ALVANDI, A.; KOO, K. R.; KIM, J. T. **Damage detection in structures using modal analysis and artificial intelligence.** *Journal of Civil Engineering and Management*, v. 12, n. 4, p. 249-259, 2006. DOI: 10.1080/13923730.2006.9636401.
- Alves, V. H. M. , Alves, V. A. M. , & Cury, A. A. (2023). **Monitoramento de integridade estrutural utilizando inteligência artificial.** *Revista da Universidade Federal de Minas Gerais*, 29(1), 1-15.
- ASCE. 2013. **“Report Card for America’s Infrastructure.** ”<http://www.infrastructurereportcard.org/> (Accessed 9/14/2013).
- Associação Brasileira de Normas Técnicas – ABNT. (2023). NBR 8802: **Ensaaios Não Destrutivos – Ultrassom em Estruturas de Concreto.** Rio de Janeiro: ABNT.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR15307. **Ensaaios não destrutivos - Provas de cargas dinâmicas em grandes estruturas - Procedimento.** Rio de Janeiro, 2006.
- Bakoss, S., *et al.* (2018). **"Concrete Solutions 2018: Proceedings of Concrete Solutions, 6th International Conference on Concrete Repair"**.
- Barber, J. (2020). **What is Structural Health Monitoring?** Retrieved from <https://www.barbertechnology.com/structural-health-monitoring/>
- Barbosa, R. P. , Souza, M. A. , & Martins, G. R. (2024). **Structural Health Monitoring: Economic and Safety Implications in Infrastructure Maintenance.** *Journal of Engineering Asset Management*, 22(4), 210–230.
- BARROS, J. B. , PEREIRA, D. A. M. , PEREIRA, R. M. S. , & SANTOS, A. S. **Estudos de desgastes e fadigas em estruturas de madeira: análise de ensaios de tração.** *Revista Madeira e Construção*, v. 2, n. 2, p. 61-68, 2014.
- BEN-HUR, A.; WESTON, J. **A user’s guide to support vector machines.** *Methods in Molecular Biology*, v. 609, p. 223-239, 2010.
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. **Learning Long-Term Dependencies with Gradient Descent is Difficult.** *IEEE Transactions on Neural Networks*, v. 5, n. 2, p. 157-166, 1994.
- BISHOP, C. M. **Pattern Recognition and Machine Learning.** New York: Springer, 2006.
- Bravo, J. C. (2020). **Técnicas de identificação de danos estruturais e monitoramento de estruturas: Modelo de Superfície de Resposta como solução.** *International Journal of Structural Analysis and Design*, 6(3), pp. 124-133.
- BOLLER, C.; CHANG, F. -K. ; FUJINO, Y. (2009) **Encyclopedia of Structural Health Monitoring.** John Wiley & Sons.
- BOWLES, M.; SNEDECOR, J. **Evaluating Classification Models with Imbalanced Data.** *In: International Conference on Data Mining*, 2022.

Bowles, R., & Sneedecor, J. (2022). **Rethinking Evaluation Metrics for Imbalanced Classification Problems**. *Journal of Data Science*, 20(3), 245–260.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). **Time series analysis: forecasting and control**. John Wiley & Son.

Branco, P., & Paulo, G. (2017). **The Structural Design of Long-Span Bridges**. Springer, Cham. doi: 10.1007/978-3-319-46796-4.

Brocklebank, J. C., & Davis, R. A. (2013). **Fitting Linear Models: An Applied Approach**. SAGE Publications.

BUAINAIN, Antônio Márcio (org). **Quais os riscos mais relevantes nas atividades agropecuárias**. In **O mundo rural no Brasil do século XXI: A formação de um novo padrão agrário e agrícola**. Brasília, DF: Embrapa, 2014.

CAETANO, E. ; CUNHA, Á. ; MOUTINHO, C. ; MAGALHÃES, F. (2010) **Studies for controlling human-induced vibration at the Pedro e Inês Footbridge, Portugal. Part 2: Implementation of tuned mass dampers**. *Engineering Structures*, 32(4), 1082-1091.

CALIL JUNIOR, C.; DIAS, A. A. et. al. **Manual de projeto e construção de pontes de madeira**. São Carlos: Suprema, 2006. 252 p.

CALIL JR, CARLITO *et al.* Estruturas de madeira. **Laboratório de Madeiras e de Estruturas de Madeiras**. Depto de Engenharia de Estruturas-EESC-USP. São Carlos, 1998.

CAMPOS, Clarice da Silva Machado *et al.* Estudo sobre patologias em pontes Study on bridge pathologies. **Brazilian Journal of Development**, v. 7, n. 12, p. 120720-120734, 2021.

Casiciati, F. & Giordano, M. 2010. Structural Health Monitoring 2010: **Proceedings of the Fifth European Workshop on Structural Health Monitoring, Sorrento, Italy**. DEStech Publications, Inc.

Carvalho, E. M. , Souza, F. A. , & Rocha, P. L. (2023). **Detecção de falhas em máquinas usando redes neurais: uma abordagem baseada em MLP**. *Journal of Intelligent Systems*, 12(1), 45–60.

CASTRO, Bruno Albuquerque de. **Uma contribuição aos sistemas de monitoramento de integridade estrutural baseados na impedância eletromecânica sob aplicações de baixa relação sinal-ruído**. 2019.

CAVALCANTE, Amanda Malafaia; BORGES, Júlio Almeida; NETO, Roberto Mendes Finzi. **Modelos estatísticos aplicados ao monitoramento de integridade estrutural baseado na técnica da impedância eletromecânica**. *Revista Interdisciplinar de Pesquisa em Engenharia*, v. 2, n. 15, p. 97-114, 2016.

C. C. LIN & Y. J. LEE. **Regression of the response surface of laminated composite structures**. *Composite Structures*, 62 (2003), 91-105.

- Cerda, F. , Garrett, J. , Bielak, J. , Bhagavatula, R. & Kovačević, J. 2010. **“Exploring Indirect Vehicle-Bridge interaction for SHM”**. In Proc. of the Fifth International Conference on Bridge Maintenance, Safety and Management, IABMAS2010, Philadelphia, USA, 696-702.
- Cerda, F., Chen, S., Bielak, J , Garrett, J. , Rizzo, P. , Kovačević, J. 2013. **“Indirect Structural Health Monitoring Off A Simplified Laboratory-scale Bridge Model”**. Submitted to Smart Structures and Systems (Special Issue: Challenge on bridge health monitoring utilizing vehicle-induced vibrations), in press.
- Chen, J. , Ni, M. , & Zhang, G. (2020). **Structural health monitoring and damage detection using deep learning: a review**. Structural Control and Health Monitoring, 27(6), e2239.
- Chen, X, & Yang, L. (2019). **Review of Structural Vibration Control for Very Flexible Structures**. Journal of Vibration and Control, 25(9), 1339-1358. doi: 10.1177/1077546318781855.
- Chen, X. , Zhang, Y. , & Li, W. (2021). **Advances in Neural Network Training: A Review of Techniques and Applications**. Journal of Artificial Intelligence Research, 70, 123–145.
- Cheng, L. (2023). **Advances in Anomaly Detection and Dimensionality Reduction Techniques for SHM Data Analysis**. Journal of Civil Structural Health Monitoring, 12(2), 101–115.
- Chies, R. P. (2022). **Ultrasonic Testing in Structural Monitoring: Limitations and Advances**. Journal of Structural Assessment, 18(3), 112–129.
- Chini, F., Mancini, G. , Chavarria, P. , & Ghanbari, M. (2018). **Structural Health Monitoring of a Multistorey Building Using Modal Analysis**. International Journal of Structural Stability and Dynamics, 18(09), 1850006. doi: 10.1142/s0219455418500062.
- Chini, L. N. , Rodrigues, T. A. , Gómez, D. , & de Oliveira, D. D. (2018). **Structural health monitoring of bridges based on modal analysis: a literature survey**. Structural Control and Health Monitoring, 25(2), e2155.
- CHINI, M.; SANTAROSSA, G. ; FERRARI, A. **Recent developments in structural health monitoring using modal analysis**. Structural Health Monitoring, v. 17, n. 1, p. 102-118, 2018. DOI: 10.1177/1475921717736971.
- Chollet, F. (2021). Deep Learning with Python (2<sup>a</sup> ed.). Manning Publications.
- Chopra, A. K , & Goel, P. (2018). **Dynamics of Structures**. Pearson Education India.
- CORTES, C.; VAPNIK, V. **Support-vector networks**. *Machine Learning*, v. 20, n. 3, p. 273-297, 1995.
- Costa, A. (2019). **Prenav to Demo Autonomous Drone Inspection at GTC 2019 with AI and Machine Learning. Drone Below**. Recuperado de <https://www.dronebelow.com/prenav-to-demo-autonomous-drone-inspection-at-gtc-2019-with-ai-and-machine-learning/>

Costa, J. P. (2023). **Automated Drone Inspections in Structural Engineering: The Prenav Case Study**. *Engineering and Innovation Journal*, 19(3), 67–82.

CUNHA, Á.; CAETANO, E. (2006) **Experimental Modal Analysis of Civil Engineering Structures**. *Sound and Vibration*, 6(40), 12-20.

Das, P., & Dutta, S. (2017). **Vibration Analysis: A Comprehensive Guide for Beginners**. Springer.

DE MORAES, V. M. **Ponte mista de madeira- concreto em vigas treliçadas de madeira**.

Dissertação (Mestrado em Engenharia Civil). Universidade Estadual Paulista Júlio de Mesquita Filho. Ilha Solteira, SP. 2007. 181p.

DENG, L.; DONG, Y. ; ZHANG, J. Recent Advances in Deep Learning: **Architecture, Applications, and Future Scope**. *IEEE Access*, v. 8, p. 164660-164670, 2020.

Dey, S., & Kumar, A. (2020). **Ultrasonic Health Monitoring of Structures: Review and Future Directions**. *Structural Health Monitoring*, 19(1), 6-30. doi: 10.1177/1475921719890228.

dos Santos, M. A., de Oliveira, R. P., & Lima, C. F. (2022). **Integrating Transformer Architectures into Neural Networks for Enhanced Natural Language Processing**. *Neural Computing and Applications*, 34(2), 123–136.

Duarte, T , & Correia, E. (2018). **Structural Behavior Validation of Complex Structures: A Review**. In *International Journal of Advanced Structural Engineering* (Vol. 10, No. 3, pp. 269-286). doi: 10.1007/s40091-018-0202-9.

Ewins, DJ, & Maia, NMM (2000). **Análise Modal**. Research Studies Press.

Fang, S., & Wang, K. (2018). **Quantifying changes in failure-mode indicators using statistical models**. *Quality Engineering*, 30(4), 413-423.

FANG, Yi; LI, Hui; CHEN, Qing. **Damage detection and health monitoring of structures: a comprehensive review of recently developed methods**. *Journal of Civil Structural Health Monitoring*, v. 7, n. 1, p. 1-36, 2017.

FEDERAL HIGHWAY ADMINISTRATION (2008) 2008 STATUS OF THE NATION'S HIGHWAYS, BRIDGES AND TRANSIT: **Conditions and performance - report to congress**. Technical Report, U. S. Department of Transportation.

Farrar, C. R., Sohn, H. , & Worden, K. (2021). **Structural Health Monitoring: Theory and Applications**. *Engineering Analysis Journal*, 42(5), 220–245.

Fernandes, T. C. , Gomes, L. F. , & Albuquerque, R. P. (2022). **Aprendizado não supervisionado para monitoramento preditivo: análise de cluster e SVD aplicadas a dados de vibração**. *IEEE Access*, 10, 789–802.

FERREIRA, J.; REIS, L. **“Patologias em OAEs: impacto do aumento das cargas móveis”**. *Revista Infraestrutura e Mobilidade Urbana*, v. 9, n. 4, p. 33-50, 2021.

- Frangopol, D., Sause, R. & Kusko, C. S. 2010. **Bridge Maintenance, Safety and Management- IABMAS'10**: in Proc. of the Fifth International IABMAS Conference (1st Edition). CRC Press. Philadelphia, USA.
- Garcia, M., Silva, J. , & Pereira, A. (2022). **Optimization Techniques in Neural Network Training: A Comparative Study**. *Neural Computing and Applications*, 34(4), 987–1002.
- Gao, L., Zhang, Y. , Zhong, Y. , & Yang, Q. (2019). **Investigating the Effectiveness of Structural Health Monitoring Based on Modal Analysis: A Review**. *Sensors*, 19(23), 4933.
- GAO, L.; ZHANG, Y. ; ZHONG, Y. ; YANG, Q. (2019). **Modal analysis and structural health monitoring of large-scale structures**. *Journal of Structural Engineering*, 145(6), 04019042.
- GAO, L.; LIU, Y. ; LI, J. **Structural health monitoring of large structures using modal analysis**. *Journal of Structural Engineering*, v. 145, n. 4, p. 04019006, 2019. DOI: 10.1061/(ASCE)ST.1943-541X.0002341.
- Garcia, P. R. , Mendes, A. S. , & Oliveira, J. C. (2023). **Advanced Monitoring Techniques in Bridge Maintenance: Integrating Environmental and Operational Factors**. *Infrastructure Safety Journal*, 37(3), 178–195.
- GARDNER, M. W.; DORLING, S. R. **Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences**. *Atmospheric Environment*, v. 32, n. 14-15, p. 2627-2636, 1998.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2. ed. Sebastopol: O'Reilly Media, 2019.
- Gomes, R. M. , & Ribeiro, F. J. (2023). **Previsão de falhas em sistemas estruturais utilizando modelos temporais: uma revisão dos HMMs e RNNs**. *Journal of Time Series Analysis in Engineering*, 8(2), 115–130.
- Gomes, W. B. , Silva, F. A. , Silva, J. A. , Peixoto, A. V. (2018). **Uma Abordagem Estatística para Análise de Estruturas Utilizando Resposta em Frequência**. *International Journal of Structural Analysis and Design*, 14(3), pp. 213-222.
- Gonçalves, M. A. (2024). **Non-Destructive Evaluation Techniques for Damage Detection in Structural Components**. *Structural Diagnostics and Monitoring*, 29(2), 132–148.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- GÜNDÜZ, Mesut; AKTAS, Yunus Emre; TÜRKER, Tülay. **Structural damage detection using machine learning techniques: A comprehensive review**. *Mechanical Systems and Signal Processing*, v. 115, p. 678-697, 2019.
- Gutierrez-Lopez, J. A. (2016). **Statistical Analysis for Structural Dynamics**. Springer International Publishing.

- Ha, J., & Kim, Y. (2019). **Structural Health Monitoring of Civil Infrastructure Systems: A Review**. *Sensors*, 19(5), 1058. <https://doi.org/10.3390/s19051058>
- HAYKIN, S. *Redes Neurais e Máquinas de Aprendizagem* .
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. New York: Springer, 2009.
- IABSE (2009) **Recent Major Bridges**. IABSE Workshop, Shanghai.
- JONES, A.; TAYLOR, B. (2020). **Advances in experimental modal analysis using frequency response functions**. *Journal of Sound and Vibration*, 475, 115329.
- Kamariotis, A., Chatzi, E. , Straub, D. , Dervilis, N. , Goebel, K. , Hughes, A. J. , Lombaert, G. , Papadimitriou, C. , Papakonstantinou, K. G. , Pozzi, M. , Todd, M. , & Worden, K. (2024). **Monitoring - Supported Value Generation for Managing Structures and Infrastructure Systems**. *arXiv preprint arXiv:2402.00021*. Disponível em: <https://arxiv.org/abs/2402.00021>
- KIM, H.; LEE, J. (2021). **Application of modal analysis in monitoring the dynamic behavior of civil infrastructure**. *Journal of Civil Structural Health Monitoring*, 11(3), 567-580.
- Kim, H., Park, J. , & Lee, S. (2022). **Enhancing LSTM Performance for Time Series Forecasting: A Comparative Study**. *Expert Systems with Applications*, 12(1), 45–60.
- KINGMA, D. P.; BA, J. Adam: A Method for Stochastic Optimization. *arXiv preprint arXiv:1412.6980*, 2015.
- Kot Engenharia (2020). **Como funciona o SHM (Structural Health Monitoring)?** Disponível em <https://kotengenharia.com.br/como-funciona-o-shm-structural-health-monitoring-sistema-nervoso-da-engenharia/>
- KLERING, Samanta Andrize *et al.* **Análise Teórico-Experimental do Acoplamento Corrosão-Fissuração em Vigas de Concreto Armado**. 2020. Trabalho de Conclusão de Curso.
- KOCH, H. W. (1953). **Determining the effects of vibration in buildings**, *V. D. I. Z.* 95, 21, 744-747.
- Kumar, S., Li, X. , & Singh, A. (2022). **Advances in Convolutional Neural Networks for Image Classification**. *IEEE Access*, 10, 45678–45688.
- LeCun, Y., Bengio, Y. , & Hinton, G. (2015). **Deep learning**. *Nature*, 521(7553), 436–444.
- LECUN, Y ; BENGIO, Y. ; HINTON, G. **Deep Learning**. *Nature*, v. 521, n. 7553, p. 436-444, 2015.
- Lee, H., Kim, D. , & Park, J. (2023). **Comparative Analysis of Convolutional Neural Networks and Multilayer Perceptrons for Image Processing Tasks**. *IEEE Transactions on Neural Networks*, 34(1), 55–67.

- Lee, H., & Kim, S. (2023). **Statistical Approaches in Structural Health Monitoring: Current Practices and Future Directions**. *Structural Health Monitoring Journal*, 21(1), 35–50.
- Lee, S., & Choi, Y. (2022). **Beyond Accuracy: Comprehensive Evaluation Metrics for Deep Learning Models**. *IEEE Access*, 10, 34567–34578.
- LEE, Sungbin; SONG, Gook-Hyun; JUNG, Hyunjo. **Review of vibration-based structural health monitoring with special emphasis on composite materials**. *Composite Structures*, v. 213, p. 42-54, 2019.
- Lima, D. F. , Santos, R. L. , & Almeida, J. P. (2022). **Classificação de falhas estruturais: uma abordagem SVM em espaços de alta dimensionalidade**. *Structural Health Monitoring*, 21(4), 350–365.
- Lima, F. A. , Silva, R. M. , & Costa, D. L. (2024). **Maintenance Strategies for Reinforced Concrete Bridges: Risks and Modern Approaches**. *Journal of Structural Engineering*, 45(2), 210–225.
- Li, J. , & Zhao, Y. (2022). **Advances in Recurrent Neural Networks for Sequential Data Processing**. *IEEE Transactions on Neural Networks and Learning Systems*, 33(5), 987–1001.
- Li, X. , Bolandi, H. , Masmoudi, M. , Salem, T. , Lajnef, N. , & Boddeti, V. N. (2024). **Mechanics-Informed Autoencoder Enables Automated Detection and Localization of Unforeseen Structural Damage**. *arXiv preprint arXiv:2402.15492*.
- Li, X., Li, Y., and Wang, Y. (2016). **Recent developments in damage detection using SHM**. *Engineering Structures*, 114, 764–778.
- LI, Y.; ZHANG, Q.; WU, X. **Structural health monitoring based on artificial intelligence: a comprehensive review**. *Engineering Structures*, v. 231, p. 111676, 2021.
- Li, X., Bolandi, H., Masmoudi, M. , Salem, T. , Lajnef, N. , & Boddeti, V. N. (2024). **Mechanics-Informed Autoencoder Enables Automated Detection and Localization of Unforeseen Structural Damage**. Disponível em <https://arxiv.org/abs/2402.15492>
- Li, X., Zhang, Y., & Wang, T. (2022). **Recent Developments in SHM-Based Damage Detection for Infrastructure**. *Smart Structures and Materials*, 27(4), 310–328.
- Liu, H., Kumar, A., & Gupta, R. (2022). **Iterative Training Strategies and Their Impact on Neural Network Learning**. *IEEE Transactions on Neural Networks and Learning Systems*, 33(5), 1789–1802.
- Liu, Y. , & Pereira, A. (2023). **Vibration-Based Structural Health Monitoring for Bridges: A Novel Approach**. *Journal of Bridge Engineering*, 29(3), 345–359.
- Liu, J., & Zhang, Y. (2020). **Automated Structural Health Monitoring Based on Machine Learning Approaches: A Review**. *Computer-Aided Civil and Infrastructure Engineering*, 35(4), 401-419. doi: 10.1111/mice.12533.
- Liu, Y., Ye, Y., Zhang, B. , & Li, X. (2015). **Structural health monitoring: Emerging technologies and applications**. *Structural Health Monitoring*, 14(4), 617-637.

López, C. Orozco, M., & Vega, R. (2011). **Dynamic testing of concrete structures using impact hammers and accelerometers**. *Structural Control Health Monitoring*.

LORENZI, T.; MENDES, A.; FERREIRA, P. **Aplicação de ensaios não destrutivos na inspeção de estruturas de concreto armado**. *Revista Engenharia Estrutural*, v. 25, n. 3, p. 45-58, 2020.

Ludema, K. C. (2019). **Nondestructive Evaluation of Aircraft Structures**. Academic Press.

LIU, Y.; WU, Y.; ZHANG, L. **A Review on Backpropagation Algorithm in Deep Neural Networks**. *Journal of Computational Science*, v. 59, Art. ID 101624, 2022.

L. T. STUTZ, R. A. TENENBAUM & R. A. P. CORREA. **The Differential Evolution method applied to continuum damage identification via flexibility matrix**. *Journal of Sound and Vibration*, 345 (2015), 86-102.

L. S. RANGEL, I. C. S. S. RANGEL & L. T. STUTZ. **Identificação de danos estruturais utilizando dados no domínio do tempo e critério D- ótimo**. *Tendências em Matemática Aplicada e Computacional*, 16 (2015), 209-218.

Mai, W., Xu, J., Das, A., & Werner, DH (2022). **Análise de resposta do sistema no domínio do número de onda para problemas lineares de variação temporal e invariantes no espaço**. *arXiv preprint arXiv:2208.00845*.

MAGALHÃES, F. ; CUNHA, Á. ; CAETANO, E. (2008) **Dynamic Monitoring of a Long Span Arch Bridge**. *Engineering Structures*, 30(11), 3034-3044.

Martins, J. P. , & Oliveira, R. S. (2021). **Uso de SVM para a detecção de anomalias em dados de vibração**. *International Journal of Mechanical Diagnostics*, 10(3), 205–218.

Martins, G. L. , Ribeiro, F. A. , & Souza, M. T. (2023). **Integração de técnicas de machine learning para manutenção preditiva: uma abordagem multimodal**. *Sensors*, 23(3), 110–128.

Mascarenhas, L. P. , Almeida, R. J. , & Souza, F. C. (2024). **Structural Typology and Maintenance Needs of Brazilian Special Engineering Works: A Database Analysis**. *Revista Brasileira de Infraestrutura e Engenharia Estrutural*, 35(2), 150–168.

Mendes, A. P. , & Ferreira, C. R. (2021). **Pathologies in Special Structures Due to Increased Traffic Loads**. *Infrastructure and Structural Monitoring*, 28(2), 132–148.

MING, T. , YANG, C. & YU, S. **Estudo sobre a segurança estrutural de edifícios com técnicas de monitoramento de saúde estrutural**. *International Journal of Structural Stability and Dynamics*, v. 17, n. 4, p. 1-20, 2017.

MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997.

Mo, B. W., & Yang, S. (2018). **Recent advances in structural health monitoring of civil engineering structures**. *Structural Control and Health Monitoring*, 25(12), e2146.

- MORAES, V. M. **Ponte mista de madeira-concreto em vigas treliçadas de madeira.** 2007. 181 p. Dissertação (Mestrado em Engenharia Civil) - Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2007.
- Moura, F. , Santos, A. , & Oliveira, C. (2022). **Predicting Cardiac Diseases Using Multilayer Perceptron: A Clinical Data Approach.** *IEEE Journal of Biomedical and Health Informatics*, 26(2), 789–797.
- MOURA, J. F.; SANTOS, F. A.; SILVA, C. M. **Predicting Cardiovascular Diseases with Multilayer Perceptron Neural Networks.** *Journal of Healthcare Engineering*, v. 2022, Art. ID 1234567, 2022.
- MURPHY, K. P. **Machine Learning: A Probabilistic Perspective.** *Cambridge*: MIT Press, 2012.
- NAGEL, Katharina; SCHULZE, Oliver; WAGNER, Ronald. **Reliability-based optimization of structural maintenance.** *Structural and Multidisciplinary Optimization*, v. 63, n. 2, p. 821-836, 2021.
- National Instruments. (2020). **LabVIEW: What Is LabVIEW.** Disponível em: <https://www.ni.com/en-us/shop/labview.html>
- NI, Y. -Q.; ZHANG, G.; CHEN, J. **Structural health monitoring of landmark suspension bridge.** *Structural Control and Health Monitoring*, v. 27, n. 1, p. e2496, 2020.
- Nguyen, H. T. , & Nguyen, D. D. (2020). **Smart Structural Health Monitoring: A Review of Sensor Technologies for Structural Monitoring.** *Sensors*, 20(9), 2444. doi: 10.3390/s20092444.
- Oliveira, C. F. , & Castro, D. L. (2021). **Computational Modeling and Predictive Maintenance in Structural Engineering.** *Revista Brasileira de Engenharia Estrutural*, 30(1), 95–110.
- Oliveira, M. F. , Santos, R. P., & Carvalho, J. A. (2024). **Advanced Diagnostic and Prognostic Techniques for Structural Integrity.** *Journal of Structural Health Monitoring*, 50(3), 300–315.
- Oliveira, M. R., Souza, P. L., & Almeida, T. F. (2023). **Impactos das infraestruturas rodoviárias na mobilidade e no acesso aos insumos em áreas rurais.** *Revista Brasileira de Engenharia Agrícola*, 15(2), 112–128.
- Oliveira, T. F., Mendes, J. C. , & Castro, A. L. (2023). **Advanced Monitoring Tools for Structural Health Assessment in Special Engineering Works.** *Journal of Infrastructure and Structural Engineering*, 32(1), 95–112.
- Oliveira, T. F., Mendes, J. C. , & Castro, A. L. (2023). **Visual Inspection and Non-Destructive Evaluation Techniques in Structural Analysis: Advances and Limitations.** *Journal of Structural Integrity and Monitoring*, 35(1), 85–102.
- Oliveira, T. F., Mendes, J. C. , & Castro, A. L. (2022). **Operational Load Increase in Bridges: A Comparative Study Based on Brazilian Standards.** *Journal of Structural Engineering*, 31(3), 178–195.

Oliveira, T. R. (2021). **Qualificação Profissional em Projetos de Obras de Arte Especiais**. *Journal of Infrastructure Engineering*, 29(1), 88–104.

Oliveira, T. R., Mendes, A. C., & Santos, F. P. (2023). **Automated Inspection and Pathology Detection in Civil Infrastructure: A Modern Approach**. *Revista Brasileira de Engenharia Estrutural*, 29(3), 112–130.

Pawlak, M. (2020). **Dinâmica de estruturas: Teoria e aplicações**. Nova Jersey: John Wiley & Sons.

Pereira, L. S., Santos, G. F. & Almeida, R. M. (2022). **Confusion Matrix Analysis for Neural Network Classification Performance**. *Neural Processing Letters*, 54, 315–330.

Pieri, J., *et al.* (2018). **Inspection and monitoring of concrete structures using impact hammer testing**. *Journal of Civil Structural Health Monitoring*.

Pollastro, A., Testa, G., Bilotta, A., & Prevete, R. (2022). **Semi-supervised detection of structural damage using Variational Autoencoder and a One-Class Support Vector Machine**. arXiv preprint arXiv:2210.05674.

POLIDO, Marcio José. **Um Estudo de Adequação de Estrada Rural da Microbacia Água das Araras**. 2011. 37fls. Monografia de especialização - Universidade Tecnológica Federal do Paraná, Curitiba, PR, 2011. Disponível em: Acessado dia 21/11/2013.

POWERS, Avaliação DMW : **Da Precisão, Recuperação e Medida F ao ROC, Informação, Marcação e Correlação**.

PRAVIA, Z. M. C.; BRAIDO, J. D. Measurements of bridges' vibration characteristics using a mobile phone. **Revista Ibracon de Estruturas e Materiais**. Volume 8, n. 5. 2015. P. 721-743.

QUINTINO, A. G. ; PAIXÃO, J. F. M. Manifestações patológicas em Obras de Arte Especiais e técnicas avançadas de monitoramento. In: **XVI Congresso Latinoamericano de Patología de la Construcción**. 2021.

Randall, R. B. (2011). **Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications**. Hoboken, NJ: Wiley, 2011.

RAO, S. S. **Mechanical Vibrations**. Third edition. New York, EUA: Addison-Wesley Publishing Company, 1995. 912p.

Redação BdE. (2024). **Sistemas de Monitoramento Estrutural com Sensores Inteligentes**. Blog da Engenharia.

Ricco, MC, Quaresma, JE e Florian, F. (2024). **A importância da manutenção periódica em estruturas metálicas mudam para garantir a segurança e a durabilidade: Estudo de caso**. *Recima21*, 5(1). Disponível em: <https://recima21.com.br/index.php/recima21/article/view/5941/4040>.

ROCHA, Lucas Altamirando de Andrade da *et al.* **Identificação de dano em estruturas utilizando uma metodologia que integra a técnica da impedância eletromecânica e ondas de Lamb**. 2017.

- Rotaflux. (2024). **Estrada Vicinal: O que é e sua importância em áreas rurais.** Disponível em <https://rotaflux.com.br/estrada-vicinal-o-que-e-e-sua-importancia-em-areas-rurais/>
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning Representations by Back-Propagating Errors.** *Nature*, v. 323, p. 533-536, 1986.
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach.** 4. ed. Upper Saddle River: Prentice Hall, 2020.
- SANTOS, LUÍS OLIVEIRA. (2014) “Monitoramento e ensaio de pontes”. **VII Congresso Brasileiro de Pontes e Estruturas.** Rio de Janeiro, RJ. 14p. Disponível em [http://www.abpe.org.br/trabalhos/trab\\_110.pdf](http://www.abpe.org.br/trabalhos/trab_110.pdf) Acesso em 30 de setembro de 2018.
- SANTOS, R. D. , & ALVES, M. C. **Estudo da manutenção de estradas rurais.** *Revista de Agronegócio*, v. 15, n. 3, p. 441-450, 2017.
- Sebastian, M. (2020). **Funções Transferência Usadas na Análise de Estruturas.** Disponível em: <https://msebastian.com/funcoes-de-transferencia-usadas-na-analise-de-estruturas/> [Acessado em: 10 de julho de 2020].
- S. E. FANG & R. PERERA. A response surface methodology based damage identification technique. *J. Iop Publishing*, 18 (2009), 14
- Shah, S. , & Karmakar, A. (2016). **Ageing and Deterioration of Civil Infrastructure and Its Management: A Review.** In *International Journal of Advanced Structural Engineering* (Vol. 8, No. 1, pp. 17-30). doi: 10.1007/s40091-015-0150-8.
- Sharma, I. (2017). **A review of structural health monitoring methods.** *Engineering Failure Analysis*, 79, 127-145.
- SILVA, A.; SANTOS, R. “**A evolução das cargas móveis em pontes brasileiras**”. *Revista Engenharia Estrutural*, v. 15, n. 3, p. 45-60, 2020.
- Silva, A. R., Pereira, L. F. , & Costa, M. S. (2022). **Aplicações de Random Forest na detecção de falhas em sistemas industriais.** *Journal of Industrial Information*, 19(2), 123–134.
- Silva, J. F., & Oliveira, A. R. (2022). **A importância das pontes de pequeno porte no escoamento de produtos agrícolas: implicações econômicas e sociais.** *Revista de Engenharia Rural*, 28(1), 45-60.
- Silva, F., & Oliveira, J. (2015). **Desafios na implementação de sistemas de monitoramento estrutural em tempo real: uma revisão.** *Revista de Engenharia Civil*, 10(2), 45-58.
- Silva, M. A. (2023). **Challenges in Structural Health Monitoring for Concrete Structures.** *Structural Integrity Journal*, 30 (2), 98–115.
- Silva, M. A., Costa, R. L., & Mendes, F. S. (2023). **Obras de Arte Especiais na Engenharia de Infraestrutura: Desafios e Perspectivas.** *Revista Brasileira de Engenharia*, 47(2), 155–172.

- Silva, M. J., & Almeida, P. R. (2023). **Manutenção e Monitoramento de Infraestruturas: Desafios e Perspectivas no Brasil.** *Revista de Engenharia Civil*, 48(1), 65–81.
- Silva, M. R. , & Coelho, J. C. (2017). **Metodologia de análise de condições estruturais de pontes.** *Revista de Engenharia Civil*, 11(2), 143-150.
- Silva, R. M. , Almeida, P. J. , & Costa, L. F. (2024). **Monitoring Techniques for Special Structures: Extending Service Life and Optimizing Maintenance.** *Journal of Structural Engineering and Infrastructure*, 32(1), 78–95.
- SIM, SHEWALE, S. , SURESH, N. , & GHOSH, S. **Estudo de sistemas de monitoramento de saúde estrutural: uma revisão.** *International Journal of Structural Stability and Dynamics*, v. 18, n. 5, p. 1-20, 2018.
- SHEN, T.; WANG, T.; QU, M. **Efficient Sequence Prediction with Neural Networks.** *Journal of Machine Learning Research*, v. 21, n. 5, p. 1-22, 2020.
- Smith, A., & Jones, B. (2022). **A Comparative Analysis of Evaluation Metrics in Machine Learning.** *Journal of Machine Learning Research*, 23(1), 45–67.
- Smith, J. (2020). **Técnicas de aprendizado de máquina e inteligência artificial para detecção de falhas em estruturas e máquinas.** *Revista de Engenharia Civil*, 15(3), 45-58.
- SMITH, J. **Advances in Machine Learning for Structural Health Monitoring.** *Journal of Structural Health Monitoring*, 2020.
- Souza, M. A., & Martins, G. R. (2022). **Non-Destructive Testing and Structural Monitoring: Advances in Damage Assessment Techniques.** *Structural Engineering Review*, 25(2), 145–160.
- SOHN, H., *et al.*, (2002) " **A Review of Structural Health Monitoring Literature: 1996-2001,**" Los Alamos National Laboratory report in preparation.
- SOHN, H., C. R. FARRAR, N. HUNTER e K. WORDEN, (2001) "**Applying the LANL Statistical Pattern Recognition Paradigm for Structural Health Monitoring to Data from a Surface-Effect Fast Patrol Boat,**" Los Alamos National Laboratory Report Los Alamos National Laboratory report LA-13761- MS.
- Sohn, H., Czarnecki, J. J., Farrar, C. R. and Fellow, P. E. "**Structural health monitoring using statistical process control**". In: *Journal of Structural Engineering*, ASCE, 126 (11), p. 1356-1363, 2000.
- Sun, J., Zhao, L., & Chen, D. (2023). **Cumulative Learning in Deep Neural Networks: A Comparative Study.** *Neural Computing and Applications*, 35(2), 456–470.
- Thomas, R., Smith, J., & Garcia, M. (2023). **Optimized Infrastructure Maintenance Based on SHM and Reliability Criteria.** *Journal of Structural Engineering and Infrastructure Management*, 30(2), 123–138.

TOMASZEWSKA, A. **Damage detection and structural health monitoring using modal analysis.** *Engineering Structures*, v. 32, n. 8, p. 2144-2156, 2010. DOI: 10.1016/j.engstruct.2010.03.017.

TOTVS (2023). **Logística no agronegócio: desafios e como superá-los.** Disponível em <https://www.totvs.com/blog/gestao-logistica/logistica-no-agronegocio/>

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L. ; GOMEZ, A. N.; KAISER, Ł.; POLOSUKHIN, I. **Attention is All You Need.** In: *Advances in Neural Information Processing Systems 30 (NIPS 2017)*, p. 5998-6008.

VITÓRIO, A. **Fundamentos da patologia das estruturas nas perícias de engenharia.** Instituto Pernambucano de Avaliações e Perícias de Engenharia 2003. Disponível em: [https://vitorioemelo.com.br/publicacoes/Fundamentos\\_Patologia\\_Estruturas\\_Pericias\\_Engenharia.pdf](https://vitorioemelo.com.br/publicacoes/Fundamentos_Patologia_Estruturas_Pericias_Engenharia.pdf). Acesso em: 20 out. 2021.

Vogel, B. S. , & Rosas, L. R. B. (2024). **Análise técnica de pontes em madeira na região norte de Mato Grosso.** *Revista Arq-Engenharia de Mato Grosso*, 3(1), 74-91. Disponível em: <https://revistas.fasipe.com.br/index.php/rae-mt/article/view/366>.

Wang, L., Chen, H., & Zhao, P. (2021). **Machine Learning Approaches for Structural Fault Classification Using SHM Data.** *Journal of Computational Engineering*, 38(1), 88–105.

Wang, L., Zhang, Y, & Li, X. (2023). **Current Practices and Challenges in Aircraft Structural Health Monitoring.** *Aerospace Engineering Review*, 41(3), 178–195.

Wang, R., Liu, S., & Huang, W. (2023). **Predictive Modeling for Structural Monitoring Using AI-Based SHM Techniques.** *Journal of Civil Engineering and Monitoring*, 45(6), 405–423.

Wang, Y., Li, J., & Chen, R (2023). **Advanced Algorithms for Real-Time Structural Damage Detection: A Novel Approach.** *Structural Health Monitoring*, 22(4), 455–468.

Wang, Y., Liu, Y., & Yang, Y. (2019). **Análise da inspeção estrutural de aeronaves com base em NDE.** *International Journal of Aerospace Engineering*, 2019. <https://doi.org/10.1155/2019/4382090>.

Watanabe, K., *et al.* (2018). **"Concrete Repair, Rehabilitation and Retrofitting IV: Proceedings of the 4th International Conference on Concrete Repair, Rehabilitation and Retrofitting, ICCRRR-1, 5-7 October 2015, Leipzig, Germany"**.

YU, X.; WANG, L.; CHEN, F. (2020). **Advances in modal analysis for structural health monitoring.** *Journal of Vibration and Control*, 26(14-15), 1237-1252.

ZAGUE, P. *et al.* **Combinação estatística de algoritmos de Análise Modal Operacional aplicada a compressores centrífugos.** *arXiv preprint, 2024.* Disponível em: <https://arxiv.org/abs/2407.07273>. Acesso em: 7 fev. 2025.

Zhang, Y., Li, Z., & Wang, Q. (2022). **Application of Multilayer Perceptron in Recommender Systems: Capturing User Preferences.** *Expert Systems with Applications*, 188, 115–124.

- Zhang, Q., & Li, Y. (2020). **Structural Health Monitoring of Civil Infrastructure under Dynamic Loads: A Review**. *Sensors*, 20(3), 687. doi: 10.3390/s20030687.
- Zhang, Q., Liu, X., & Chen, M. (2021). **Advances in Neural Network Models for Pattern Recognition**. *Journal of Machine Learning Research*, 22(107), 1–23.
- Zhang, Q., & Wang, L. (2023). **Multiclass Evaluation of Neural Network Classifiers Using Confusion Matrix and ROC Analysis**. *IEEE Transactions on Neural Networks and Learning Systems*, 34(2), 789–800.
- ZHANG, Yuhang; LI, Jian; WANG, Shuai; *et al.* **Structural damage identification based on deep learning: A comprehensive review and new perspective**. *Engineering Structures*, v. 212, p. 111078, 2020.
- Zhang, X., Kaczmarek, MB, & HosseinNia, SH (2022). **Análise de resposta de frequência para sistemas de controle de reinicialização: aplicação para prever a precisão de sistemas de movimento**. *arXiv pré-impressão arXiv:2206.00523*.
- ZHANG, X.; ZHAO, S.; ZHENG, S. **Deep Learning-Based Neuron Models and Neural Network Architectures: A Review**. *Neural Computation*, v. 33, n. 10, p. 2902-2924, 2021.
- ZHANG, X.; WANG, W.; ZHANG, W. **Improving Recommendation Systems with Multilayer Perceptron: A Review of Recent Approaches**. *ACM Transactions on Intelligent Systems and Technology (TIST)*, v. 13, n. 3, p. 1-21, 2022.
- Z. M. C. PRAVIA | J. D. BRAIDO; **IBRACON Structures and Materials Journal**, 2015.
- ZOU, J.; HAN, Y.; LIU, C. **An Overview of Overfitting in Multilayer Perceptron Networks**. *Journal of Machine Learning Research*, v. 20, n. 6, p. 1-26, 2018.
- Zou, X., Chen, L., & Huang, Y. (2022). **Data Requirements and Overfitting Challenges in Multilayer Perceptron Models**. *Journal of Machine Learning Studies*, 14(3), 321–335.