



MARIA EDUARDA SOARES VIANA

MATHEUS VITOR FERNANDES PIMENTA

**CARACTERIZAÇÃO DE RUPTURAS ATRAVÉS DE
FUNÇÕES DE RESPOSTA EM FREQUÊNCIA UTILIZANDO
REDES NEURAIS ARTIFICIAIS**

LAVRAS – MG

2023

MARIA EDUARDA SOARES VIANA
MATHEUS VITOR FERNANDES PIMENTA

**CARACTERIZAÇÃO DE RUPTURAS ATRAVÉS DE FUNÇÕES DE RESPOSTA EM
FREQUÊNCIA UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Trabalho de conclusão de curso
apresentado à Universidade Federal de
Lavras, em formato de artigo, como parte
das exigências do Curso de Engenharia
Civil, para a obtenção do título de bacharel.

Prof. Dr. Fábio Lúcio Santos

Orientador

LAVRAS – MG

2023

MARIA EDUARDA SOARES VIANA
MATHEUS VITOR FERNANDES PIMENTA

**CARACTERIZAÇÃO DE RUPTURAS ATRAVÉS DE FUNÇÕES DE RESPOSTA EM
FREQUÊNCIA UTILIZANDO REDES NEURAS ARTIFICIAIS**
**CHARACTERIZATION OF RUPTURES THROUGH FREQUENCY RESPONSE
FUNCTIONS USING ARTIFICIAL NEURAL NETWORKS**

Trabalho de conclusão de curso
apresentado à Universidade Federal de
Lavras, em formato de artigo, como parte
das exigências do Curso de Engenharia
Civil, para a obtenção do título de bacharel.

APROVADO em 12 de dezembro de 2023

Dr. Lucas Henrique Pedrozo Abreu - UFLA

Dr. Paulo Roberto Borges - UFLA


Prof. Dr. Fábio Lúcio Santos

Orientador

LAVRAS – MG

2023

RESUMO

Com o aperfeiçoamento das técnicas construtivas, o estudo para a conservação da integridade estrutural tem sido cada vez mais aprofundado. Certas deficiências como a formação de fissuras e deformações, podem ser amparadas com o monitoramento de estruturas por meio da instrumentação da estrutura. A definição desses parâmetros permite conhecer o comportamento dinâmico do sistema estrutural e definir a necessidade da manutenção. Assim, este estudo foi realizado com o objetivo de caracterizar dinamicamente e detectar danos em vigas de 45 mm de MDF, a partir do treinamento de redes neurais artificiais que fariam a leitura dos espectros de frequência. Os ensaios foram realizados no Laboratório de Vibrações Mecânicas, e os dados foram obtidos por meio do *software LabView®*. Os entalhes na viga, que simulam as falhas, variaram de 0 mm (sem defeito) à 40 mm, com incremento de 5 mm entre os diferentes cenários estudados. Os dados foram processados no *software MatLab*, para que fossem extraídas as FRFs (Funções de Resposta em Frequências) para cada ponteira. Com a determinação dos espectros de frequência do sistema, foi desenvolvida uma rede neural no *software RStudio* para identificação de danos na estrutura estudada. Após as etapas de treinamento e validação, foram utilizados os índices *Kappa* e acurácia para verificação da predição da RNA, e, assim, foram determinadas as melhores arquiteturas do sistema. Devido a concordância perfeita, as RNAs demonstraram ser capazes de predizer tanto a existência quanto a severidade do defeito.

Palavras chave: monitoramento de estrutura, vibrações, espectros de frequência, rede neural, *Kappa*.

ABSTRACT

With the improvement of construction techniques, the study for the conservation of structural integrity has been increasingly in-depth. Certain deficiencies, such as the formation of cracks and deformations, can be addressed by monitoring structures through instrumentation of the structure. The definition of these parameters makes it possible to understand the dynamic behavior of the structural system and define the need for maintenance. Therefore, this study was carried out with the objective of dynamically characterizing and detecting damage in 45 mm MDF beams, based on the training of artificial neural networks that would read the frequency spectra. The tests were carried out in the Mechanical Vibration Laboratory, and the data were obtained using the LabView® software. The notches on the beam, which simulate failures, ranged from 0 mm (no defect) to 40 mm, with an increase of 5 mm between the different scenarios studied. The data was processed in the MatLab software, so that the FRFs (Frequency Response Functions) were extracted for each tip. With the determination of the system's frequency spectra, a neural network was developed in the RStudio software to identify damage in the studied structure. After the training and validation stages, the Kappa and accuracy indices were used to verify the ANN prediction, and, thus, the best system architectures were determined. Due to perfect agreement, ANNs proved to be capable of predicting both the existence and severity of the defect.

Keywords: structure monitoring, vibrations, frequency spectra, neural network, Kappa.

LISTA DE FIGURAS

Figura 1 - Fluxograma das etapas do trabalho.....	10
Figura 2 - Corpos de prova utilizados no experimento.....	11
Figura 3 - Configuração experimental.....	13
Figura 4 - Esquemático dos equipamentos utilizados.....	13
Figura 5 - Composição de uma RNA perceptron multicamadas.....	17
Figura 6 - Magnitudes dos testes feitos com a ponteira de metal.....	21
Figura 7 - Magnitudes dos testes feitos com a ponteira de borracha.....	21
Figura 8 - Magnitudes dos testes feitos com a ponteira de plástico.....	22
Figura 9 - Imagem do processo de treinamento e validação para o cenário de 2 classes.....	24
Figura 10 - Imagem do processo de treinamento e validação para o cenário de 3 classes.....	24
Figura 11 - Resultado do treinamento das RNAs de 2 classes referentes a ponteira de metal.	25
Figura 12 - Resultado do treinamento das RNAs de 3 classes referentes a ponteira de metal.	25

LISTA DE TABELAS

Tabela 1 - Classificação de concordância conforme Landis e Koch (1977).....	20
Tabela 2 - Frequências naturais em Hertz (Hz) utilizando a ponteira de metal.....	22
Tabela 3 - Frequências naturais em Hertz (Hz) utilizando a ponteira de borracha.....	23
Tabela 4 - Frequências naturais em Hertz (Hz) utilizando a ponteira de plástico.....	23
Tabela 5 - Arquiteturas RNA selecionadas após as etapas de treinamento e validação.....	26
Tabela 6 - Resultados das RNA selecionadas após as etapas de treinamento e validação.....	26

SUMÁRIO

1	INTRODUÇÃO.....	9
2	MATERIAL E MÉTODOS.....	11
2.1	Caracterização dos corpos de prova.....	11
2.2	Sistema de aquisição de dados.....	12
2.3	Configuração experimental.....	13
2.4	Determinação das funções de resposta de frequência.....	15
2.5	Determinação das frequências naturais.....	15
2.6	Modelagem de redes neurais artificiais.....	16
2.7	Desenvolvimento das redes neurais artificiais.....	17
3	RESULTADOS E DISCUSSÃO.....	22
3.1	Determinação das FRFs.....	22
3.2	Resultado do treinamento de redes neurais artificiais.....	24
4	CONCLUSÃO.....	28
	REFERÊNCIAS.....	29

1 INTRODUÇÃO

Com o passar do tempo, o monitoramento de estruturas tem tido bastante destaque devido ao envelhecimento das construções. Comparando o período em que a humanidade se estabeleceu em um local, é recente a execução da primeira construção feita de cimento Portland, e por ser um material bastante utilizado em obras de infraestrutura duradouras, há um interesse no conhecimento da vida útil do concreto, visto que se preza pela segurança, funcionalidade e estética dessas construções.

Por outro lado, também há a preocupação com a ocorrência de eventos adversos que podem comprometer uma estrutura, tais como terremotos, recalques excessivos e intempéries que surgem dependendo do ambiente e ações antrópicas que, podem ter como consequência, problemas na construção.

A engenharia diagnóstica é a área da engenharia civil que busca entender o comportamento de falhas e anomalias (ROSSI JÚNIOR, 2022) e utiliza como ferramentas de análise o monitoramento de estruturas. A partir da análise é feito o diagnóstico da construção apontando as manifestações patológicas.

Os estudos relacionados aos resultados de uma manifestação patológica proporcionaram o desenvolvimento de técnicas que buscam fornecer parâmetros de classificação mais assertivos (GUERRA, 2022). Com as análises numéricas realizadas por meio de simulações no estudo de Delalibera (2006) foram representados com maior precisão o comportamento real de blocos sobre estacas. No trabalho de Silva (2018) as análises numéricas focaram no estudo da deterioração por meio de temperaturas elevadas.

Neste campo, emerge o Monitoramento de Saúde Estrutural (SHM – *Structural Health Monitoring*) que engloba o conjunto de dimensões, métodos e avanços tecnológicos que oferecem informações numéricas fundamentais para estabelecer diagnósticos mais precisos, e está cada vez mais centrado na aplicação de sensores inteligentes e análise de dados em tempo real, proporcionando uma abordagem proativa para a gestão de infraestruturas (BOLLER; CHANG; FUJINO, 2009)

Como exemplos de aplicação que busca a aquisição de dados referentes ao comportamento dinâmico das estruturas, está a análise do modo de vibração de uma viga com sensor piezoelétrico que permite determinar frequências próximas às naturais (SILVA, 2018).

Em outro estudo parecido que utiliza o mesmo sensor, é descrita a criação de um sistema portátil e econômico para a medição de impedância. Esse sistema tem a capacidade de medir e registrar automaticamente as leituras de sensores piezoelétricos, eliminando a

necessidade de intervenção humana. Nos testes foi utilizada uma viga de alumínio para o monitoramento de danos (PALOMINO, 2012).

O estudo de Guerra (2022) apresentou uma inovação no campo de sistemas de micro-ondas não destrutivos, visando a medição de umidade em blocos vazados de concreto. A abordagem empregou uma superfície seletiva de frequência (FSS) como componente sensor, enquanto arranjos de antenas de microfita foram utilizados como transmissores e receptores dos sinais de leitura.

Para realizar o monitoramento de estruturas é necessário encontrar uma metodologia eficaz e eficiente para ser aplicada na detecção de danos, onde é realizada a instrumentação para a inspeção de parâmetros que permitem o conhecimento do comportamento dinâmico da estrutura para que se possa adotar as medidas de manutenção coerentes ao problema identificado (MONTEIRO, 2023). Com a ajuda da tecnologia, fica mais fácil identificar isso, pois é necessário o uso de ferramentas que lidam com um grande conjunto de dados.

As redes neurais artificiais (RNAs) se mostraram uma ferramenta bastante útil e promissora na detecção de danos, onde foi capaz de interpretar modelos numéricos de danos em estruturas aperticadas, danos em vigas de concreto protendido, danos de articulações de pontes treliçadas, entre outros (MARCY, 2017).

Essa ferramenta tem a capacidade de resolver problemas complexos reconhecendo padrões, sendo similar ao funcionamento do cérebro humano. Com essa capacidade, ela é capaz de aprender, errar e descobrir (SILVA et. al., 2004). Dessa forma, a condução dessa tecnologia se apoia em experiências obtidas de trabalhos relacionados e a partir do contexto do trabalho a que está sendo submetida (MARCY, 2017).

No trabalho de Palomino (2012); Durval *et al.* (2018), foram utilizadas redes neurais que conseguiram classificar os danos inseridos de forma eficiente em vigas de alumínio.

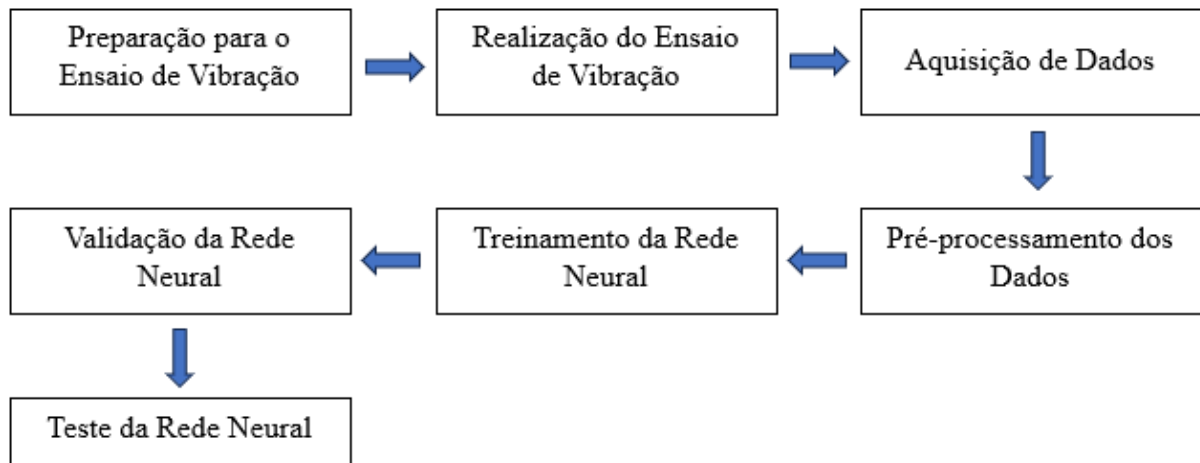
Diante do contexto apresentado, este trabalho tem o objetivo de obter um modelo de detecção de danos em vigas através de redes neurais artificiais (RNA) que permita o desenvolvimento de uma estratégia de monitoramento de uma estrutura por meio da análise das funções de resposta em frequência (FRFs).

2 MATERIAL E MÉTODOS

O experimento foi realizado no Laboratório de Vibrações Mecânicas do Departamento de Engenharia da UFLA.

A metodologia consiste no treinamento de uma RNA para interpretar Funções de Resposta em Frequência de um sistema composto por uma viga de madeira de MDF em balanço. As Funções de Resposta em Frequência foram obtidas a partir de análise modal experimental por excitação impulsiva, em que os impactos foram realizados por meio de martelo de impacto. A Figura 1 apresenta o fluxograma que indica cada etapa do experimento.

Figura 1 - Fluxograma das etapas do trabalho



Fonte: dos autores (2023).

Portanto, para o sistema físico avaliado foi realizada uma progressão de entalhes, ao longo das execuções dos ensaios, sendo determinadas FRF's para todas as condições propostas, objetivando avaliar as assinaturas espectrais do sistema.

2.1 Caracterização dos corpos de prova


Os corpos de provas foram compostos por ripas de madeira MDF de 70 cm de comprimento, 4,5 cm de largura e 0,6 cm de espessura, conforme é observado na Figura 2. Eles podem ser removidos do engaste sem serem destruídos e de forma que não danifique a estrutura do engaste, permitindo o uso do mesmo engaste com outros corpos de prova.

A escolha da madeira MDF ocorreu devido a facilidade de obtenção de corpos de provas com as mesmas dimensões, densidades e composições. Também foi levado em consideração as suas propriedades mecânicas em comparação com materiais cerâmicos, o que

permite a realização de mais entalhes e testes antes do colapso da estrutura. A maior resistência desse material, decorre da utilização de madeira de baixa densidade que permite a fabricação dos MDFs com melhores propriedades mecânicas (ELEOTÉRIO, 2000).

Nos corpos de prova após a realização de cada ciclo de ensaios, foi feito um entalhe transversal de 5 mm para o próximo ciclo de testes. Os entalhes na viga, que simulam as falhas, variaram de 0 mm (sem defeito) à 40 mm, com incremento de 5 mm entre os diferentes cenários estudados, totalizando 9 cenários, sendo um sem entalhe e 8 com entalhes de tamanhos diferentes. A Figura 2, mostra os corpos de prova com entalhe de 4,5 cm, que foi o último entalhe realizado. Esses entalhes simulam falhas no corpo de prova, que permitem que seja feito o estudo de diferentes cenários e diferentes condições de severidade.

Figura 2 - Corpos de prova utilizados no experimento.



Fonte: dos autores (2023).

2.2 Sistema de aquisição de dados

Para a aquisição dos dados e geração das funções de resposta em frequência foi utilizado a linguagem *LabView*®, também desenvolvida pela *National Instruments*, associado ao pacote *Sound and Vibration* para realização de análises modais experimentais. A instrumentação utilizada no trabalho encontra-se descrita a seguir:


- um Chassi CompactDAQ cDAQ-9174 de 4 slots, que opera a uma temperatura de -20°C a 55°C com alimentação por USB, projetado para sistemas portáteis de pequeno porte que fazem medições com sensores. Ele também é responsável pela alimentação dos módulos que são acoplados nele e pela transmissão dos dados para o computador.

- um módulo de entrada *Sound and Vibration* de 4 canais NI9234, com 4 canais de entrada analógica, faixa de tensão de entrada analógica de -5 V a 5V, taxa de amostragem máxima de 51.2 kS/s/ch que mede sinais de sensores piezoelétricos com eletrônica embarcada (IEPE).
- um acelerômetro uniaxial de alta sensibilidade fabricado pela PCB Piezotronics™ com sensibilidade de 97,4mV/g. Este é utilizado para medir a vibração da estrutura e possui uma massa adesiva em sua base para fixação no corpo de prova.
- um martelo de impacto produzido pela PCB Piezotronics™; modelo PCB 086C03 com sensor de força. Este martelo registra a força de impacto e é utilizado em conjunto com o acelerômetro.
- três ponteiros de martelo de impacto, sendo uma de metal, a segunda de borracha e a terceira de plástico.
- um cabo para transmissão dos dados obtidos pelo acelerômetro para o módulo de entrada de *Sound and Vibration*.
- cabos para alimentação e transmissão de dados que conectam o martelo e o módulo de entrada de *Sound and Vibration*; o módulo e o computador; o chassi e a tomada.
- uma peça de madeira maciça com braçadeira para o engastamento dos corpos de prova.
- um computador com software *LabView*® instalado.

2.3 Configuração experimental

O corpo de prova foi engastado por meio de abraçadeira com travamento por parafusos e porcas. A distância entre a extremidade mais próxima do corpo de prova e o engastamento foi de 16 cm. Dessa forma, o corpo de prova permaneceu na horizontal com apenas o engaste como ponto de apoio, simulando uma viga em balanço. No corpo de prova, a 1,5 cm do engaste são realizados os entalhes, a 4 cm posteriores é o ponto destinado ao impacto do martelo e a mais 17 cm fica posicionado o acelerômetro como demonstrado na Figura 3.

Figura 3 - Configuração experimental.

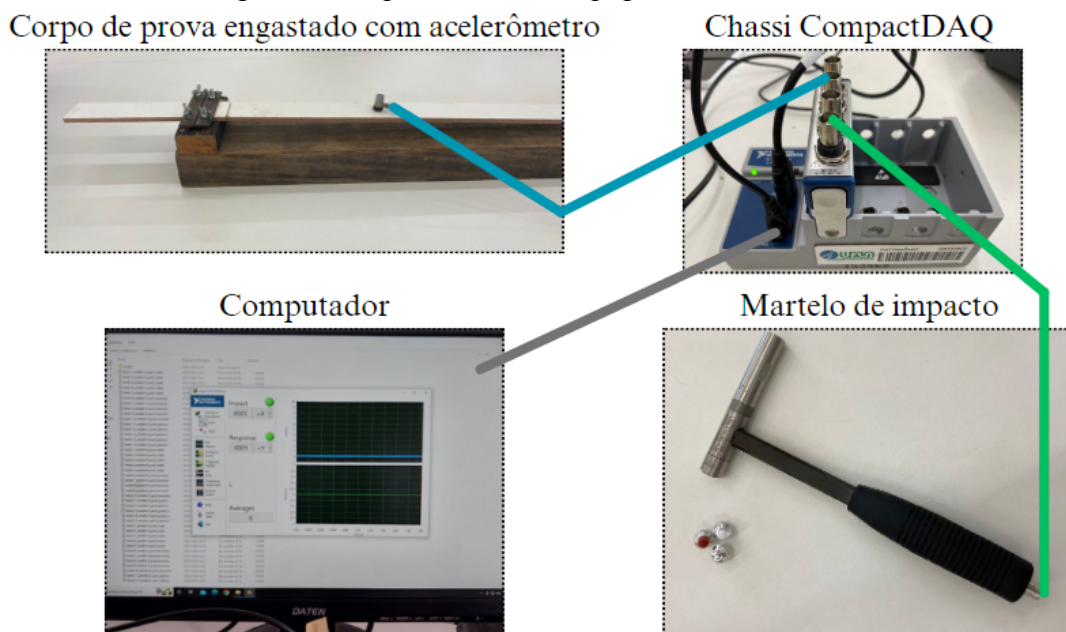


Fonte: dos autores (2023).

Foram empregadas diferentes ponteiros para a excitação do sistema: borracha, plástico e metal, visto que o uso de diferentes ponteiros influenciam nas FRFs em diferentes faixas de frequência. O martelo foi conectado por meio de um cabo ao módulo do sistema de aquisição de dados e transmite a força de impacto aplicada durante o impacto.

O módulo para aquisição de sinais de vibração e impacto foi acoplado no chassi cDAQ-9174 que por sua vez foi conectado ao computador que irá realizar a leitura e gravação dos dados obtidos como mostra a Figura 4.

Figura 4 - Esquemático dos equipamentos utilizados



Fonte: dos autores (2023).

2.4 Determinação das funções de resposta de frequência

A determinação das funções de resposta de frequência ocorre através do ensaio de impacto, considerando a metodologia SISO (*Single Input Single Output*). O impacto do martelo provoca uma vibração no corpo de prova e a magnitude dessa vibração é registrada pelo acelerômetro.

O ensaio completo consiste em ciclos de ensaio feitos para cada entalhe. Cada ciclo consiste na média de 5 impactos para cada uma das 3 ponteiros, por corpo de prova. As FRFs foram obtidas considerando-se como critério de rejeição ou aceitação do ensaio o parâmetro de coerência, em que a partir do seu valor pode-se inferir sobre a qualidade do ensaio realizado em termos da excitação imposta e a resposta obtida. Nesse contexto, ao longo das faixas de frequência de interesse buscou-se valores de coerência superiores a 0,8.

Com o auxílio de um programa desenvolvido para a realização da aquisição de dados por meio do software *LabView*®, foi possível armazenar e tratar os dados obtidos (aceleração no domínio do tempo). A partir do pacote *Sound and Vibration*, produzido pela *National Instruments*, integrado à plataforma *LabView*®, foram determinadas as respostas em frequência.

A faixa de frequência estudada foi de 0 a 2560Hz, na qual foram registradas as magnitudes de aceleração a cada 0,5Hz. Foram ensaiadas 5 vigas com 9 entalhes para cada ponteira, informações as quais constituíram o banco de dados para as etapas subsequentes do trabalho.

As Funções de Resposta em Frequência (FRF) foram obtidas a partir de um programa desenvolvido em linguagem *MatLab*, que realiza a leitura dos dados exportados do *LabView*® e gera os gráficos a partir das médias dos ensaios.

2.5 Determinação das frequências naturais

O primeiro passo foi armazenar todos os dados obtidos nos ensaios no Laboratório de Vibrações Mecânicas, por meio do software *LabView*®.

Com os dados de cada sistema; sem entalhe, primeiro entalhe de 5mm, segundo entalhe de 10mm, e assim, sucessivamente, organizados num bloco de notas, foi possível elaborar um banco de dados com as frequências e magnitudes obtidas.

A partir dos dados de frequências versus magnitudes, foram produzidos gráficos com as médias das FRFs (Funções de Resposta em Frequências) para cada ponteira. E a partir desses gráficos foram extraídas as frequências naturais que ocorreram para cada entalhe.

A determinação das frequências naturais é importante para o conhecimento dos sistemas vibratórios. Essas frequências, que dependem da forma e da rigidez do sistema, representam a vibração por conta própria do sistema após ser estimulado externamente (RAO, 2017).

2.6 Modelagem de redes neurais artificiais

Este estudo emprega a metodologia de redes neurais para abordar a tarefa de classificação de padrões. A escolha por redes neurais se baseia na capacidade intrínseca desses modelos em aprender representações complexas e não lineares a partir de dados de entrada, fazendo o uso de uma extensa rede de células computacionais simples, também chamadas de unidades de processamento ou "neurônios" (HAYKIN, 2001 apud FLECK *et al.*, 2016).

Inicialmente, os dados são coletados e separados em um conjunto de treinamento e um de testes. Essa separação dos dados deve ser feita de modo a cobrir todo o problema, desde as operações normais, até as condições limites do domínio, considerando as exceções, para evitar ambiguidades e erros. Também pode ser utilizado um conjunto de validação contido dentro do conjunto de treinamento, em que será utilizado para avaliar a capacidade de generalização da rede durante o treinamento (FURTADO, 2019).

Para a configuração da rede neural é necessário determinar qual o paradigma neural será utilizado. Panchal *et al.* (2011) argumentaram que as redes *Multilayer Perceptrons* (MLP), com fluxo de informação de movendo unidirecionalmente (*feedforward*) e normalmente treinadas com algoritmo de retropropagação (*backpropagation*), são muito populares.

Também é necessário determinar a topologia da rede, que é caracterizada pelo número de camadas, quantidade de neurônios de cada camada, funções de ativação e hiperparâmetros. A quantidade de neurônios é determinada pelo formato do problema, na camada de entrada é de acordo com a quantidade de características dos dados de entrada, na camada de saída é de acordo com as classificações que o problema pede, nas camadas ocultas é determinado pela experimentação, onde é necessário ajustar a complexidade da rede verificando a sua capacidade de assimilação, ao mesmo tempo em que evita o *overfitting*, caracterizado como um ajuste satisfatório aos dados de treinamento, mas que é ineficaz para generalizar corretamente com novos dados (SANABIO, 2022). A topologia no geral é também determinada pela experiência de quem a projeta, que realiza os testes para avaliar qual a melhor arquitetura (TÁPIA; ROISENBERG; BARRETO, 2000).

Durante o treinamento, os pesos das conexões são ajustados conforme o algoritmo escolhido, com o objetivo de melhorar a capacidade de generalização do modelo e diminuir as perdas. O treinamento deve ser interrompido quando ele atingir seus objetivos (FURTADO, 2019).

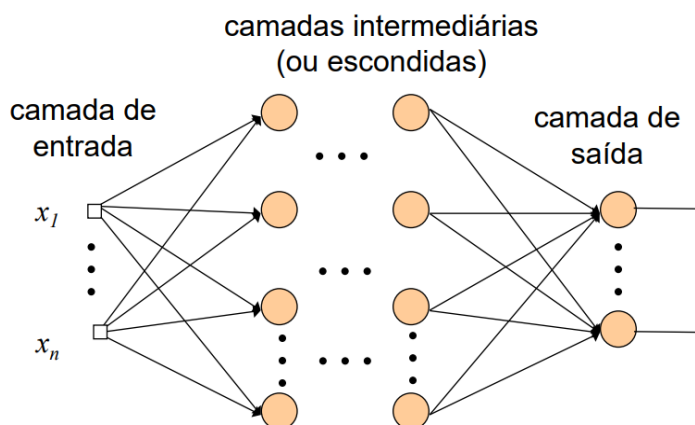
Para atestar a qualidade do treinamento, é realizada a validação da rede, com um conjunto de dados que não foi visto durante o treinamento. Dessa forma, é possível realizar ajustes de hiperparâmetros e prevenir o *overfitting*, a partir dos resultados de indicadores como a acurácia e as perdas (BOCHIE *et al.*, 2020).

Por fim são realizados testes com dados que ainda não foram utilizados anteriormente (FURTADO, 2019). A partir dos testes é medido o desempenho da rede a partir de métricas que dizem qual a capacidade de previsão, precisão, concordância, efeitos do desbalanceamento, entre outros.

2.7 Desenvolvimento das redes neurais artificiais

As redes MLP foram adotadas para a configuração da rede, pois são compostas por uma série de unidades sensoriais (neurônios) formando a camada de entrada, seguida por uma ou mais camadas ocultas (ou intermediárias) de neurônios e, por fim, uma camada de saída, como ilustrado na Figura 5.

Figura 5 - Composição de uma RNA perceptron multicamadas.



Fonte: Renato Tinós (2018).

O treinamento de uma MLP começa com a seleção de amostras previamente classificadas. Cada amostra no conjunto de treinamento tem suas características extraídas e incorporadas à camada de entrada da rede. A classificação esperada é adicionada à camada de saída. Durante o treinamento, as informações percorrem os neurônios, camada por camada, em uma fase chamada de *forward*, indo da entrada para a saída da rede (LUDERMIR; BRAGA; CARVALHO, 2000). Após a propagação das informações pela rede, é verificado se a solução esperada foi alcançada, característica de redes supervisionadas.

A abordagem supervisionada é justificada pelos objetivos específicos que têm a necessidade de dados rotulados. Neste trabalho, a identificação de danos estruturais ocorre em dois cenários: no primeiro, os rótulos de saída representam as classes de existência de defeito, como "com defeito" e "sem defeito", e no segundo, os rótulos de saída representam as classes de severidade de dano, em "baixo", "médio" e "alto". Ao realizar um treinamento supervisionado, a rede neural aprende a associar padrões nas magnitudes de frequências naturais de vibração a essas classes específicas, otimizando a precisão na previsão das condições desejadas.

Existem mais duas formas de abordagem, a aprendizagem não-supervisionada e o reforço. A não-supervisionada tem a capacidade de encontrar padrões sem a necessidade de rótulos predefinidos, sendo amplamente utilizada em tarefas de agrupamento e análise exploratória de dados. O reforço é parecido com o modelo supervisionado no sentido de saber se há respostas corretas ou não na saída. A diferença está em não dispor previamente as respostas corretas, cabendo a um crítico externo avaliar quais são satisfatórias, isto é,

funcionando por tentativa e erro (FURTADO, 2019). Nenhuma dessas duas formas se encaixa no problema deste trabalho.

A modelagem da RNA foi desenvolvida utilizando o software RStudio, um IDE (Ambiente de Desenvolvimento Integrado) que oferece uma interface de trabalho amigável para criação de algoritmos e códigos em linguagem R, e foi composta por três etapas: treinamento, validação e teste, onde 60% dos dados foram utilizados para treinamento, e, 20% destes, foram utilizados para validação. Os 40% restantes do total foram destinados aos testes.

Na etapa de treinamento foi considerada a seguinte arquitetura: 5.121-n1-n2-2 para o cenário de 2 classes e 5.121-n1-n2-3 para o cenário de 3 classes, sendo 5.121 o número de elementos no vetor de entrada, n1 e n2 o número de neurônios em cada camada oculta. Diversas configurações foram testadas na camada oculta da RNA, onde o número de neurônios foi acrescido de 5 em 5. Os neurônios da primeira camada oculta (n1) variaram de 5 a 50 e o número de neurônios da segunda camada (n2) variou de 0 a 50, onde uma quantidade nula representa a ausência da segunda camada. No total foram analisadas 110 arquiteturas para cada cenário de cada ponteira. O número de neurônios na camada de saída varia conforme a quantidade de classes.

Uma vez treinada a RNA utilizando o conjunto de dados de treinamento, seu desempenho foi avaliado a partir do conjunto de dados de validação. Os indicadores de validação são a acurácia e as perdas. Após a validação são realizados os testes que irão avaliar a rede neural por meio da acurácia e do *Kappa*.

A acurácia indica o quão próximo é uma estimativa do seu parâmetro ou valor verdadeiro (MIKHAIL; ACKERMANN, 1976). A função da acurácia na validação de uma RNA, é fornecer uma medida geral de quão bem o modelo está realizando suas previsões em todas as classes. Seu cálculo é feito conforme a Eq. 1:

$$Acurácia = \frac{\text{Número de instâncias corretamente classificadas}}{\text{Número total de instâncias}} \quad (1)$$

A acurácia quando tem valores próximos a 1 indicam bom desempenho e quando possui valores próximos a 0 indicam péssimo desempenho. É importante que a acurácia tenha um desempenho superior a um modelo que faz previsões aleatoriamente, pois ela precisa ter um desempenho superior ao acaso para justificar sua utilidade.

A acurácia oferece apenas uma visão geral do desempenho de um modelo de classificação. Mas é importante destacar que em cenários de desequilíbrio entre as classes, onde uma classe é significativamente mais comum que a outra, a acurácia pode não ser uma medida apropriada. Nestas circunstâncias, métricas alternativas podem ser mais esclarecedoras (CASTRO; BRAGA, 2011).

O índice *Kappa* é baseado na construção de matrizes de erro ou de contingência. O uso desse coeficiente é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação (BERNARDES, 2006).

A matriz de confusão acomoda as diferentes combinações de classificações para cada classe, representando o total de previsões corretas e incorretas para cada classe (FACELI *et al.*, 2011).

Conforme Rosenfield e Fitzpatrick-Lins (1986 apud SARTORI, 2006), o coeficiente *Kappa* representa uma medida da diferença entre a concordância efetiva do mapeamento (refletida pela concordância entre as classes resultantes e os dados de referência, cujos valores são encontrados na diagonal da matriz de confusão) e a concordância que ocorreria ao acaso (calculada pelo produto dos valores marginais das linhas e colunas da matriz de confusão). A Eq. 2 mostra como é feito o cálculo do *Kappa*:

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (2)$$

onde P_o é a proporção observada de concordância e P_e é a proporção esperada de concordância ao acaso. Os valores podem variar de -1 a 1, sendo que -1 indica uma discordância perfeita, 0 indica uma concordância igual a esperada ao acaso e 1 uma concordância perfeita.

A avaliação do nível de concordância do valor de *Kappa* se baseia em uma classificação proposta por Landis e Koch (1977) em seu estudo de caso e que vem sendo usada em estudos mais recentes (BAZAN, 2020; PERTILLE *et. al.*, 2018). Essa classificação é mostrada na Tabela 1.

Tabela 1 - Classificação de concordância conforme Landis e Koch (1977)

Valor de <i>Kappa</i>	Nível de concordância
< 0	Não há concordância
0 - 0,20	Concordância mínima
0,21 - 0,40	Concordância razoável
0,41 - 0,60	Concordância moderada
0,61 - 0,80	Concordância substancial
0,81 - 1,00	Concordância perfeita

Fonte: Landis e Koch (1977).


A escolha da arquitetura da RNA considerou os maiores valores de acurácia e *Kappa*. Também foi levado em consideração a escolha da arquitetura mais simples, pois quanto maior a complexidade da RNA, maior é o tempo de treinamento e é exigido um maior poder computacional.

3 RESULTADOS E DISCUSSÃO

3.1 Determinação das FRFs

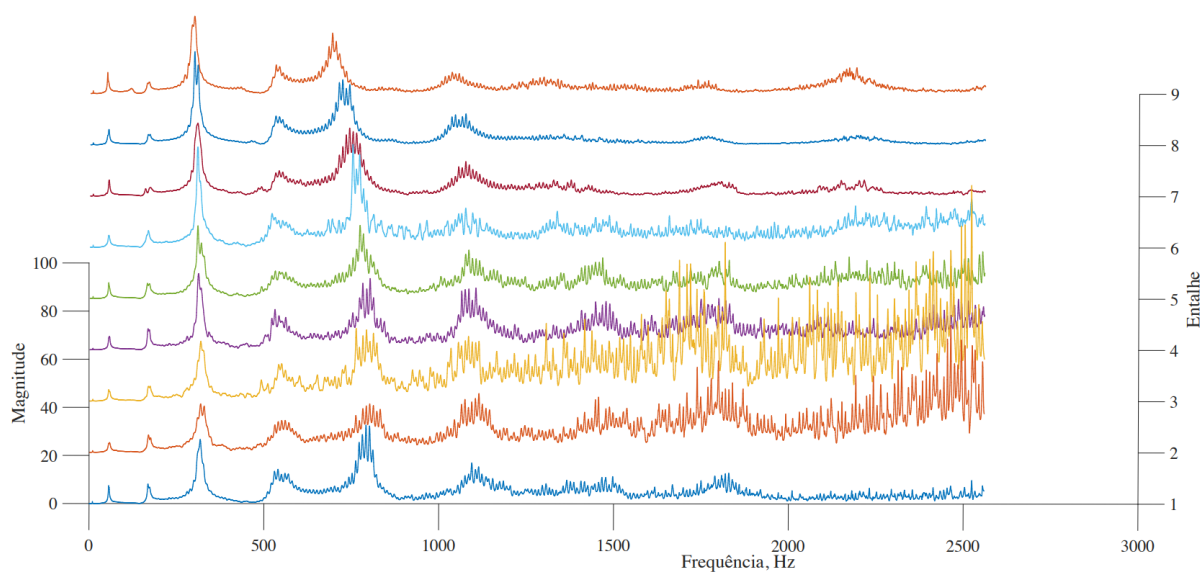
As figuras a seguir estão representadas com os gráficos das médias das FRFs (Funções de Resposta em Frequências) para ponteira de metal (FIGURA 6), ponteira de borracha (FIGURA 7) e ponteira de plástico (FIGURA 8).

Figura 6 - Magnitudes dos testes feitos com a ponteira de metal.




Fonte: dos autores (2023).

Figura 7 - Magnitudes dos testes feitos com a ponteira de borracha.



Fonte: dos autores (2023).

Figura 8 - Magnitudes dos testes feitos com a ponteira de plástico.



Fonte: dos autores (2023).

Analisando os gráficos, foi possível inferir que as frequências naturais são determinadas nesse espectro pelos picos que nele surgem, e, a partir deles, foi possível determinar os valores dessas frequências para ponteira de metal (TABELA 2), ponteira de borracha (TABELA 3) e ponteira de plástico (TABELA 4).

Tabela 2 - Frequências naturais em Hertz (Hz) utilizando a ponteira de metal.

Entalhe	1 ^a frequência	2 ^a frequência	3 ^a frequência	4 ^a frequência	5 ^a frequência	6 ^a frequência
Sem	9,5	56	168,5	318	566	798,5
1	9,5	55,5	169,5	316	564,5	797,5
2	9,5	55,5	168,5	315	551,5	807
3	9,5	56	172	312,5	555	792
4	9	54	165	309	548,5	775
5	8,5	53	166,5	308	523,5	770,5
6	8,5	53,5	173	304	543,5	763,5
7	7,5	52,5	170,5	298,5	531	717
8	7	48,5	167,5	292	537,5	691

Fonte: dos autores (2023).

Tabela 3 - Frequências naturais em Hertz (Hz) utilizando a ponteira de borracha.

Entalhe	1 ^a frequência	2 ^a frequência	3 ^a frequência	4 ^a frequência	5 ^a frequência	6 ^a frequência
Sem	9,5	56	168,5	318	540,5	792
1	9,5	58	169,5	318,5	560,5	802
2	9,5	55	173,5	318,5	550	762,5
3	9	56,5	167	311,5	530	802
4	9	54	164,5	309	530,5	772,5
5	8,5	53,5	166,5	308	520,5	751,5
6	8,5	53,5	172,5	307,5	540	741,5
7	8	52,5	170	298,5	530,5	721,5
8	7	48,5	167,5	297,5	530,5	691,5

Fonte: dos autores (2023).

Tabela 4 - Frequências naturais em Hertz (Hz) utilizando a ponteira de plástico.


Entalhe	1 ^a frequência	2 ^a frequência	3 ^a frequência	4 ^a frequência	5 ^a frequência	6 ^a frequência
Sem	9,5	56	168,5	317,5	565	797,5
1	9,5	55,5	169,5	316	572,5	828,5
2	9,5	55,5	168,5	315,5	551,5	807,5
3	9	55,5	172	313	533,5	790
4	9	55,5	167	317,5	531	799
5	8,5	53	166	308	522	785
6	8,5	53,5	172,5	304	531	739,5
7	8	52,5	170,5	298	530,5	717,5
8	7	48,5	163	292	541	691,5

Fonte: dos autores (2023).

3.2 Resultado do treinamento de redes neurais artificiais

Na etapa de validação, foram obtidos os valores de perda e acurácia. As Figuras 9 e 10 mostram a evolução no desempenho do aprendizado para cada cenário que apresentaram resultados satisfatórios após várias épocas do treinamento.


Figura 9 - Imagem do processo de treinamento e validação para o cenário de 2 classes.



Legenda: o eixo das abscissas representam as épocas do treinamento e o eixo das ordenadas representam as escalas de cada indicador.

Fonte: dos autores (2023).

Figura 10 - Imagem do processo de treinamento e validação para o cenário de 3 classes.

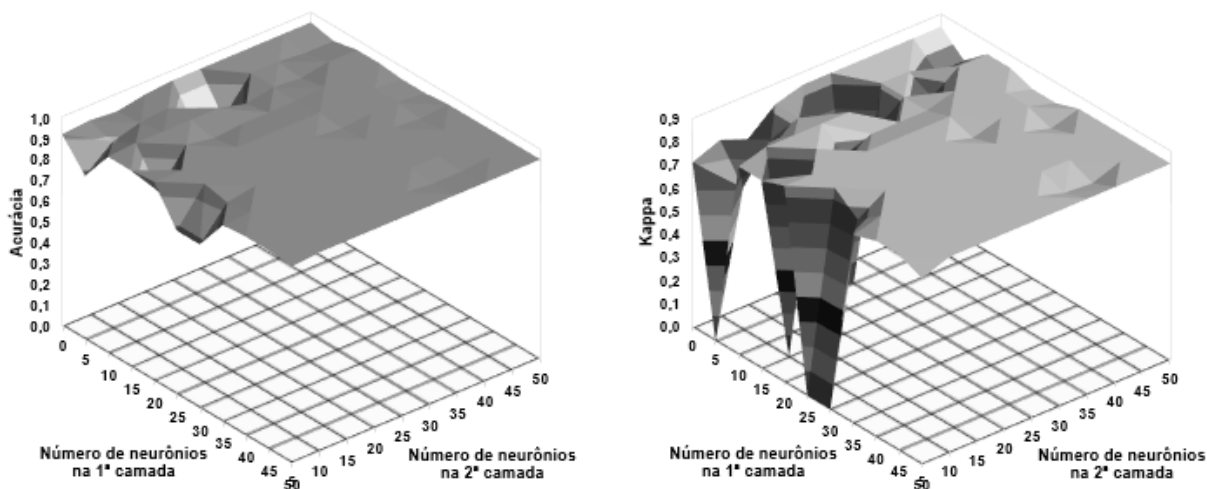


Legenda: o eixo das abscissas representam as épocas do treinamento e o eixo das ordenadas representam as escalas de cada indicador.

Fonte: dos autores (2023).

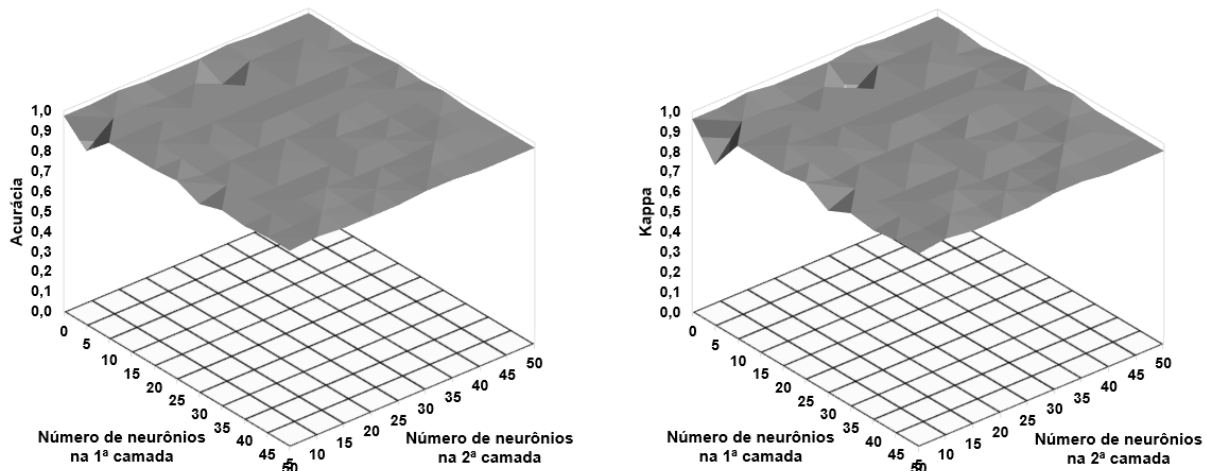
As Figuras 11 e 12 mostram o resultado do estudo realizado durante a etapa de treinamento, na qual foram avaliadas as arquiteturas de RNA. O estudo considerou RNAs de uma e duas camadas ocultas.

Figura 11 - Resultado do treinamento das RNAs de 2 classes referentes a ponteira de metal.



Fonte: dos autores (2023).

Figura 12 - Resultado do treinamento das RNAs de 3 classes referentes a ponteira de metal.



Fonte: dos autores (2023).

Para a rede neural de 2 classes nota-se que em algumas combinações de camadas o coeficiente *Kappa* apresentou valores com concordância mínima, mas para a maioria das combinações a concordância foi perfeita. Foi observado que quanto maior o número de neurônios, maior a capacidade de assimilação da rede neural, mas há melhorias até determinado ponto e a partir dele a concordância permanece constante.

Para a rede neural de 3 classes todas as arquiteturas tiveram concordâncias perfeitas, independente da quantidade de neurônios. A diferença de resultado, em relação a rede com 2

classes, pode ter ocorrido devido ao conjunto de dados desbalanceados que a rede com 2 classes possui. O conjunto de dados das situações “sem defeito” e “com defeito” tem a proporção de 1 para 8, respectivamente, pois foram realizados a mesma quantidade de ensaios para cada entalhe e houveram 8 entalhes. Já a rede de 3 classes, teve um conjunto de dados igualmente distribuídos, e por isso apresentou resultados melhores.

O coeficiente *Kappa* mostrou ser útil pois, utilizando apenas a acurácia, não foi possível observar resultados insatisfatórios. No trabalho de Castro e Braga (2011), realizou-se um estudo sobre o aprendizado supervisionado em conjuntos de dados desbalanceados, e ele sugeriu a matriz de confusão como uma forma de identificar problemas de concordância que a acurácia não detecta.

As arquiteturas RNA que apresentaram os melhores resultados de acordo com os critérios de seleção, estão apresentadas na Tabela 5, e os respectivos resultados de acurácia e *Kappa* para essas arquiteturas selecionadas estão apresentados na Tabela 6. Para a ponteira de metal foi selecionada uma arquitetura com uma camada oculta.

Tabela 5 - Arquiteturas RNA selecionadas após as etapas de treinamento e validação.

Ponteira	Duas classes	Três classes
Metal	5.121-25-2	5.121-15-3
Borracha	5.121-20-40-2	5.121-10-10-3
Plástico	5.121-10-20-2	5.121-5-5-3

Fonte: dos autores (2023).

Tabela 6 - Resultados das RNA selecionadas após as etapas de treinamento e validação.

Ponteira	Duas classes		Três classes	
	Acurácia	<i>Kappa</i>	Acurácia	<i>Kappa</i>
Metal	0,9518	0,8457	0,9879	0,9819
Borracha	0,9638	0,8867	1,0000	1,0000
Plástico	0,9397	0,8028	0,9879	0,9819

Fonte: dos autores (2023).

É notável que a acurácia e o *Kappa* apresentaram valores próximos de 1, indicando um bom desempenho da RNA. De acordo com a Tabela 1, podemos dizer que todas as arquiteturas escolhidas tiveram concordância perfeita e o material da ponteira não exerceu influência significativa nos resultados.

4 CONCLUSÃO

As frequências naturais foram determinadas a partir de Funções de Resposta em Frequência, e as alterações das curvas consequentes dos entalhes, evidenciaram a possibilidade de monitorar o avanço de irregularidades nas estruturas.

Os resultados demonstraram que as RNAs foram capazes de prever com assertividade os comportamentos da viga a partir da entrada dos espectros de frequência. A metodologia desenvolvida, foi capaz de classificar a estrutura, tanto em termos da existência de danos, quanto ao grau de severidade do dano, se baixo, médio ou alto.

Os resultados revelaram que a modelagem desenvolvida da RNA pode ser usada para prever e classificar danos em estruturas.

REFERÊNCIAS

- BAZAN, G. H. **Identificação inteligente de falhas em máquinas elétricas utilizando informação mútua**. 2020. 155 p. Tese (Doutorado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2020.
- BERNARDES, T. **Caracterização do ambiente agrícola do complexo Serra Negra por meio de Sensoriamento Remoto e Sistemas de Informação Geográfica**. 2006. 119 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) – Universidade Federal de Lavras, Lavras, 2006.
- BOCHIE, K. *et al.* **Aprendizado profundo em redes desafiadoras**: Conceitos e aplicações. In Minicursos do XXXVIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, p. 140-189. SBC, dez. 2020.
- BOLLER, C.; CHANG, F.K.; FUJINO, Y. **Encyclopedia of Structural Health Monitoring**. John Wiley & Sons, New York, 2009.
- CASTRO, C. L. de; BRAGA, A. P. **Aprendizado supervisionado com conjuntos de dados desbalanceados**. Revista Controle & Automação, v. 22, n. 5, set-out 2011.
- DELALIBERA, R. G. **Análise numérica e experimental de blocos de concreto armado sobre duas estacas submetidos à ação de força centrada e excêntrica**. 2006. Tese (Doutorado em Engenharia de Estruturas) - Escola de Engenharia de São Carlos, Universidade de São Paulo, 2006.
- DURVAL, M. dos S. *et al.* **Classificação de danos por meio de mapas auto-organizáveis (SOM) associado ao monitoramento da integridade estrutural baseado na impedância eletromecânica**. In: Enciclopédia Biosfera, 2018. Goiânia: Centro Científico Conhecer, v. 15, n. 27, p. 30, 2018.
- ELEOTÉRIO, J. R. **Propriedades físicas e mecânicas de painéis MDF de diferentes densidades e teores de resina**. Piracicaba, 2000. 121 p. Dissertação (Mestrado em Ciências). Escola Superior de Agricultura Luiz de Queiroz, fev. 2000.
- FACELI, K. *et al.* **Inteligência Artificial**: Uma Abordagem de Aprendizado de Máquina. Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora, 2011. 378 p. Bibliografia: p. 343–373.

FLECK, L. *et al.* **Redes Neurais Artificiais: Princípios Básicos**. Revista Eletrônica Científica Inovação e Tecnologia Universidade Tecnológica Federal do Paraná Campus Medianeira, v. 1, n. 13, p. 47-57, jan./jun. 2016.

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. Ponta Grossa: Atena Editora, 2019, 99 p.

GUERRA, J. R. F. **Monitoramento da Saúde Estrutural na Construção Civil Usando Sensor com Superfície Seletiva em Frequência**. 2022. 116 p. Tese (Doutorado) - Universidade Federal do Rio Grande do Norte. Centro de Tecnologia. Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, 2022.

LANDIS, J. R.; KOCH, G. G. **The Measurement of Observer Agreement for Categorical Data**. Biometrics, 1977, vol. 33, n. 1, p. 159-174.

LUDERMIR, T. B.; BRAGA, A. P.; CARVALHO, A. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000.

MARCY, M. C. de A. **Metodologia Baseada Em Redes Neurais Artificiais para a Detecção De Danos Estruturais** [Distrito Federal] 2017. xxi, 203 p., 297 mm (ENC/FT/UnB, Mestre, Estruturas e Construção Civil, 2017). Tese (Doutorado) – Universidade de Brasília. Faculdade de Tecnologia.

MIKHAIL, E.; ACKERMAN, F. **Observations and least squares**. New York: University Press of America, 1976, 497 p.

MONTEIRO, D. K. **Detecção, Localização e Quantificação de Dano em Estruturas via Algoritmos Metaheurísticos e Redes Neurais Artificiais**. 2023. 108 f. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2023.

PALOMINO, L. V. **Artificial intelligence techniques applied to the impedance-based structural health monitoring technique for monitoring damage in aircraft structures**. 2012. 215 f. Tese (Doutorado em Engenharias) - Universidade Federal de Uberlândia, Uberlândia, 2012.

PANCHAL, G. *et al.* **Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers**. International Journal of Computer Theory and Engineering, v. 3, n. 2, Apr. 2011.

PERTILLE, C. T.; *et al.* **Estudo da eficiência de classificações supervisionadas aplicadas em imagem de média resolução espacial.** Universidade Federal do Paraná, BIOFIX Scientific Journal, 2018, v. 3, n. 2, p. 289-296

RAO, S. S. **Mechanical Vibrations in SI Units, Global Edition.** 6th. ed. London: Pearson, 2017.

ROSSI JÚNIOR, M. H. **O que é a engenharia diagnóstica.** Aera, 2022. Disponível em: <<https://aera.org.br/o-que-e-a-engenharia-diagnostica/>>. Acesso em 27 out. 2023.

SANABIO, R. M. R. de B. **Previsão de cargas elétricas utilizando redes neurais artificiais MLP.** 2022. 50 p. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal do Ceará, Centro de Tecnologia, Fortaleza, 2022.

SARTORI, L. R. **Métodos para extração de informação a partir de imagens multiespectrais de escalas grandes.** 2006. 133 p. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2006.

SILVA, A. N. R. da; *et al.* **SIG: uma plataforma para introdução de técnicas emergentes no planejamento urbano, regional e de transportes.** São Carlos, SP. Ed. autores, 2004.

SILVA, R. H. V. da. **Análise dinâmica de uma viga com material piezoelétrico aplicando o método de elementos finitos.** Ouro Preto, 2018. 50 p. TCC (Graduação em Engenharia Mecânica). Universidade Federal de Ouro Preto, Ouro Preto, 2018.

TÁPIA, M.; ROISENBERG, M.; BARRETO, J. M. **Aplicação de Redes Neurais Diretas na Previsão de Preços de Ovos.** In: InfoAgro 2000 - Congresso e Mostra de Agroinformática, Ponta Grossa, out. 2000.

TINÓS, R. **Perceptron Multicamadas.** Universidade de São Paulo: Departamento de Computação e Matemática, 2018, 32 p. [Notas de aula].