



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GIOVANNI DE SOUZA PINHEIRO

**IDENTIFICAÇÃO DE SISTEMAS MULTIFORÇAS A PARTIR DE DADOS DE  
VIBRAÇÃO E TÉCNICAS DE APRENDIZADO DE MÁQUINAS**

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2024

GIOVANNI DE SOUZA PINHEIRO

**IDENTIFICAÇÃO EM SISTEMAS MULTIFORÇAS A PARTIR DE DADOS DE  
VIBRAÇÃO E TÉCNICAS DE APRENDIZADO DE MÁQUINAS**

Tese apresentada ao Programa de Pós-graduação em Engenharia elétrica do Instituto de Tecnologia da Universidade Federal do Pará como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica. Linha de pesquisa: Sistemas Elétricos de Potência.

Orientador: Prof. Dr. Marcus Vinicius Alves Nunes.

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a)  
autor(a)

---

P654i Pinheiro, Giovanni de Souza.  
IDENTIFICAÇÃO DE SISTEMAS MULTIFORÇAS A  
PARTIR DE DADOS DE VIBRAÇÃO E TÉCNICAS DE  
APRENDIZADO DE MÁQUINAS / Giovanni de Souza  
Pinheiro. — 2024.  
128 f. : il. color.

Orientador(a): Prof. Dr. Marcus Vinicius Alves Nunes  
Tese (Doutorado) - Universidade Federal do Pará,  
Instituto de Tecnologia, Programa de Pós-Graduação em  
Engenharia Elétrica, Belém, 2024.

1. Identificação de forças. 2. Método de Elementos  
Finitos. 3. Metodologia de Superfície de Resposta. 4.  
Aprendizado de Máquinas. I. Título.

CDD 621.3

---

GIOVANNI DE SOUZA PINHEIRO

**IDENTIFICAÇÃO DE SISTEMAS MULTIFORÇAS A PARTIR DE DADOS DE  
VIBRAÇÃO E TÉCNICAS DE APRENDIZADO DE MÁQUINAS**

Tese apresentada ao Programa de Pós-graduação em Engenharia elétrica do Instituto de Tecnologia da Universidade Federal do Pará como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica. Linha de pesquisa: Sistemas Elétricos de Potência.

Data de Aprovação: 07 de novembro de 2024.

Banca Examinadora:

---

Prof. Dr. Marcus Vinicius Alves Nunes  
(ORIENTADOR – PPGEE/UFPA)

---

Prof. Dr. Ubiratan Holanda Bezerra  
(MEMBRO INTERNO – PPGEE/UFPA)

---

Prof. Dr. Allan Rodrigo Arrifano Manito  
(MEMBRO INTERNO – ITEC/UFPA)

---

Prof. Dr. Fabio Antonio do Nascimento Setubal  
(MEMBRO EXTERNO – FEM/ITEC/UFPA)

---

Prof. Dr. Diorge de Souza Lima  
(MEMBRO EXTERNO - UNIFESSPA)

---

Prof. Dr. Denis Carlos Lima Costa  
(MEMBRO EXTERNO - IFPA)

À minha família, em especial a minha mãe  
Jacira de Souza (*in memoriam*).

À minha esposa Samara Mufarrej e meus  
filhos Arif Brahim Mufarrej Pinheiro e Ana  
Mufarrej Pinheiro.

## **AGRADECIMENTOS**

Primeiramente a Deus pela dádiva da vida e todo amor e cuidado para comigo e minha família.

À minha família, a maior dádiva que Deus pode dar a qualquer pessoa.

A minha esposa Samara Mufarrej, que me amou e cuidou de nossa família e de nossa casa, enquanto tornava esse sonho realidade.

Ao meu filho Arif Brahim, um jovem que tem um grande coração, que me inspira e me motiva a ser melhor.

A minha filha Ana, que apesar de ainda uma linda bebê, tem um sorriso lindo e distribui amor a todos.

Aos meus pais Cleto e Jacira, que me apoiaram e me educaram pelo amor e exemplo.

Aos meus irmãos, Jacicley, Gorbom, Ester e Eliane, que sempre torceram por mim e me ajudaram quando preciso.

Aos meus sogros Elias Mufarrej e Valdirene Picanço, meus cunhados Sulema e Moisés e concunhados Vanessa e Raphael, pelo apoio e carinho.

Aos meus professores Newton, Gustavo, Alexandre, Fábio e tantos outros que me inspiraram e me ajudaram a chegar a esse momento.

Ao meu orientador Marcus Vinícius, pelo apoio, orientação e amizade que me permitiram chegar à concretização desse trabalho.

Aos meus amigos Sérgio, Everton, Nelson, Luís, Celina, Alessandro, João, Andrey, Jonatan, Denison e Wirland, que me ajudaram e torceram por mim e me apoiaram sempre.

A todos que de alguma forma contribuíram para que esse trabalho se concretizasse.

*“Os rios não bebem sua própria água; as árvores não comem seus próprios frutos. O sol não brilha para si mesmo; e as flores não espalham sua fragrância para si. Viver para os outros é uma regra da natureza. (...)A vida é boa quando você está feliz; mas a vida é muito melhor quando os outros estão felizes por sua causa”.*

*(Papa Francisco)*

## RESUMO

O surgimento de defeitos em componentes dinâmicos, tende a produzir alterações nas forças geradas e podem ser detectadas por meio do espectro de resposta à vibração do equipamento. Compreender as forças que atuam sobre uma estrutura é extremamente importante, especialmente nos casos em que os pontos de medição são limitados ou inacessíveis, pois permite avaliar, entre outros fatores, se a vida útil dos componentes está comprometida pela condição atual da máquina. Nesses casos, um problema inverso precisa ser resolvido. As técnicas de Aprendizado de Máquinas vêm se destacando como uma poderosa ferramenta de predição dentre as soluções desenvolvidas para esse tipo de problema, sendo cada vez mais aplicadas na solução de problemas de engenharia. Portanto, este trabalho tem como objetivo avaliar diferentes modelos de aprendizado de máquina para a identificação de forças atuando em um sistema composto por uma placa suspensa, com base em dados de vibração medidos. Nesse sentido, um modelo computacional foi gerado e calibrado usando respostas de vibração medidas em laboratório. Um banco de dados robusto foi criado utilizando a Metodologia de Superfície de Resposta (*Response Surface Methodology*-SRM) em conjunto com o Delineamento de Experimentos (*Design of Experiment* - DOE) e, em seguida, utilizado para avaliar a capacidade dos modelos de aprendizado de máquina em prever a localização, frequência de excitação, magnitude e número de forças que atuam na estrutura. Entre os seis modelos de aprendizado de máquina avaliados, o modelo k-NN foi capaz de prever os parâmetros das forças com um erro de 0,013%, e o modelo de floresta aleatória, com um erro máximo de 0,2%. Por fim, um banco de dados, contendo uma linha de dados experimentais, foi utilizada para avaliar os modelos k-NN e Floresta Aleatória, obtendo um *score* de 0,96 e 0,93, respectivamente. A inovação do estudo está na aplicação do método proposto para identificação de parâmetros em sistemas multiforças.

**Palavras-chave:** Identificação de forças. Método de Elementos Finitos. Metodologia de Superfície de Resposta. Aprendizado de Máquinas.

## ABSTRACT

The emergence of defects in dynamic components tends to produce changes in the forces generated, which can be detected through alterations in the vibration response spectrum of the equipment. Understanding the forces acting on a structure is extremely important, especially in cases where measurement points are limited or inaccessible, as it allows for assessing, among other things, whether the component's lifespan is compromised by the current condition of the machine. In such cases, an inverse problem needs to be solved. Machine Learning techniques have been standing out as a powerful tool for prediction among the solutions developed for this type of problem, being increasingly applied to engineering problems. Therefore, this work aims to evaluate different machine learning models for the identification of a system, composed of a suspended plate with one or more applied forces, based on measured vibration data. In this regard, a computational model was generated and calibrated using vibration responses measured in the laboratory. A robust database was created using Response Surface Methodology together with the Design of Experiment (DOE) and then used to assess the ability of machine learning models to predict the location, excitation frequency, magnitude, and number of forces acting on the structure. Among the six machine learning models evaluated, k-NN was able to predict with an error of 0.013%, and random forests showed a maximum error of 0.2%. Finally, a database, containing a line of experimental data, was used to evaluate the k-NN and Random Forest models, obtaining a score of 0.96 and 0.93, respectively. The innovation of the study lies in the application of the proposed method for parameter identification in multiforce systems.

**Keywords:** Force identification. Finite element method. Harmonic analysis. Machine Learning.

## LISTA DE FIGURAS

Figura 1 – (a) Análise univariada; (b) matriz com todas as combinações; e (c) CCD. .....	47
Figura 2 – (a) CCD para dois fatores ( $k = 2$ e $\alpha = 2$ ); (b) CCD para três fatores ( $k = 3$ e $\alpha = 3$ ). .....	49
Figura 3 – Geometria do elemento SHELL181 utilizado nos modelos em MEF.....	57
Figura 4 – Fluxograma das etapas fundamentais realizadas para a obtenção do objetivo do trabalho. ....	80
Figura 5 – Sistema básico de medição usado na análise modal experimental usando o excitador de vibrações (Shaker), transdutor de força e acelerômetro. ....	83
Figura 6 - Modelo experimental: chapa suspensa com o acelerômetro no ponto 1 e excitador de vibração no ponto 49. ....	85
Figura 7 - Aparato experimental: amplificador de sinais (B&K 2716), um analisador de sinais (B&K 3160-B-042) e um notebook com software Pulse Labshop. ....	86
Figura 8 - Modo de vibração gerado pelo software TestLab, referente a frequência 81,48 [Hz] e amortecimento modal 1,49%. ....	87
Figura 9 - Geometria computacional com as localizações dos pontos de medição; .	89
Figura 10 - Malha em elementos finitos da chapa, contendo 4.060 elementos e 4.129 nós. ....	90
Figura 11 - Fixação da força no ponto 9 do modelo da análise harmônica numérica. .....	91
Figura 12 - Fixação da força no ponto 33 do modelo da análise harmônica numérica. .....	91
Figura 13 - Fixação da força fixa no ponto 33 e força móvel no ponto 13 do modelo da análise harmônica numérica.....	92
Figura 14 - Pontos de projeto versus parâmetros. ....	93
Figura 15 - Superfície de resposta para aceleração no ponto 20, em função da componente de força no ponto 40 e da frequência. ....	94
Figura 16 - Superfície de resposta para aceleração no ponto 49, em função da componente de força no ponto 33 e da frequência. ....	95
Figura 17 - Reta em 45° com a comparação entre a predição do SRM e os valores gerados pela análise harmônica com aplicação de apenas uma força. ....	97

Figura 18 - Reta em 45° com a comparação entre a predição do SRM e os valores gerados pela análise harmônica para o modelo com duas forças.....	98
Figura 19 - Função Resposta em Frequência pontual da chapa destacando as cinco primeiras frequências naturais. ....	102
Figura 20 - Primeiro modo de flexão, obtido experimentalmente, na frequência natural de 60,24 Hz. ....	103
Figura 21 - Primeiro modo de flexão do modelo na frequência natural de 60,58 Hz. ....	104
Figura 22 - Segundo modo de flexão, obtido experimentalmente, na frequência natural de 81,48 Hz. ....	104
Figura 23 - Segundo modo de flexão do modelo na frequência natural de 81,369 Hz. ....	105
Figura 24 - Gráfico com valores do MAC para os modos gerados pelos modelos experimental e numérico via MEF. ....	106
Figura 25 - Valores do COMAC usados na comparação dos GDL dos modos experimentais e numéricos via MEF. ....	107
Figura 26 - Importância das localizações das medições de vibração (features) e suas respectivas contribuições percentuais, na acuracidade do modelo.....	108
Figura 27 - Dendrograma de Spearman apresentando a correlação entre as 49 variáveis. ....	109

## LISTA DE TABELAS

Tabela 1 - Designação das Funções Resposta em Frequência (FRF's). .....	51
Tabela 2 - Características de métodos de extração modais disponíveis no <i>software Ansys</i> . .....	55
Tabela 3 – Propriedades do aço usadas nos modelos numéricos. ....	88
Tabela 4 – Comparação das frequências naturais obtidas experimentalmente com as frequências obtidas pelo modelo em MEF. ....	105
Tabela 5 – Comparação das métricas de predição entre os Modelos de Aprendizado de Máquinas.....	111
Tabela 6 - Comparação dos erros de predição para os Modelos k-NN e Floresta Randômica nas fases de treino e teste, adotando-se 10 pontos de medição. ....	112

## LISTA DE ABREVIATURAS E SIGLAS

ANOVA	<i>Analysis of Variance</i>
BIC	Bayesian Information Criterion
CARTs	Classification and Regression Trees
CCD	<i>Central Composite Design</i>
CFD	<i>Computational Fluid Dynamics</i>
CHAID	<i>Chi-squared Automatic Interaction Detection</i>
COMAC	<i>Coordinate Modal Assurance Criterion</i>
DNS	<i>Direct Numerical Simulations</i>
DOE	<i>Design of Experiments</i>
DPH-TrLSTM	Data-Physics Hybrid - Time-Reversed Long Short-Term Memory
EGB	<i>Extreme Gradient Boosting</i>
EMA	<i>Experimental Modal Analysis</i>
FRF	<i>Frequency Response Function</i>
GDL	Grau de Liberdade
IFM	Identificação da Força Móvel
k-NN	k Nearest Neighbors
LSF	<i>Moving Least Square Fitting</i>
MAC	<i>Modal Assurance Criterion</i>
MAE	<i>Mean Absolute Error</i>
MEF	<i>Método de Elementos Finitos</i>
MDOF	<i>Multiple Degree of Freedom</i>
MLP	<i>Multi-layer Perceptron</i>
MSE	<i>Mean Squared Error</i>
NN-FCGLS	Non-Negative Flexible Conjugate Gradient Least Squares Method
OOB	<i>Out-of-Bag</i>
PDIPM	<i>Primal-Dual Interior Point Method</i>
PRMCSM	<i>Pattern-Recognition Method Combined with a Similarity Metric</i>
RF	<i>Random Forest</i>
RFR	<i>Random Forest Regresion</i>
RMSE	Root Mean Square Error
RPV	<i>Reactor Pressure Vessel</i>
RVM	<i>Relevance Vector Machine</i>

SFM	<i>Shape Function Method</i>
SHM	<i>Structural Health Monitoring</i>
SISO	<i>Single Input Single Outputs</i>
SRM	<i>Surface Response Methodology</i>
STLF	<i>Short-Term Load Forecast</i>
SVM	<i>Support Vector Machine</i>
XGBoost	<i>Extreme Gradient Boosting</i>

## LISTA DE SÍMBOLOS

$\xi$	Fator de amortecimento viscoso
$(E_i, E_j)$	Similaridade entre pares de exemplos
$\{\Phi_i^r\}$	Vetor modal do modelo de referência do i-ésimo modo
$\{\Phi_j^c\}$	Vetor modal do modelo calculado do j-ésimo modo
$\{\phi_i\}$	Vetor da forma modal do modo i ou autovetor
$\hat{y}_i$	Saída do modelo
$\{h(\mathbf{x}, \Theta_k), k = 1, \dots\}$	Coleção de classificadores estruturados em árvore
$h_1(X), h_2(X), \dots, h_k(X)$	Conjunto de classificadores
$\Theta_G$	Parâmetros treinados
$\Theta_k$	Vetores aleatórios independentes
$E_{X,Y}$	Erro de generalização médio quadrático
$E_t$	Frequência esperada da célula
$G_L$	Pontuações da nova folha esquerda
$G_R$	Nova folha direita
$H_L$	Folhas originais esquerda
$H_R$	Folhas originais direita
$[M]$	Matriz de massa do sistema
$N_k$	Conjunto formado pelos k padrões de treinamento
$O_t$	Frequência observada na célula
$PE^*$	Erro de generalização
$P_{X,Y}$	Probabilidade está acima do espaço $X, Y$
$T_k$	Conjuntos de treinamento <i>bootstrap</i>
$X_i$	Valores observados
$\bar{Y}$	Média das observações
$Y_i$	Valor estimado (previsão) de $X_i$
$f_k$	Função de pontuação
$i_v$	Pontos dos vértices
$[k]$	Matriz de rigidez do sistema;
$v_k$	Vetores aleatórios amostrados de forma independentes
$w_j$	Peso da j-ésima folha
$x_k$	Fatores experimentais

$x_i$	Vetor de variáveis de entrada
$\beta_0, \beta_1, \beta_2, \dots, \beta_k$	Coefficientes polinomiais
$\bar{\rho}$	Valor médio da correlação
$\omega_i$	Frequência natural do modo $i$
$\omega_i^2$	Autovalor
$\omega_n$	Frequência natural em rad/s
$\kappa^2$	Desvios quadrados padronizados
ERM	Erro relativo médio
GL	Graus de Liberdade
$m$	Número de linhas da tabela de contingência;
$n$	Número de colunas da tabela de contingência
$N$	Número de previsões
$R^2$	Coefficiente de determinação
$\Omega$	Termo de regularização na rodada
$\mathbf{x}$	Dados de entrada
$F$	Conjunto de árvores de classificação e regressão
$F(\omega)$	Força de excitação
$Gain$	Função de ganho
$I(\cdot)$	Função do indicador
$J$	Função objetivo
$K$	Número de árvores
$L(\theta)$	Função de perda de treinamento
$R^2$	Coefficiente de determinação
$S$	Robustez do conjunto de classificadores
$T$	Número de folhas da árvore
$X$	Amplitude da resposta em termos de deslocamento
$\vec{Y}, \vec{X}$	Vetor aleatório
$C_{eq}$	Coefficiente de amortecimento equivalente em N.s/m
$c$	Total marginal da coluna
$d$	Distância entre dois pontos no espaço n-dimensional
$i_v$	Pontos dos vértices de uma estrutura CCD
$k$	Número de variáveis independentes estudadas
$K_{eq}$	Rigidez equivalente em N/m

$l$	Total marginal da linha;
$m_{eq}$	Massa equivalente em kg
$mg(X, Y)$	Função de margem
$mr(\mathbf{x}, y)$	Expectativa de $rmg(\theta, \mathbf{x}, y)$ em relação a $\theta$
$n$	Total
$rmg(\theta, \mathbf{x}, y)$	Função de margem bruta
$s$	Robustez do conjunto de classificadores
$sd(\theta)$	Desvio padrão de $rmg(\theta, \mathbf{x}, y)$ mantendo $\theta$ fixo
$t$	Célula da tabela de contingência
$y$	Variável dependente (resposta)
$\gamma$	Termo de dimensão da penalidade
$\varepsilon$	Erro aleatório associado à determinação experimental
$\lambda$	Termo de regularização da complexidade de cada folha
$\rho(\theta, \theta')$	Correlação entre $rmg(\theta, \mathbf{x}, y)$ e $rmg(\theta', \mathbf{x}, y)$
$\omega$	Frequência de excitação em rad/s e
$\epsilon$	Taxa de aprendizagem

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>19</b>
<b>1.1</b>	<b>CONTEXTUALIZAÇÃO</b> .....	<b>19</b>
1.1.1	Identificação de forças .....	19
1.1.2	Delineamento de experimentos com superfície de resposta .....	22
1.1.3	Aprendizado de máquina .....	23
<b>1.2</b>	<b>OBJETIVO GERAL</b> .....	<b>25</b>
1.2.1	Objetivos específicos .....	25
<b>1.3</b>	<b>METODOLOGIA GERAL</b> .....	<b>26</b>
<b>1.4</b>	<b>ORGANIZAÇÃO DO TRABALHO</b> .....	<b>28</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>30</b>
<b>2.1</b>	<b>INTRODUÇÃO</b> .....	<b>30</b>
<b>2.2</b>	<b>ESTADO DA ARTE</b> .....	<b>30</b>
<b>2.3</b>	<b>CONCLUSÕES DO CAPÍTULO</b> .....	<b>45</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>46</b>
<b>3.1</b>	<b>INTRODUÇÃO</b> .....	<b>46</b>
<b>3.2</b>	<b>DELINEAMENTO DE EXPERIMENTOS</b> .....	<b>46</b>
3.2.1	Metodologia de superfície de resposta .....	47
3.2.2	Delineamento composto central .....	49
<b>3.3</b>	<b>CORRELAÇÃO ENTRE MODELOS MODAIS</b> .....	<b>49</b>
<b>3.4</b>	<b>ANÁLISES NUMÉRICAS COM O SOFTWARE ANSYS</b> .....	<b>53</b>
3.4.1	Etapas Básicas no Método dos Elementos Finitos .....	53
3.4.2	Análise modal .....	54
3.4.3	Análise Harmônica.....	55
3.4.4	Elementos finitos utilizados na modelagem no <i>software Ansys</i> .....	56
<b>3.5</b>	<b>APRENDIZADO DE MÁQUINA</b> .....	<b>58</b>
3.5.1	Regressor de floresta aleatória.....	60
3.5.1.1	Caracterizando a precisão de florestas aleatórias.....	61
3.5.1.2	Usando features aleatórias.....	65
3.5.1.3	Usando estimativa <i>Out-of-Bag</i> (OOB) para monitorar erro, força e correlação	66
3.5.1.4	Florestas aleatórias para regressão .....	67

3.5.2	Algoritmo k-NN ( <i>k-Nearest Neighbor</i> ) .....	68
3.5.3	Modelos de Árvore de Decisão .....	71
3.5.4	Redes Neurais MLP ( <i>Multi-layer Perceptron</i> ) .....	77
<b>3.6</b>	<b>PROBLEMAS DE MÚLTIPLAS SAÍDAS .....</b>	<b>78</b>
<b>3.7</b>	<b>CONSIDERAÇÕES SOBRE O CAPÍTULO .....</b>	<b>79</b>
<b>4</b>	<b>METODOLOGIA .....</b>	<b>80</b>
<b>4.1</b>	<b>ANÁLISE EXPERIMENTAL .....</b>	<b>81</b>
4.1.1	Análise modal experimental .....	81
<b>4.2</b>	<b>ANÁLISES NUMÉRICAS COM ELEMENTOS FINITOS .....</b>	<b>87</b>
4.2.1	Análise modal numérica .....	87
4.2.2	Análise harmônica numérica .....	90
<b>4.3</b>	<b>APLICAÇÃO DO MODELO DE SUPERFÍCIE DE RESPOSTA USANDO <i>DESIGN</i></b>	
	<b><i>EXPLORATION</i> .....</b>	<b>92</b>
4.3.1	Modelo de Superfície de resposta .....	93
4.3.2	Geração Numérica do Banco de dados usando (DOE e SRM) .....	95
<b>4.4</b>	<b>APRENDIZADO DE MÁQUINAS .....</b>	<b>99</b>
<b>4.5</b>	<b>AVALIAÇÃO DE DESEMPENHO DOS MODELOS DE APRENDIZADO DE MÁQUINAS .....</b>	<b>100</b>
<b>4.6</b>	<b>CONSIDERAÇÕES SOBRE O CAPÍTULO .....</b>	<b>100</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>102</b>
<b>5.1</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>113</b>
<b>6</b>	<b>CONCLUSÕES .....</b>	<b>115</b>
<b>6.1</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS .....</b>	<b>117</b>
	<b>REFERÊNCIAS .....</b>	<b>118</b>
	<b>APENDICE A - RELAÇÃO ENTRE AS METODOLOGIAS UTILIZADAS NESSE TRABALHO E SUAS</b>	
	<b>RESPECTIVAS ÁREAS DE CONHECIMENTO .....</b>	<b>126</b>
	<b>ANEXO A – LINKS PARA ACESSO DOS ALGORÍTMOS DE APRENDIZADO DE MÁQUINAS .....</b>	<b>128</b>

# 1 INTRODUÇÃO

## 1.1 Contextualização

### 1.1.1 Identificação de forças

O conhecimento de parâmetros como a localização e magnitude das forças dinâmicas que excitam um sistema, apresenta grande importância em praticamente todas as engenharias, desde a engenharia civil, mecânica, aeroespacial e elétrica. O conhecimento desses parâmetros é uma questão importante para uma análise de dinâmica estrutural, pois, por meio do conhecimento das cargas dinâmicas que atuam sobre uma estrutura, pode-se avaliar as tensões mecânicas, às quais os componentes do sistema estão expostos, podendo-se estimar a vida útil em termos da fadiga e a confiabilidade desses componentes. Um exemplo onde se observa a importância do conhecimento das forças que causam falhas em máquinas e equipamentos pode ser visto na área das fontes de energias renováveis, evidenciada pela constante busca por formas mais eficazes de energia limpa.

Segundo Lin et al. (2008), entre as principais opções em estudo, a energia eólica é um forte concorrente, devido à sua confiabilidade, maturidade tecnológica, boa infraestrutura e relativa competitividade de custos. Neste sentido, em seu trabalho, Lin et al. (2008) utilizaram, assim como outros autores, o sistema *Structural Health Monitoring* (SHM) para fornecer e identificar a integridade do sistema, o qual para ser realizada necessita do conhecimento prévio das forças atuantes na estrutura.

De acordo com Maia (2012), a determinação da localização e magnitude das forças dinâmicas que excitam o sistema nem sempre são simples, especialmente quando as forças operacionais não podem ser diretamente medidas, como ocorre em locais inacessíveis; dessa forma, os transdutores não podem ser introduzidos na estrutura, limitando a análise à poucas posições disponíveis.

Em estruturas como turbinas eólicas ou asas de aeronaves, o conhecimento das cargas externas é essencial, uma vez que a medição direta das forças aplicadas nas estruturas é muitas vezes impossível (Setúbal, 2022). Uma solução é a utilização do problema de identificação de força inversa, onde se deseja determinar quantas forças são aplicadas, onde são aplicadas e quais são suas magnitudes e frequências.

Muitos desses problemas são resolvidos através de técnicas de medição indireta (problemas inversos). Esta abordagem consiste em computar os parâmetros de entrada de um sistema (cargas de excitação), através de dados de saída conhecidos (vibração) e o modelo da estrutura. Muitos desses problemas podem ser solucionados por métodos como pseudo-inversão para sistemas super determinados, uso de filtros de Kalman, Decomposição do Valor Singular e regularização de Tikhonov (Choi, Thite e Thompson, 2006).

Rezayat et al. (2016), afirmam que o grande desafio dos problemas inversos é que eles são matematicamente mal colocados em quase todos os casos, o que significa que não existe uma solução única para o problema que dependa continuamente dos dados medidos. Essa falta de estabilidade está relacionada ao fato de que o modelo do sistema é deficiente em classificação e o número de condição é alto. Em outras palavras, uma ampla gama de soluções não realistas, mas matematicamente corretas, pode existir, todas resultando na mesma resposta estrutural.

Segundo Kim e Nelson (2002), muitas vezes a localização das forças são conhecidas e podem ser aproximadas como forças pontuais. Neste caso, métodos indiretos podem ser utilizados, em que uma matriz de funções de resposta de frequência (FRF) medida é invertida e utilizada para reconstruir os espectros de forças operacionais, a partir de um conjunto de respostas operacionais, medidas no domínio da frequência. Problemas com essas técnicas indiretas surgem quando a matriz FRF é mal condicionada. Em tais situações, pequenos erros nas respostas operacionais podem levar a grandes erros nas forças reconstruídas.

De forma geral, dependendo da escolha do domínio de trabalho, os problemas de identificação de carga são tratados de forma diferente e, em muitos estudos, as técnicas no domínio do tempo são utilizadas para solucionar o problema. A identificação de força no domínio do tempo tem sido menos estudada do que seu equivalente no domínio da frequência, portanto, não há muitos estudos de identificação de força na literatura (Huang, 2001).

Na prática da engenharia, a localização e reconstrução de excitações externas é um problema difícil. As abordagens tradicionais de regularização requerem a atribuição de parâmetros de regularização e parâmetros de forma antes de implementar a reconstrução. No entanto, uma seleção pobre desses parâmetros geralmente leva a uma reconstrução pobre. Neste sentido, Feng et al. (2020)

propuseram um método Bayesiano hierárquico no domínio do tempo para localizar e reconstruir as excitações externas, utilizando a seleção automática de parâmetros.

O método de estimação inversa consiste na identificação de forças a partir de respostas dinâmicas de estruturas, no entanto, em sistemas estruturais reais a não-linearidade sempre existe. Para sistemas mecânicos ou estruturais reais, a não-linearidade tende a variar de acordo com o problema a ser avaliado, além de, se apresentar mais forte com o aumento da amplitude de resposta, tornando as soluções tradicionais muito complexas e de difícil solução.

A literatura mostra que os trabalhos realizados com o objetivo de identificação de força pelo método inverso, apresentam grande dificuldade na representatividade temporal das medições, para que se possa conhecer as (saídas) em vários pontos de medição ao mesmo tempo em que o sistema é excitado (Setúbal, 2022).

Tendo isso em vista, a metodologia proposta nesta tese, visa apresentar uma alternativa para a solução desses problemas com uma abordagem mais simples, no entanto, com excelentes resultados. Para tanto, se propõe a criação de um banco de dados robusto, o qual é utilizado para treinar de modelos de Aprendizado de Máquinas. Para a geração do banco de dados é utilizado um modelo computacionalmente validado pela análise modal experimental do modelo real.

Dessa forma, um banco de dados representativo do sistema real, pôde ser gerado evitando-se o tempo exaustivo em medições de respostas experimentais. Uma análise harmônica do modelo computacional foi realizada em conjunto com a utilização do Delineamento de Experimento, baseado no Delineamento Composto central, com a parametrização da frequência de excitação e magnitude das forças e consequente geração da superfície de resposta, o que permite expandir o conjunto de respostas do sistema. Esses procedimentos foram realizados por meio de ferramentas disponíveis no *Software ANSYS*.

Seis modelos de Aprendizado de Máquinas foram, então, treinados e testados, obtendo-se erros menores que 1% em dois desses modelos (k-NN e Floresta Aleatória). Também foi realizada a análise da capacidade de previsão dos modelos com a redução do número de pontos de medição, mantendo a métrica de eficiência de predição do modelo acima de 99% nos dois modelos, demonstrando a eficácia e potencial dos métodos apresentados.

### 1.1.2 Delineamento de experimentos com superfície de resposta

Segundo Xu (2024), a metodologia SRM é um método de otimização que combina a superfície de resposta de um conjunto de dados de amostra experimental, fornece a equação de superfície e, em seguida, resolve a equação de superfície para obter um conjunto de variáveis de projeto ideais.

Ao contrário de outros métodos estatísticos, o SRM, além de, considerar a interação entre variáveis independentes e melhorar a precisão do ajuste, também utiliza tecnologia gráfica para exibir a relação funcional entre as duas, tornando os resultados mais intuitivos (Liu et al, 2022).

Polidoro (2016), destaca o esgotamento de reservas de petróleo e os problemas ambientais fomentados pela combustão de combustíveis fósseis e seu conseqüente e crescente interesse na utilização de biomassas na obtenção de combustíveis e produtos químicos. Em seu estudo, ele otimizou a temperatura final e a vazão de gás inerte para a pirólise de *Silverskin* em reator de leito fixo, utilizando um delineamento composto central, aliado à superfície de resposta.

Costarrosa et al. (2018) otimizaram a transesterificação de resíduos de óleo de cozinha com hidrotalcita Mg-Al usando Metodologia de Superfície de Resposta. Uma vez que eles relataram que o biodiesel se tornou uma alternativa muito promissora ao combustível diesel fóssil, no que diz respeito às preocupações ambientais e ao esgotamento dos recursos combustíveis e que, geralmente, o biodiesel é produzido por meio de transesterificação homogênea ou heterogênea de diferentes matérias-primas gordurosas. Em seu trabalho, hidrotalcita de Mg-Al calcinada (HT) foi utilizada para a transesterificação heterogênea de óleo de cozinha residual. Três parâmetros de reação, a saber, tempo de reação, quantidade de catalisador e razão molar metanol-óleo, foram otimizados por meio da Metodologia de Superfície de Resposta (SRM) a temperatura constante (65°C), usando um *Design Box-Behnken*.

Buonanno et al. (2024) investigaram os benefícios potenciais de uma abordagem de aprendizado de máquina em combinação com previsões de energia fotovoltaica geradas por meio de modelos meteorológicos. Vários métodos de aprendizado de máquina foram testados para a abordagem combinada (modelo linear, *Long Short-Term Memory*, *eXtreme Gradient Boosting* e *Light Gradient Boosting Machine*). Entre eles, os modelos lineares demonstraram ser os mais eficazes, com pelo menos uma melhoria RMSE de 3,7% na previsão da produção fotovoltaica, no

que diz respeito a dois métodos de linha de base, baseados na previsão numérica do tempo. Os autores demonstraram como os modelos de aprendizado de máquina podem ser usados para refinar a previsão de um modelo de previsão de geração fotovoltaica já estabelecido e destacaram a eficácia dos modelos lineares, mesmo em um regime de poucos dados, como no caso de usinas recentemente estabelecidas.

### 1.1.3 Aprendizado de máquina

O aprendizado de máquinas tem revolucionado diversos campos da engenharia, onde a capacidade de aprender a partir de dados e fazer previsões ou decisões, sem ser explicitamente programado para realizar a tarefa, é uma característica poderosa. Na engenharia civil, por exemplo, o aprendizado de máquinas pode ser usado para prever a vida útil de estruturas, além da otimização de projetos de construção, levando em consideração vários fatores, como custo, tempo e qualidade.

Na engenharia mecânica, o aprendizado de máquinas pode ser aplicado na manutenção preditiva de máquinas, o que permite previsão de falhas antes que aconteçam, economizando tempo e dinheiro.

Na engenharia elétrica, o aprendizado de máquinas, também é usado para otimização do consumo de energia em sistemas de energia elétrica e detecção de falhas em sistemas de energia elétrica.

Apesar de todas essas aplicações, ainda há muitos desafios no uso do aprendizado de máquinas na engenharia. Um desses desafios é a necessidade de grandes quantidades de dados para treinar os modelos de aprendizado de máquinas, que nem sempre estão disponíveis. Outro desafio é a interpretabilidade dos modelos de aprendizado de máquinas.

Segundo Barbaresi et al. (2022), um avanço importante na redução do tempo computacional vem da aplicação de modelos de aprendizado de máquina para contornar simulações de energia. Com o objetivo de limitar o número de simulações, eles investigaram o desempenho de regressão de diferentes modelos de aprendizado de máquina, tais como, *Support Vector Machine* (SVM), *Random Forest* (RF) e *Extreme Gradient Boosting* (EGB), treinados em um pequeno conjunto de dados de simulações de energia realizadas em um edifício de estudo de caso.

As aplicações de engenharia encontram regimes de fluxo complexos envolvendo fluxos turbulentos e de transição (de laminar para turbulento), que abrangem uma ampla faixa de comprimento e escalas de tempo que aumentam com o número de Reynolds ( $Re$ ). Segundo Bhushan et al. (2021), simulações numéricas diretas (*Direct Numerical Simulations* – DNS) exigem resoluções de grade pequenas o suficiente para resolver toda a faixa de escalas turbulentas e estão além da capacidade computacional atual. A disponibilidade de DNS de alta fidelidade e conjuntos de dados experimentais, está alimentando o surgimento de ferramentas de aprendizado de máquina para melhorar a precisão, a convergência e a aceleração das previsões de fluxo turbulento. Em muitos casos, as ferramentas de aprendizado de máquina dependem de redes neurais para identificar a correlação entre recursos de entrada e saída e têm sido usadas de diferentes maneiras para previsões de fluxo turbulento, como estimativa de campo direto, estimativa de incerteza de modelagem de turbulência ou modelagem avançada de turbulência. Para isso, é necessário que o modelo aprenda a partir de conjunto de dados de treinamento.

O aprendizado de máquina é uma ferramenta poderosa para encontrar padrões em dados de alta dimensão; emprega algoritmos pelos quais um computador pode aprender a partir de dados empíricos, modelando as relações lineares ou não lineares entre as propriedades dos materiais e fatores relacionados (Murphy, 2013).

Segundo Yue et al. (2017), a previsão dos atributos mecânicos dos materiais é essencial para melhorar a eficácia dos materiais em diversas aplicações. À medida que as indústrias recorrem cada vez mais a técnicas de produção avançadas, a capacidade de prever propriedades importantes através de aprendizado de máquina torna-se fundamental. O aprendizado de máquina emergiu como uma ferramenta poderosa para prever e compreender o comportamento material.

O aprendizado de máquina é popular na solução de problemas de previsão de sistemas complexos, como previsão de consumo de combustível. Segundo Yang et al. (2022), ao fazer o modelo aprender o conjunto de treinamento, é possível que o modelo mostre um melhor efeito de previsão no conjunto de teste. Nesse sentido, tem havido muitos estudos sobre previsão de consumo de combustível com modelos de aprendizado de máquina, que tendem a se concentrar em um único aspecto de fatores que afetam a previsão de consumo de combustível, envolvendo fatores do veículo, fatores de comportamento de condução, fatores de condições da estrada, fatores climáticos, e assim por diante. No entanto, o consumo de combustível é afetado por

muitos fatores e dificilmente pode fazer uma previsão precisa apenas focando em uma única dimensão. Nesse caso, devido à limitação de aquisição de dados, faltam pesquisas de previsão de consumo de combustível com base em dados de fatores multidimensionais. Em todos esses exemplos percebe-se a importância do monitoramento e obtenção de histórico através da criação de banco de dados, que possam ser usados para treinar e testar o modelo de aprendizado de máquinas.

Em linhas de transmissão, a pesquisa sobre a contaminação natural do isolador é um requisito básico do isolamento externo. O grau de contaminação dos isoladores é resultado do ambiente operacional real, que pode refletir as características de resistência à poluição dos isoladores em condições naturais. Segundo Ren, Li e Xiao (2017), devido ao ambiente de trabalho complexo dos isoladores, as características naturais de contaminação do isolador são difíceis de descrever com expressões matemáticas, neste sentido, algoritmos de aprendizado de máquina são amplamente utilizados no estudo das características naturais de contaminação de isoladores. Eles afirmaram que as medições de densidade de depósito de sal equivalente e densidade de depósito não solúvel, são um requisito básico dos sistemas de energia e para prever a severidade da poluição do local de isoladores, eles utilizaram uma metodologia baseada em algoritmo de florestas aleatórias.

Uma classe de métodos de aprendizado de máquinas amplamente utilizada na prática é a aprendizagem supervisionada; onde pares das variáveis de entrada e a variável de saída são usadas para aprender a função de mapeamento de entrada-saída. O objetivo é aproximar a função de mapeamento, otimizando alguma função objetivo, de modo que quando novos dados estão disponíveis na entrada (sem previsões de saída associadas), pode-se prever a variável de saída para esses dados (Rushdi et al., 2020).

## **1.2 Objetivo geral**

Identificar parâmetros de forças em sistemas multiforças por meio da utilização de modelos de Aprendizado de Máquinas.

### **1.2.1 Objetivos específicos**

- Realizar análise modal experimental em uma chapa metálica;

- Construir um modelo computacional da chapa metálica, em Elementos Finitos;
- Realizar a Calibração do modelo computacional com base nos resultados experimentais;
- Validar o modelo computacional pela utilização dos critérios MAC e COMAC;
- Realizar análise harmônica numérica no modelo validado com a aplicação de múltiplas forças;
- Aplicar o Delineamento de experimentos (DOE) em conjunto com a metodologia de superfície de resposta (SRM) para expansão dos resultados obtidos;
- Construir um banco de dados a partir dos resultados obtidos;
- Utilizar algoritmos de Aprendizado de Máquinas no banco de dados gerado;
- Identificar os modelos que melhores se ajustam ao conjunto de dados.
- Utilizar um banco de dados contendo dados experimentais para avaliar a capacidade dos modelos que se destacarem, em lidar com dados experimentais.

### 1.3 Metodologia Geral

Esse trabalho tem por finalidade a identificação de forças (magnitude, frequência e posição) através dos dados de vibração de uma chapa na condição de apoio livre – livre. Tendo isso em vista, uma análise modal experimental foi realizada em uma chapa de aço com o intuito de validar um modelo computacional, o qual foi utilizado para gerar o banco de dados inicial. A malha de medição contou com 49 pontos dispostos em sete linhas e sete colunas, no ponto 49 foi fixado o excitador de vibração, com uma célula de carga. A resposta de vibração foi medida nos 49 pontos da malha.

O modelo computacional foi gerado usando o Método de Elementos Finitos (MEF) com uso do *software Ansys®*, sendo calibrado pelos dados obtidos na Análise Modal Experimental. O processo de calibração do modelo computacional foi realizado através dos critérios *Modal Assurance Criterion (MAC)* e *Coordinate Modal Assurance Criterion (COMAC)*, conforme procedimento descrito em (DZIEDZIECH *et al.*, 2022;

HENKEL; WEIJTJENS; DEVRIENDT, 2021; RANDALL J. ALLEMANG, 2003; WOO; VACCA, 2022).

Para a realização das análises harmônicas numéricas, o método de Delineamento de Experimento (*Design of Experiments – DOE*), junto com o delineamento composto central (*Central Composite Design – CCD*), foram utilizados para a parametrização da força em termos da amplitude e frequência de excitação.

A utilização do Método de Superfície de Resposta (*Surface Response Methodology- SRM*) permitiu a obtenção da superfície de resposta do modelo, o qual possibilitou a expansão do banco de dados para uma gama de respostas possíveis (acelerações médias), em detrimento das variações da magnitude, da frequência de excitação e das posições das forças harmônicas configuradas.

O banco de dados foi, então, utilizado para treinar e avaliar a capacidade de diferentes modelos de aprendizado de máquinas em realizar a identificação dos parâmetros das forças atuando sobre a estrutura. Para a avaliação da capacidade dos diferentes modelos de aprendizado de máquinas foram utilizados o Erro Relativo Médio, o Coeficiente de correlação ( $R^2$ ) e o tempo de processamento. Além disso, foi avaliado também a importância de cada ponto de medição na capacidade de previsão de cada modelo de aprendizado de máquina. O procedimento apresentado nesse trabalho, traz uma alternativa aos procedimentos experimentais exaustivos em campo, que dependendo do número de medições e das condições do sistema, seria impraticável, e se utiliza de modelos em elementos finitos calibrados, aplicados em conjunto com o DOE e SRM para a criação de um banco de dados robusto, o qual pode ser utilizado para treinar e avaliar diferentes modelos de aprendizado de máquinas na identificação dos parâmetros de sistemas multiforças.

Uma vez que os trabalhos estudados na literatura necessitam de grande esforço experimental e matemático para reproduzir e localizar forças pelo método inverso, a metodologia proposta nessa tese, visa reduzir o tempo e complexidade no processo de identificação de sistemas multiforças atuantes em uma estrutura. Tendo isso em vista, destaca-se que a metodologia desenvolvida neste trabalho, apresenta grande potencial na identificação de defeitos e monitoramento de equipamentos eletromagnéticos, a exemplo de transformadores e reatores, a partir do monitoramento da resposta vibratória da carcaça desses equipamentos, bem como a determinação da vida útil dos componentes desses equipamentos. A presente tese inova na identificação de sistemas multiforças.

## 1.4 Organização do trabalho

Esta tese está estruturada em 6 *capítulos* divididos da seguinte forma:

- **Capítulo 1 – INTRODUÇÃO:** apresenta motivação para o desenvolvimento desta tese, descrevendo sobre técnicas utilizadas para a determinação e reconstrução de forças, descrevendo as dificuldades e limitações dessas técnicas. Além disso, descreve o objetivo geral e objetivos específicos desta tese, seguindo com uma breve apresentação da metodologia utilizada e finaliza com a disposição dos capítulos do trabalho.
- **Capítulo 2 – REVISÃO BIBLIOGRÁFICA:** apresenta o estudo da arte sobre a determinação de forças dinâmicas, uma vez que várias técnicas foram utilizadas durante os anos, por se saber que essas forças são geralmente responsáveis pelas principais causas de falhas encontradas em estruturas de diferentes tipos, além de ser um parâmetro essencial em desenvolvimento de projetos. Também é realizado um estudo sobre o delineamento de experimento utilizando a metodologia de superfície de resposta (SRM) em conjunto com o delineamento composto central (CCD), aplicada na otimização e correlação de parâmetros e como forma do desenvolvimento de um banco de dados e finaliza com o estudo sobre aprendizado de máquinas, ressaltando os principais trabalhos que subsidiaram diretamente a realização desta tese.
- **Capítulo 3 – FUNDAMENTAÇÃO TEÓRICA:** apresenta a fundamentação teórica do DOE, SRM, CCD, correlação entre modelos modais, e modelos de aprendizado de máquinas.
- **Capítulo 4 – METODOLOGIA:** apresenta a metodologia proposta neste trabalho através de um fluxograma, iniciando com a aplicação da análise modal experimental até a criação de seis modelos de predição de forças com uso de aprendizado de máquinas.
- **Capítulo 5 – RESULTADOS E DISCUSSÕES:** apresenta os resultados e discussões obtidos em cada etapa da metodologia aplicada nesta tese para a obtenção dos modelos de predição em RFR, k-NN, Arvore Aleatória, árvore

CHAID, Arvore XGBoost e Redes Neurais, destacando a eficiência de cada modelo, os testes de reduções de pontos de medição e os erros obtidos.

- **Capítulo 6 – CONCLUSÕES:** apresenta as conclusões da tese e sugestões para trabalhos futuros.

O trabalho é finalizado com a apresentação da lista com as referências utilizadas nesta tese. Finalmente, espera-se que este trabalho se constitua numa contribuição para o desenvolvimento de novas técnicas de identificação de forças utilizando técnicas de aprendizado de máquinas e que poderá ser aplicado em vários sistemas submetidos à vibrações mecânicas, sejam eles dispositivos elétricos, navais, ferroviários ou mecânicos.

## **2 REVISÃO BIBLIOGRÁFICA**

### **2.1 Introdução**

Esta tese tem como objetivo realizar a identificação de forças a partir de um banco de dados, gerado por um modelo computacional validado, utilizando a resposta de vibração do modelo real. Uma análise harmônica do modelo numérico computacional é realizada e os resultados expandidos pelo uso de DOE e SRM. Seis modelos de aprendizado de máquinas foram utilizados para a predição dos parâmetros de força (magnitude, frequência de excitação e localização). Com base no exposto, neste capítulo é apresentada uma revisão bibliográfica sobre o assunto, sendo este tema amplamente discutido por diversos pesquisadores, envolvendo diferentes análises com diferentes metodologias.

### **2.2 Estado da arte**

Com a análise da literatura acadêmica, tornou-se evidente que uma grande quantidade de pesquisadores tem direcionado suas energias para a elaboração de modelos numéricos e analíticos sofisticados. Esses modelos são projetados com o intuito de identificar e simular as forças que atuam em uma ampla gama de sistemas, visando otimizar as condições de projeto e minimizar as falhas e defeitos quando esses sistemas estão em operação.

Nesse contexto, é de suma importância obter informações precisas sobre as forças dinâmicas externas que influenciam esses sistemas vibratórios em uma variedade de sistemas dinâmicos. Isso é especialmente relevante para fins de projeto ou diagnóstico. Por exemplo, a identificação de impactos em estruturas civis pode ajudar a prevenir danos catastróficos, enquanto a análise das lâminas de turbinas eólicas pode levar a melhorias na eficiência energética.

Além disso, a transmissão de forças em núcleos de transformadores e em reatores elétricos de alta potência é um campo de estudo crucial para a manutenção da estabilidade da rede elétrica e para a prevenção de falhas no sistema. Portanto, a pesquisa nessa área não só contribui para a melhoria dos sistemas existentes, mas também abre caminho para o desenvolvimento de tecnologias inovadoras no futuro.

Tendo isso em vista, Lu e Law (2006) introduziram uma abordagem baseada na sensibilidade temporal para a identificação de forças em seu estudo. Segundo eles, existem basicamente três tipos de problemas inversos. O primeiro tipo é quando as localizações das forças são conhecidas e apenas os históricos de forças são identificados. O segundo tipo é quando, tanto o histórico da força, quanto sua localização, são desconhecidos. O terceiro tipo envolve a identificação de forças móveis em estruturas. Os autores sugeriram um método para identificar o histórico temporal da força de excitação de entrada usando a resposta dinâmica da estrutura. As sensibilidades da resposta dinâmica em relação aos parâmetros da força de entrada foram calculadas no domínio do tempo. Essas sensibilidades foram empregadas para atualizar os parâmetros das forças identificadas de maneira iterativa na análise inversa. Em suas simulações, eles utilizaram forças de excitação senoidais e impulsivas. As forças de entrada foram aproximadas por uma série de Fourier. As matrizes de sensibilidade do deslocamento dinâmico, velocidade e aceleração em relação aos parâmetros de força foram calculadas no domínio do tempo e usadas em um método baseado em sensibilidade para atualizar os parâmetros de força. Eles concluíram que a metodologia proposta não era sensível a ruídos de medição e erros de modelagem do sistema. Eles destacaram uma vantagem do método por exigir, no mínimo, uma medição para atualizar teoricamente os parâmetros de força.

Maia, Lage e Neves (2012) propuseram uma nova forma de categorizar os métodos de identificação de força, baseando-se em medidas de resposta. Essa classificação divide os métodos em três grupos: métodos determinísticos, métodos estocásticos e métodos que utilizam aprendizado de máquinas. Eles também discutem progressos recentes na identificação de forças na dinâmica estrutural, empregando o princípio de transmissibilidade em sistemas com múltiplos graus de liberdade (Multiple Degree of Freedom – MDOF).

Liu et al. (2014) propuseram uma técnica computacional inovadora para a identificação de forças, utilizando o método de ajuste de mínimos quadrados móveis. Eles foram capazes de identificar a força dinâmica através desta metodologia. O histórico de força foi discretizado e a carga local foi estimada pelo método de função de forma (SFM) sob o ajuste de mínimos quadrados móveis (LSF). A força foi caracterizada com base no domínio local em movimento e a matriz de resposta foi construída pela combinação das respostas das cargas da função de forma em todos os domínios locais, estabelecendo assim o modelo direto. A carga dinâmica real foi

caracterizada através de uma função de aproximação contínua de alta ordem, sob o ajuste de mínimos quadrados no domínio do tempo local. A carga dinâmica real foi aproximada movendo este domínio local e as respostas das mesmas cargas da função de forma, em cada domínio de tempo local, foram obtidas através do cálculo de elementos finitos. Assim, a matriz de resposta completa das funções de forma foi formada pela combinação das respostas das cargas da função de forma em todas as unidades de tempo adjacentes. Portanto, o modelo direto de identificação de carga dinâmica foi estabelecido através da operação matricial entre a força, que eles denominaram carga, e a matriz discretizada.

Qiao et al. (2015) introduziram uma técnica de identificação de força que se baseia na transformada discreta de cosseno. Em seu estudo, eles explicam que a identificação de força é um problema inverso tradicional, onde se utilizam dados medidos e modelos matemáticos de estruturas mecânicas para descobrir a força aplicada. No entanto, eles observam que a força identificada pode se desviar significativamente da solução real devido ao ruído desconhecido, que contamina os dados medidos e a inversão mal posicionada da matriz de transferência, que caracteriza a estrutura mecânica. Para superar esses desafios, os autores propuseram um método que utiliza a transformada discreta de cosseno no domínio do tempo para a identificação de forças, que supera a deficiência do mau posicionamento da matriz de transferência. Eles expandiram a força desconhecida usando um conjunto de funções de base de cosseno e reformularam a equação governante original para encontrar o coeficiente de cada função de base de cosseno. A simulação numérica mostrou que, em comparação com o critério da curva L, o critério modificado de validação cruzada generalizada foi bastante robusto na presença de ruído. Os resultados experimentais indicaram que, em comparação com os métodos baseados em decomposição de valor singular truncado e em polinômios de Chebyshev, o método baseado na transformada discreta de cosseno combinado com o critério de validação cruzada generalizada modificado pode reconstruir o histórico de tempo de força e identificar o pico de força de impacto com alta precisão.

Rezayat et al. (2016) sugeriram uma abordagem para a identificação de forças dinâmicas que se baseia na esparsidade de grupo no domínio da frequência. Eles explicam que, para um modelo estrutural específico, as técnicas inversas permitem reconstruir as forças de entrada do sistema a partir de dados de vibração. No entanto, o problema inverso é extremamente sensível ao ruído de medição, e o método

pseudo-inverso tradicional muitas vezes não consegue encontrar as cargas corretas. Em seu estudo, foi proposto uma função de penalidade que une as vantagens das propriedades da norma  $\ell_p$  com uma técnica de otimização iterativa modificada. O algoritmo proposto foi empregado para localizar e reconstruir forças pontuais dinâmicas em uma estrutura de viga, sem conhecimento prévio sobre a localização das forças, e foi validado através de várias simulações e experimentos. Eles concluem que seu trabalho contribuiu com uma nova técnica para identificação de força pontual no domínio da frequência, adaptando métodos iterativos penalizados, e que a melhor solução foi escolhida minimizando o Critério de Informação Bayesiano (BIC). Diversos cenários de carregamento com diferentes configurações de sensores foram investigados. As simulações e os experimentos demonstraram que a localização e o histórico de tempo de forças discretas em estruturas reais foram estimados corretamente usando o método proposto. No entanto, eles afirmaram que, apesar das vantagens do método em termos de localização e precisão, ele tem como desvantagem o alto tempo de processamento computacional.

Quiao et al. (2017) levaram em conta a característica esparsa da força de impacto e construíram um modelo abrangente de deconvolução esparsa da força de impacto. Em seu estudo, eles propuseram uma alternativa para a reconstrução da força de impacto, baseada no método de ponto interior primal-dual (*primal-dual interior point Methodology*– PDIPM), para resolver um modelo de deconvolução esparsa em grande escala, substituindo a minimização da norma  $\ell_2$  pela minimização da norma  $\ell_1$ . Como resultado, eles usaram o algoritmo de gradiente conjugado pré-condicionado para calcular a direção de busca do PDIPM e conduziram dois experimentos, incluindo a reconstrução de uma força de impacto simples em pequena ou média escala e a reconstrução de uma força de impacto consecutiva em uma escala relativamente grande, em uma pá de turbina eólica composta e uma estrutura de concha, para demonstrar a eficácia do método. De acordo com os autores, em comparação com a regularização de Tikhonov, o PDIPM provou ser mais eficiente, preciso e robusto, tanto na reconstrução de uma única força de impacto quanto na reconstrução de forças de impacto consecutivas.

Wambacq et al. (2019) sugeriram um algoritmo para rastrear e identificar forças dinâmicas em estruturas, utilizando o método de pontos interiores e a esparsidade de grupo. A estimativa da força foi conduzida no domínio da frequência, baseando-se em um número restrito de sensores e um modelo de sistema dinâmico

linear, através da minimização de uma função objetivo que foi penalizada com um termo de esparsidade de grupo. A minimização da função objetivo foi formulada como um programa de cone de segunda ordem, que foi resolvido utilizando o método de pontos interiores. De acordo com os autores, isso permitiu uma diminuição do tempo de cálculo, quando comparado a outros algoritmos atualmente disponíveis para impor esparsidade de grupo nas forças, especialmente para problemas de grande escala. O algoritmo foi inicialmente verificado utilizando simulações numéricas. Posteriormente, os autores realizaram uma validação utilizando dados coletados em um teste de campo em uma passarela, onde dois locais específicos e arbitrários na ponte foram excitados através de impactos de martelo e a localização da força foi realizada assumindo um total de 108 possíveis localizações de força. Eles concluíram que a validação utilizando medições in situ em uma ponte demonstra que o algoritmo pode ser utilizado para localizar forças em estruturas complexas com muitas possíveis localizações de força na presença de erros de modelagem, carga ambiente e ruído de medição.

Qiao et al. (2019), levaram em conta a dispersão da força de impacto para desenvolver um método aprimorado de regularização esparsa baseado na minimização da norma  $l_1$  ponderada é proposto para diminuir o erro da força de pico e aprimorar a precisão da identificação da força de impacto. Inicialmente, um modelo de otimização convexa ponderada de norma  $l_1$  foi introduzido para lidar com a natureza mal condicionada do problema inverso de identificação da força de impacto. O mal condicionamento que surge na resolução de problemas inversos está geralmente relacionado à natureza dos próprios problemas inversos e às características das equações que os descrevem, como por exemplo: a sensibilidade a pequenas perturbações, dados incompletos ou ruidosos, informações insuficientes, natureza matemática das equações, ou mesmo, problemas mal postos, o que está ligado ao fato de que: não há garantia de que uma solução exista para todos os dados de entrada, mesmo que uma solução exista, pode não ser única e que pequenas variações nos dados de entrada podem resultar em grandes variações na solução (sensibilidade). Em seguida, para resolver eficientemente este modelo regularizado, foi proposto um algoritmo de minimização de norma  $l_1$  ponderado iterativamente, onde os pesos foram atualizados de forma adaptativa a partir da solução prévia. A implementação do esquema ponderado iterativamente visa superar a incompatibilidade entre a minimização da norma  $l_1$  e a minimização da norma  $l_0$ ,

mantendo o problema de regularização esparsa aprimorada solucionável e convexo. Por fim, a simulação numérica e a verificação experimental, incluindo a identificação da força de impacto simples e dupla em uma estrutura de placa, foram apresentadas para demonstrar a superioridade do método de regularização esparsa aprimorado em relação aos métodos clássicos de regularização. Os efeitos da reponderação do número de iterações, parâmetros de ajuste, condições iniciais e locais de resposta foram investigados em detalhes com sucesso. Os resultados mostraram que, em comparação com o método de regularização de norma  $l_1$  padrão e o método de regularização de norma  $l_2$  clássico, o método de regularização esparsa aprimorado baseado na minimização de norma  $l_1$  ponderada, cuja solução é muito mais esparsa, pode melhorar significativamente a precisão de identificação da força de impacto. Além disso, o método proposto é muito mais robusto na escolha de parâmetros de ajuste e medições ruidosas.

De acordo com Feng et al. (2020), na engenharia prática, a localização e a reconstrução de excitações externas constituem um desafio devido à grande dimensão do problema e à ausência de informações prévias sobre a precisão e os parâmetros de forma das forças. A escolha de parâmetros de regularização adiciona uma complexidade extra ao problema. Nesse contexto, os autores desenvolveram um método hierárquico Bayesiano no domínio do tempo para localizar e reconstruir as excitações externas com a seleção automática de parâmetros. O método foi implementado em duas fases. Primeiramente, com base na propriedade da função de distribuição de probabilidade posterior dos parâmetros de forma, um novo critério sem força foi proposto para determinar rapidamente as localizações sem força. Posteriormente, com base nas localizações de forças determinadas, um problema de dimensão reduzida foi construído e as distribuições posteriores dos parâmetros foram amostradas por um algoritmo Metropolis-within-Gibbs com técnica de bloqueio aninhado. Simulações numéricas e experimentos de laboratório em uma viga engastada sob várias condições de carga foram realizados para validar o método proposto. Segundo os autores, em comparação com as técnicas de regularização tradicionais, os resultados do método proposto por eles demonstraram um melhor desempenho tanto na localização quanto na reconstrução do histórico de forças.

Goutaudier et al. (2020) propuseram em seu estudo o uso de um único sensor para localizar impactos e reconstruir forças, utilizando modos de vibração discriminativos. Eles destacam que, ao contrário das técnicas de triangulação que

necessitam de pelo menos três sensores em uma estrutura do tipo placa, em seu trabalho foi usado apenas um sensor para localizar o ponto de impacto. A estratégia proposta envolveu a extração de ponderações modais específicas como uma assinatura do local de impacto, ou seja, o problema de localização foi tratado identificando as contribuições de modos de vibração específicos na resposta como uma assinatura da localização do impacto. De acordo com os autores, a robustez da estimativa das ponderações modais foi melhorada ao posicionar o sensor em um ponto neutro de um conjunto de modos de vibração selecionados e o problema de reconstrução de força foi abordado simultaneamente ajustando uma lei paramétrica. O procedimento proposto conseguiu capturar os principais parâmetros do histórico de carga, como o tempo de impacto, sua duração e sua intensidade.

Feng, Li e Lu (2020) sugeriram uma abordagem baseada em um algoritmo recursivo, que eles chamaram de filtro de Kalman esparsos, para localizar e reconstruir forças no domínio do tempo. A distribuição espacial das forças em cada instante foi estimada pelo *Relevance Vector Machine* (RVM). Eles exploraram a capacidade do filtro de Kalman esparsos de induzir esparsidade para monitorar forças em muitos locais potenciais com um número limitado de sensores, a uma velocidade significativamente maior do que os métodos convencionais. Em cada simulação, foram consideradas diferentes frequências de amostragem, atrasos de suavização, níveis de ruído de medição e locais de força para entender completamente o desempenho do filtro de Kalman esparsos e sua versão de suavização. No entanto, de acordo com os autores, a versão do filtro de Kalman esparsos que eles propuseram não conseguiu processar dados em tempo real e precisa de mais desenvolvimento no futuro.

Qiu et al. (2020) propuseram uma abordagem para localizar e reconstruir a força de impacto desconhecida na estrutura de uma placa experimental, utilizando análise de séries temporais e reconhecimento de padrões. Eles justificam a abordagem adotada, argumentando que a força de impacto é a carga que as estruturas reais geralmente enfrentam e que sua localização e reconstrução do histórico de tempo são cruciais para o monitoramento da saúde e segurança estrutural. No entanto, afirmam que as técnicas clássicas de inversão para identificação aleatória da força de impacto são demoradas e impraticáveis, e por isso, não podem ser utilizadas para aplicações de engenharia. O estudo adotou diversas análises de séries temporais e um método de reconhecimento de padrões para

identificar forças de impacto aleatórias desconhecidas, através de uma estratégia conhecida como método de reconhecimento de padrões combinado com uma métrica de similaridade (*pattern-recognition method combined with a similarity metric – PRMCSM*). Simulações numéricas do método proposto foram realizadas. No entanto, suas descobertas não foram verificadas experimentalmente. Do ponto de vista experimental, o estudo considerou uma placa de aço suspensa como objeto de pesquisa, força de impacto como entrada de carga e aceleração como saída de resposta. No modelo experimental do estudo, a aceleração foi escolhida como a resposta estrutural, enquanto a tensão foi escolhida como a resposta estrutural na simulação de elementos finitos. No entanto, os resultados experimentais foram consistentes com os resultados da simulação, apesar das diferentes condições de contorno. Com base no ponto de referência do alvo identificado, o histórico de tempo da força de impacto foi reconstruído, mas a precisão da reconstrução do histórico de tempo foi afetada pela densidade da discretização.

Segundo Setúbal (2022), modelos de predição envolvendo técnicas de aprendizado de máquinas vêm sendo utilizados na solução de problemas inversos, entretanto, estes modelos necessitam de um banco de dados consistente e adequado para a realização de treino e de teste dos modelos.

Breiman (2001) explica em seu estudo que as florestas aleatórias são essencialmente uma combinação de preditores de árvores, onde cada árvore é dependente dos valores de um vetor aleatório que é amostrado de forma independente e com a mesma distribuição para todas as árvores na floresta. Ele esclarece que o erro de generalização para florestas tende a convergir para um limite à medida que o número de árvores na floresta aumenta. Ele explora profundamente a teoria das florestas aleatórias aplicadas a modelos de classificação e regressão.

Johansson et al. (2014) desenvolveram em seu estudo uma previsão de regressão com florestas aleatórias que segue a conformidade. Eles explicam que a previsão de regressão conforme produz intervalos de previsão válidos, isto é, a probabilidade de excluir o valor alvo correto é limitada por um nível de confiança predefinido. Eles afirmam que a eficiência é o critério mais importante na comparação de regressores conformes. Em seu estudo, a utilização de florestas aleatórias como modelo subjacente para previsão de regressão conforme, foi investigada e comparada com técnicas existentes de ponta, que são baseadas em redes neurais e k-vizinhos mais próximos. Os autores notaram que, além do desempenho preditivo robusto, as

florestas aleatórias permitem determinar o tamanho dos intervalos de previsão usando estimativas fora da bolsa (*out-of-bag* - *OOB*), em vez de exigir um conjunto de calibração separado. Eles concluíram em seu trabalho que o uso de florestas aleatórias foi proposto como um forte candidato à previsão de regressão conforme, pois permitiu que a calibração necessária fosse realizada nos exemplos fora da bolsa, possibilitando assim utilizar todos os dados disponíveis como um conjunto de treinamento adequado. Os resultados mostraram que a abordagem sugerida, em quase todos os níveis de confiança e usando funções de não conformidade padrão e normalizada, produziu preditores conformes significativamente mais eficientes do que as alternativas existentes naquele momento. Em particular, a configuração geral mais eficiente foi a sugerida em seu trabalho, ou seja, um preditor de conformidade de floresta aleatória calibrado usando uma função de não conformidade normalizada com base em erros fora da bolsa de instâncias vizinhas. A evidência empírica, portanto, sugeriu fortemente que as florestas aleatórias em conjunto com a calibração fora da bolsa são um regressor conforme altamente competitivo.

Huang et al. (2016) propuseram um método de seleção de características baseado na importância da permutação para a previsão de carga elétrica de curto prazo utilizando florestas aleatórias. Eles explicam que a precisão da previsão de carga de curto prazo (*Short-Term Load Forecast* – *STLF*) é influenciada pela escolha do modelo de previsão e pelo resultado da seleção das características. Em seu estudo, eles sugeriram um método de seleção de características baseado em florestas aleatórias para *STLF*. Inicialmente, 243 características relacionadas foram extraídas dos dados históricos de carga e das informações temporais dos pontos de previsão para formar o conjunto original de características. Posteriormente, o conjunto original de características foi utilizado para treinar um modelo de floresta aleatória como o modelo original. Após o processo de treinamento, o erro de previsão do modelo original no conjunto de teste foi registrado e o valor de importância de permutação de cada característica foi obtido. Os resultados experimentais, baseados em dados reais de carga, validaram a eficácia do método de seleção de características baseado em florestas aleatórias proposto para *STLF*.

Ren, Li e Xiao (2017) conduziram um estudo sobre a influência e a previsão de medidas de densidade de depósito de sal equivalente e densidade de depósito não solúvel, utilizando florestas aleatórias. Eles propuseram um método baseado em florestas aleatórias para prever a gravidade da poluição no local dos isoladores. Foram

construídos e comparados modelos de regressão de florestas aleatórias e SVM, com o objetivo de preencher a lacuna de informação na previsão de estudos anteriores.

Lu et al. (2018) empregaram um algoritmo aprimorado de floresta aleatória para prever a carga de carregamento de veículos elétricos. Diante do aumento da demanda de carregamento de veículos elétricos, os autores sugeriram em seu estudo um método de previsão de carga de carregamento de veículos elétricos baseado no algoritmo de floresta aleatória e nos dados de carga de uma estação de carregamento específica. O método consistiu no algoritmo de árvore de classificação e regressão para realizar a previsão de curto prazo para a estação. Simultaneamente, foi proposto o algoritmo de previsão da capacidade de carregamento diário de estações de carregamento com diferentes escalas e localizações. Ao combinar os algoritmos de regressão e classificação, o aprendizado eficaz de uma grande quantidade de dados históricos de cobrança foi concluído. Após analisarem uma grande quantidade de dados de carregamento, os autores observaram que a carga de carregamento do veículo elétrico também possui características de distribuição temporal e espacial. No entanto, a característica de dados com maior grau de discriminação foi selecionada com base nos dados existentes para fornecer a base para a aplicação da floresta aleatória na previsão de cobrança.

Yang et al. (2022) criaram um modelo que utiliza aprendizado de máquina para prever o consumo de combustível de veículos movidos a gasolina, levando em consideração a energia e o impacto ambiental, com o uso de big data multidimensional. Em seu estudo, eles realizaram uma análise comparativa construindo cinco modelos de regressão para prever a taxa de consumo de combustível do mundo real de veículos leves a gasolina na China, com base em big data das perspectivas de fatores do veículo, fatores ambientais e fatores de comportamento de condução. Após o treinamento e o teste, os resultados mostraram que os valores de erro absoluto médio, erro percentual absoluto médio, erro quadrático médio,  $R^2$  e valores de validação cruzada de 10 vezes entre os valores de previsão e a taxa real de consumo de combustível foram significativamente melhores do que o valor de referência. Nesse contexto, o modelo de regressão de floresta aleatória apresentou o melhor desempenho entre os cinco modelos candidatos, com um erro absoluto médio de 0,630 l/100 km, um erro percentual absoluto médio de 7,5%, um erro quadrático médio de 0,805, um  $R^2$  0,776, e uma pontuação de validação cruzada de 10 vezes de 0,791.

Barbaresi et al. (2022) empregaram modelos de aprendizado de máquina para estimar a demanda energética na construção civil. Eles destacam que a previsão precisa da demanda energética de um edifício é crucial na fase de projeto da construção, apesar do alto custo computacional para a busca de soluções otimizadas de economia de energia. Eles relatam que uma redução significativa no tempo computacional pode ser alcançada pela aplicação de modelos de aprendizado de máquina para contornar as simulações de energia. Com o objetivo de reduzir drasticamente o número de simulações, eles sugerem em seu estudo a investigação do desempenho de regressão de diferentes modelos de aprendizado de máquina, como SVM, RF e EGB, treinados em um pequeno conjunto de dados de simulações de energia realizadas em um edifício de estudo de caso. Os autores concluíram que o tempo computacional para cada previsão foi instantâneo e substancialmente menor do que os necessários para uma simulação de energia em software. A validação dos modelos mostrou uma alta acurácia e precisão alcançadas por todos os três modelos, com o aumento de EGB fornecendo os melhores resultados em termos do erro médio absoluto (Mean Absolute Error – MAE), erro médio quadrático (Mean Squared Error – MSE) e tempo computacional. Eles finalizaram explicando que a forte não linearidade do problema fornece limitações para a adoção de modelos lineares, que podem ser aceitáveis apenas para uma previsão preliminar.

Zhang et al. (2024) propuseram uma metodologia hierárquica, capaz de determinar a localização e o histórico temporal de uma força de impacto por meio de dados obtidos de um único acelerômetro. A metodologia proposta implica uma recuperação eficiente de constantes modais não corrigidas com uma função de razão referida como transmissibilidade generalizada. A transmissibilidade generalizada simboliza a proporção de respostas de acelerômetros idênticos submetidos a dois cenários de impacto distintos, um excitado em um local ainda a ser identificado e outro em um local de referência pré-determinado. A divulgação teórica da correlação entre a transmissibilidade generalizada nas frequências polares e as constantes modais não corrigidas recuperadas são demonstradas. As constantes modais servem então como uma assinatura para identificar o local do impacto. Após a localização, o problema de reconstrução da força é resolvido ajustando-se um modelo paramétrico, em que uma função de base gaussiana é empregada para aproximar o histórico temporal da força de impacto. Demonstrações experimentais em uma placa metálica e uma asa composta foram realizadas para validar a localização eficiente e precisa, bem como

as capacidades de reconstrução rápida em resposta a uma força de impacto aplicada em qualquer lugar de uma estrutura 2D.

Chen et al. (2024) propuseram em seu trabalho, uma forma de reduzir o efeito do problema de má colocação na precisão e eficiência da IFM (Identificação da Força Móvel) através de métodos numéricos e experimentais. Um método de mínimos quadrados de gradiente conjugado flexível não negativo (NN-FCGLS) foi desenvolvido através do enriquecimento do método de mínimos quadrados de gradiente conjugado com a técnica flexível do subespaço de Krylov e condições de restrição não negativas. Em seguida, a solução do método NN-FCGLS foi continuamente atualizada com a técnica do subespaço de Krylov e as condições de Karush-Kuhn-Tucker a cada iteração para obter uma solução estável para identificação de força dinâmica mal colocada. Por fim, foram realizados experimentos de laboratório com uma viga de liga de alumínio simplesmente apoiada. Os resultados da simulação numérica mostraram que o método NN-FCGLS é insensível à velocidade e à distância entre eixos do veículo e tem melhor precisão, robustez mais forte e maior eficiência computacional do que o método no domínio do tempo e o método dos mínimos quadrados do gradiente conjugado. Os erros percentuais relativos de todos os dez casos não excedem 7,8% sob a interferência de um nível de ruído de 20%. Os resultados experimentais mostraram que os coeficientes de correlação entre as respostas medidas e as respostas reconstruídas são maiores que 0,92 em todos os casos. Estudos experimentais demonstram a precisão e eficiência do método NN-FCGLS proposto na prática da IFM.

Apesar da existência de modelos computacionais, que minimizam a necessidade de experimentos físicos, ainda podem ocorrer desafios na coleta de um conjunto de dados amplo e confiável. Isso pode ser devido a várias razões, como a complexidade dos sistemas em estudo, a falta de padrões de dados ou a dificuldade em obter dados de alta qualidade. Portanto, é importante considerar esses fatores ao desenvolver e aplicar modelos computacionais.

Dang et al. (2022) sugeriram uma técnica de previsão de demanda energética de curto prazo utilizando o algoritmo de regressão de floresta aleatória para lidar com a questão de que o modelo de previsão pontual não consegue quantificar a incerteza da demanda energética. Eles desenvolveram três modelos de previsão pontual de demanda energética de curto prazo baseados em redes neurais profundas multimodais para extrair características espaço-temporais multimodais que contêm

mais informações ocultas. Com esses três modelos de previsão pontual de demanda energética de curto prazo, os resultados da previsão pontual de transição puderam ser obtidos. Eles relataram em seu estudo que apenas as informações do histórico de demanda, histórico dos preços de demanda, mês, semana, feriado e hora foram utilizados para prever a probabilidade de demanda energética de curto prazo. No entanto, na prática, os fatores que influenciam a demanda energética são difíceis de obter e a previsão precisa da demanda energética de curto prazo pode não ser alcançada apenas com base nas características mencionadas. Portanto, eles sugerem que pesquisas futuras precisam considerar a influência de outros fatores na demanda energética, como temperatura, umidade, economia regional e meio ambiente, a fim de melhorar a precisão da previsão de demanda de curto prazo.

No contexto do estudo das correlações entre as variáveis de entrada e saída em processos, técnicas de DOE (*Design of Experiments*), incluindo experimentos fatoriais, experimentos que utilizam SRM (*Surface Response Methodology*), métodos de Taguchi, entre outros, são frequentemente empregados como uma estratégia eficaz para a otimização de processos e a construção de bases de dados. Estas técnicas permitem uma análise sistemática e eficiente das relações entre as variáveis do processo. A SRM, por exemplo, é comumente aplicada para identificar as condições ideais de um produto durante o seu processo de fabricação, estabelecendo assim as melhores correlações entre as variáveis de entrada e saída no processo. Além disso, essas técnicas também podem auxiliar na identificação de interações complexas entre as variáveis, o que pode ser extremamente útil para a otimização de processos complexos e a melhoria da qualidade do produto.

Box e Wilson (1951) já tinham introduzido uma abordagem para a otimização de um processo específico a partir de condições experimentais. O avanço do seu trabalho foi principalmente uma resposta aos desafios de determinar as condições ideais em pesquisas químicas, e eles acreditavam que os métodos seriam úteis em outras áreas onde a experimentação é sequencial e o erro é relativamente pequeno. Eles observaram que as circunstâncias que afetam a estratégia do pesquisador são a magnitude do erro experimental, a complexidade da superfície de resposta e se os experimentos podem ser conduzidos sequencialmente de modo que cada conjunto possa ser projetado usando o conhecimento adquirido nos conjuntos anteriores. Nesse contexto, uma maneira confiável de encontrar condições ideais seria explorar toda a região experimental. Como o erro experimental é pequeno, mudanças sutis

podem ser determinadas com precisão e o pesquisador pode explorar adequadamente uma pequena sub-região de toda a região R com apenas alguns experimentos. Além disso, como os experimentos são sequenciais, há a oportunidade de usar os resultados obtidos em uma sub-região para passar para uma segunda onde a resposta seja maior. Através da aplicação repetida de tal procedimento, um ponto máximo ou pelo menos quase estacionário de alta resposta deve ser alcançado. Ao limitar a região em que os experimentos são conduzidos, pode-se encontrar apenas um máximo local e perder um máximo global mais alto, no entanto, onde uma exploração mais completa é impraticável, essa possibilidade deve ser aceita e o risco implícito não é considerado problemático.

Anguebes-Franseschi et al. (2018) aprimoraram o processo de esterificação da oleína bruta de palma africana utilizando a metodologia de superfície de resposta e catálise ácida heterogênea. Eles examinaram o impacto da zeólita montmorillonita-KSF na esterificação dos ácidos graxos livres presentes na oleína bruta de palma africana. Para aprimorar a esterificação dos ácidos graxos livres da oleína bruta de palma africana, eles empregaram a metodologia de superfície de resposta, baseada em um design central composto rotacional. Três parâmetros foram analisados: (a) carga do catalisador (2,6–9,4% em peso), (b) temperatura da reação (133,2–166,2 °C) e © tempo de reação (0,32–3,68 h).

Por outro lado, Almasi et al. (2019) exploraram a viabilidade de produzir biodiesel a partir de um genótipo de canola (TERI (OE) R-983). Eles utilizaram uma abordagem ultrassônica para intensificar a reação. A metodologia de superfície de resposta foi empregada para determinar as condições ideais do processo.

Du e Chen (2023) propuseram um novo método híbrido de aprendizado de máquina (denominado SEC) para prever picos de carga de vento em um grupo de edifícios. O método SEC integra regressão semi-supervisionada, máquina de aprendizado extremo e dinâmica de fluidos computacional (CFD). As cargas de vento em um grupo de edifícios são sensíveis a muitos fatores de influência e não há amostras de teste em túnel de vento suficientes para previsão de aprendizado de máquina. SEC usa regressão semi-supervisionada para construir amostras pseudo rotuladas de edifícios não testados e as misturas com amostras existentes para expandir amostras de treinamento para melhorar a precisão da previsão. Testes em túnel de vento demonstram que os picos de carga do vento às vezes têm uma forte relação com o espaçamento do edifício ou alteram-se rapidamente com a variação

dos espaçamentos dos edifícios. O CFD pode calcular as cargas médias de vento com muito mais precisão do que as cargas de pico de vento, a custos baixos. A SEC adiciona cargas médias de vento de edifícios não testados simulados por CFD como a variável de entrada no modelo de previsão para enfraquecer a relação não linear entre as variáveis de entrada e as cargas de vento de pico e melhorar ainda mais a precisão da previsão. Os resultados do estudo de caso de um grupo de três edifícios de telhado plano mostram que o desempenho de previsão do modelo SEC usando 2.891 amostras de teste de túnel de vento existentes atinge o do modelo de máquina de aprendizagem extrema usando 5.782 amostras de teste de túnel de vento existentes quando o alvo previsto está na faixa local onde os picos de carga do vento se alteram rapidamente com o aumento do espaçamento do edifício. O desempenho de previsão do modelo SEC é melhorado com o aumento do número de amostras pseudo rotuladas.

Zhou et al. (2024) propuseram um método híbrido de aprendizado profundo e física de dados para identificação de força de impacto, chamado DPH-TrLSTM. Este método emprega a rede de memória de longo prazo invertida no tempo (TrLSTM) para estabelecer a relação causal da resposta à força. A função de perda híbrida de física de dados (DPH) foi utilizada para atenuar o efeito negativo dos erros de identificação do sistema. O DPH-TrLSTM necessita apenas da matriz de transferência e de uma quantidade mínima de dados experimentais coletados na fase de identificação do sistema, eliminando a necessidade de experimentos adicionais. Resultados experimentais de 40 forças de impacto em oito locais em uma placa composta mostraram que o DPH-TrLSTM poderia alcançar erros médios de pico e relativos abaixo de 1,0% e 2,5%, respectivamente, superando significativamente os três métodos de regularização. Os autores sugeriram que o método proposto pode realizar a identificação de força de impacto de alta precisão, mesmo na presença de erros de identificação do sistema. O impacto dos erros de identificação do sistema no desempenho do método pode ser avaliado usando a curva min-max, determinando assim seu escopo aplicável. O estudo também revelou que os erros de identificação do sistema foram a principal causa do desempenho insatisfatório dos três métodos de regularização. A escolha dos pontos de medição pode influenciar o desempenho do DPH-TrLSTM, principalmente devido a erros de identificação do sistema, e não ao número de condição da matriz de transferência.

## 2.3 Conclusões do capítulo

Nesta tese foi apresentado um método para identificação das forças atuantes em uma estrutura em termos da resposta de vibração medida, determinando sua amplitude, frequência e localização, aplicando SRM com base em CCD em conjunto com algoritmos de Aprendizado de máquinas.

Neste sentido, a revisão da literatura deixa clara a importância do tema para a acurácia na previsão de forças pelo método inverso, redução do tempo computacional e pela redução da exatidão em se obter experimentalmente um banco de dados. Diversos autores abordam metodologias de reconstrução e localização de forças em diversas estruturas pelo método inverso, ou seja, a partir de dados de vibração. O presente trabalho inova ao realizar a identificação de sistemas multiferças, o que é feito a partir da utilização da teoria de superfície de resposta, aplicada computacionalmente em um modelo de elementos finitos para a obtenção de banco de dados e utilizá-los para treinar, validar e avaliar a capacidade de diferentes modelos de aprendizado de máquinas na identificação desses sistemas.

## 3 FUNDAMENTAÇÃO TEÓRICA

### 3.1 Introdução

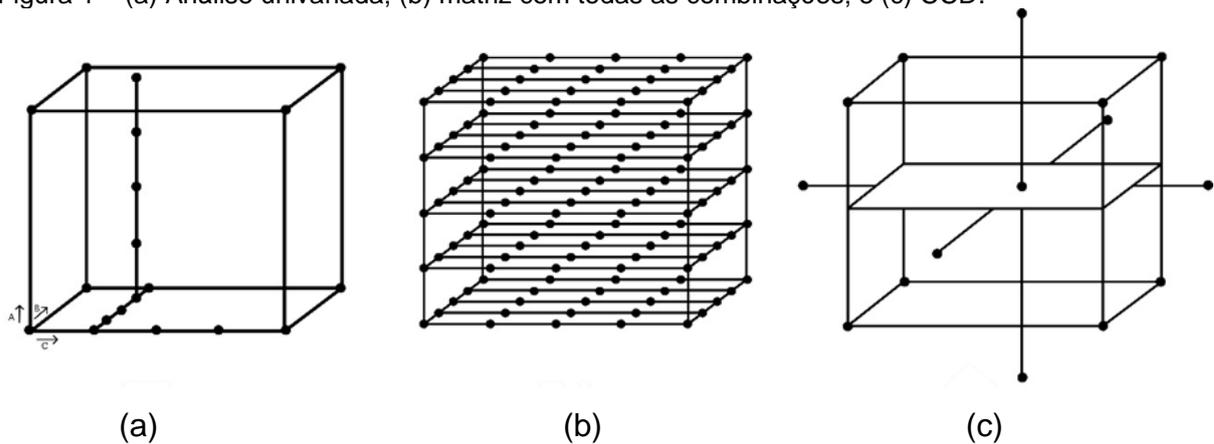
Neste capítulo será abordada a fundamentação teórica referente aos materiais e métodos utilizados neste trabalho. Inicialmente será abordado o conteúdo relacionado ao delineamento de experimentos e à metodologia de superfície de resposta com base no CCD. Um estudo sobre a metodologia de análise modal experimental utilizada para a validação do modelo computacional em elementos finitos é apresentado na sequência. As correlações entre os modelos experimental e numérico são apresentadas com base no MAC e o COMAC, seguindo da apresentação das análises numéricas usadas com o Método de Elementos Finitos. Ao final é exposta a teoria pertinente aos modelos de aprendizado de máquinas utilizados.

### 3.2 Delineamento de experimentos

O delineamento de experimento (*design of experiments* – DOE) foi desenvolvido com o intuito de criar uma metodologia experimental para analisar as respostas devido entradas específicas e verificar como esses parâmetros se correlacionam. Este método constitui-se de uma metodologia utilizada para o planejamento de experimentos. Neste sentido, os experimentos são realizados de forma planejada, onde os fatores (variáveis independentes) são modificados de modo a avaliar seu impacto sobre a resposta (variável dependente) (BOX; WILSON, 1951; NAJAFI ET AL., 2018).

Haaland et al. (2020) aborda três metodologias utilizadas na condução de um procedimento experimental: análise univariada, matriz de combinações experimentais e a metodologia de delineamento composto central (*Central Composite Design* – CCD). Na Figura 1 é apresentado a configuração esquemática de cada metodologia na condução de um experimento com 3 variáveis independentes. Sendo a análise univariada o procedimento experimental mais difundido (Figura 1a).

Figura 1 – (a) Análise univariada; (b) matriz com todas as combinações; e (c) CCD.



Fonte: Setúbal (2022).

Segundo Setúbal (2022), na análise univariada (Figura 1a), enquanto uma das variáveis é analisada, as demais permanecem fixas. Embora esse método seja muito utilizado, é incompleto, por não tratar dos efeitos causados pelas interações entre as variáveis, além disso, restringe os resultados à uma região limitada do espaço experimental. A metodologia usando matriz de combinação de todos os fatores (Figura 1b), no entanto, explora o espaço experimental de forma abrangente, porém com a desvantagem de necessitar de um número maior de medições, demandando um tempo muito maior para a realização dos experimentos. Outro ponto importante é que, por não possuir ensaios repetidos, não possibilita estimar o erro inerente às manipulações e medidas experimentais. A condução do procedimento experimental mediante um CCD (Figura 1c) permite explorar o espaço experimental de modo abrangente, utilizando um número reduzido de medidas, quando comparado com o método da matriz contendo todas as combinações possíveis no experimento. Esse delineamento permite estimar o erro mediante repetição de ao menos 3 vezes o ensaio na condição experimental central. Outra vantagem desse delineamento é a possibilidade de elaborar um modelo matemático empírico que, quando validado estatisticamente, pode ser traduzido por uma superfície de resposta (BOX; WILSON, 1951; POLIDORO, 2016; HAALAND, 2020).

### 3.2.1 Metodologia de superfície de resposta

A Metodologia de Superfície de Resposta (*Surface Response Methodology* – SRM) é uma técnica de otimização que se baseia em planejamentos fatoriais, os quais determinam as relações entre variáveis de entrada e de saída de um experimento

(BOX; WILSON, 1951; COSTARROSA ET AL., 2018; JO ET AL., 2022). O SRM representa uma coleção de técnicas estatísticas usadas para estudar as relações entre respostas e variáveis de entrada independentes. Usam-se superfícies de respostas, quando as variáveis de respostas são influenciadas por muitas variáveis de entrada e o objetivo do uso do SRM é de otimizar essas respostas.

O SRM baseia-se na construção de modelos matemáticos empíricos, geralmente empregando funções polinomiais lineares ou quadráticas para descrever o sistema estudado (ABDULLAH ET AL., 2021; BOX; WILSON, 1951; JO ET AL., 2022; KANEKO ET AL., 2020), oferecendo condições de explorar o sistema até a sua otimização.

De maneira geral, a SRM tem por objetivo relacionar e identificar essa relação existente entre fatores controláveis (variáveis independentes) e as respostas (variáveis dependentes) do sistema analisado. A superfície de resposta é representada por um gráfico que descreve o comportamento da resposta em função de fatores tomados dois a dois, permitindo analisar os fatores que afetam o sistema (BEEBE K.R.; PELL R.J.; SEASHOLTZ M.B., 1998; BOX; WILSON, 1951; ZHAO ET AL., 2022). A função matemática que descreve a superfície de resposta é dada pela Equação 1 em que  $x_1, x_2, \dots, x_k$  representam os fatores experimentais,  $y$  é a variável dependente (resposta),  $k$  é o número de variáveis independentes estudadas e  $\varepsilon$  é o erro aleatório associado à determinação experimental:

$$y = f(x_1, x_2, \dots, x_k) + \varepsilon \quad (1)$$

Para a determinação da superfície de resposta é necessário determinar a relação matemática entre a variável dependente e as variáveis independentes (BOX; WILSON, 1951). O primeiro modelo a ser verificado no ajuste da resposta deve ser o linear, representado pelo polinômio de primeira ordem a seguir, na Equação 2, no qual  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  representam os coeficientes deste:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2)$$

Segundo Polidoro (2016) quando a Análise de Variância (*Analysis of Variance* – ANOVA) apontar que o modelo linear não se ajusta bem às respostas experimentais, devido a presença de uma curvatura na superfície de resposta, a função a ser

aproximada no conjunto de resultados é um polinômio de maior ordem, como um modelo quadrático, representado pelo polinômio a Equação 3:

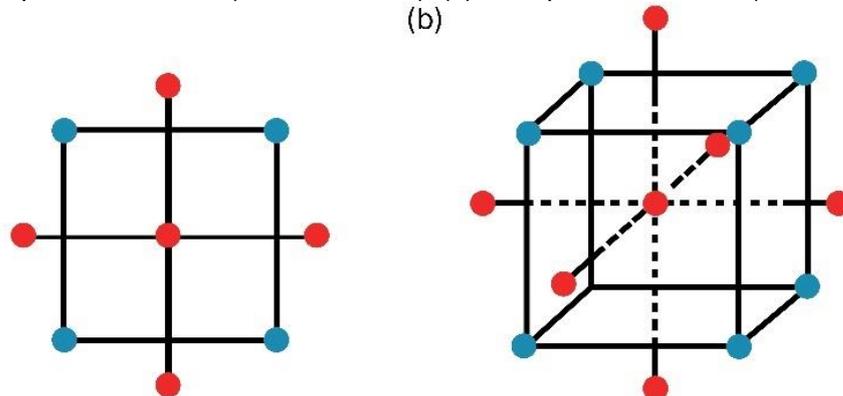
$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_i \sum_j \beta_{ij} x_i x_j + \varepsilon \quad (3)$$

Neste sentido, pode-se dizer que a análise de variância é sempre utilizada quando se deseja verificar a influência de cada fator e o nível usado no experimento, na variável de resposta.

### 3.2.2 Delineamento composto central

O CCD, consiste no delineamento experimental mais apropriado para ajustar o modelo polinomial completo de segunda ordem a dados experimentais. O CCD introduzido por Box e Wilson em 1951 são construções formadas por três partes: parte fatorial, no qual as variáveis independentes são estudadas em 2 níveis ( $2^k$ ), baixo ( $x_{v_i} = -1$ ) e alto ( $x_{v_i} = +1$ ), para todos  $i_v = 1, \dots, k$  pontos dos vértices; pontos axiais (ou estrela), com todas as coordenadas nulas, exceto uma, que corresponde a um valor  $\alpha$  (onde,  $\alpha = \sqrt[4]{2^k}$ ), ou  $-\alpha$ ; e no ponto central ( $x_{v_1} = \dots = x_{v_k} = 0$ ), que deverá ser replicado ao menos 3 vezes para fins de estimativa de erro. Assim, o delineamento possuirá uma forma circular, quando  $k = 2$  (Figura 2a) e esférica, quando  $k = 3$  (Figura 2b) (BOX E WILSON, 1951).

Figura 2 – (a) CCD para dois fatores ( $k = 2$  e  $\alpha = \sqrt{2}$ ); (b) CCD para três fatores ( $k = 3$  e  $\alpha = \sqrt{3}$ ).



Fonte: Setúbal (2022).

### 3.3 Correlação entre modelos modais

O método de análise modal experimental, visa a identificação dos parâmetros modais de um sistema real, a partir das respostas vibratórias que ela apresenta quando sujeita a excitações externas. Os modos de vibração de uma estrutura são formas pelas quais o sistema tende a vibrar quando excitados em determinadas frequências, sendo caracterizados normalmente por uma forma de vibração, uma frequência natural de vibração e um fator (ou coeficiente) de amortecimento associados. Quando se estimula uma estrutura, seja de forma livre ou forçada, a sua resposta é uma combinação dos modos de vibração. Há, portanto, uma mistura das formas de vibração, com a presença de várias frequências naturais simultaneamente. Dessa forma, a análise modal experimental permite a identificação dos parâmetros de vibração presentes numa certa faixa de frequência, a partir de suas respostas vibratórias. Estes parâmetros são a forma modal de vibração, frequência natural (frequência ressonante) e coeficiente de amortecimento modal associadas.

Há duas categorias básicas de métodos experimentais de extração de parâmetros modais: no domínio do tempo e no domínio da frequência. Os métodos no domínio do tempo requerem a aquisição de respostas livres do sistema, como funções temporais. Um inconveniente é que, a princípio, estas respostas teriam que ser obtidas simultaneamente, o que se torna difícil quando se tem em mente realizar uma análise modal que envolve, normalmente, na prática, algumas centenas de pontos distribuídos ao longo da estrutura. O número de canais de medição disponíveis seria, assim, uma limitação fundamental. Há maneiras de contornar este problema, aplicando a Transformada de Fourier Inversa sobre funções resposta em frequência, mas este procedimento implica no uso duplo de Transformadas de Fourier (direta e inversa), o que, em boa parte, anula uma das principais vantagens dos métodos no domínio do tempo, que seria a capacidade de trabalhar com os sinais diretamente na forma em que eles são adquiridos, ou seja, como funções temporais.

Já os métodos no domínio da frequência são aplicados sobre funções resposta em frequência, as quais são obtidas por processamento dos sinais adquiridos de excitação (normalmente força) e de resposta (aceleração, velocidade ou deslocamento) da estrutura. As funções respostas em frequência (*Frequency Response Function* – FRF) podem ser entendidas como sendo a relação entre a Transformada de Fourier da resposta e a Transformada de Fourier da excitação. Assim podem-se obter, por exemplo, os valores de  $\frac{X}{F(\omega)}$ , fornecendo uma curva

conhecida como receptância, onde  $X$  representa a amplitude da resposta em termos de deslocamento, enquanto  $F(\omega)$  a força de excitação.

A Tabela 1 indica a designação das FRF's mais comum às curvas assim obtidas.

Tabela 1 - Designação das Funções Resposta em Frequência (FRF's).

Tipo de resposta	Razão resposta/força	Razão força/resposta
Deslocamento	receptância	rigidez dinâmica
Velocidade	mobilidade	impedância mecânica
Aceleração	inertância	massa aparente

Fonte: Setúbal (2022).

A Equação 4 representa a receptância para um modelo de amortecimento viscoso.

$$\frac{X}{F(\omega)} = \frac{1}{K_{eq} - m_{eq}\omega^2 + j\omega C_{eq}} = \frac{1/K_{eq}}{1 - (\omega/\omega_n)^2 + i2\xi(\omega/\omega_n)}, \quad (4)$$

em que,  $\xi$  é o fator de amortecimento viscoso e  $\omega_n$  é a frequência natural em rad/s,  $K_{eq}$  é a rigidez equivalente em N/m,  $m_{eq}$  é a massa equivalente em kg,  $\omega$  a frequência de excitação em rad/s e  $C_{eq}$  o coeficiente de amortecimento equivalente em N.s/m.

Lembrando que adotando-se uma resposta harmônica  $X(\omega)$ , tem-se que  $\dot{X}(\omega) = i\omega X(\omega)$  e que  $\ddot{X}(\omega) = -\omega^2 X(\omega)$ . Logo, a mobilidade ( $\dot{X}/F(\omega)$ ) e a inertância ( $\ddot{X}/F(\omega)$ ) podem ser obtidas pelo produto da equação 4, respectivamente, por  $j\omega$  e  $-\omega^2$ .

A análise modal experimental pode ser utilizada para validar um modelo numérico obtido, por exemplo, através do Método dos Elementos Finitos. Nesta situação calibra-se o modelo numérico de forma que as frequências naturais numéricas e experimentais aproximem ao máximo os seus valores.

A metodologia computacional em elementos finitos necessita de dados experimentais para o ajuste dos modelos e validação da solução. A principal ferramenta para fornecer os dados necessários que amparem a metodologia proposta é a Análise Modal Experimental (*Experimental Modal Analysis* – EMA).

Os dados da análise modal experimental são sempre tratados por algoritmos específicos usados para a extração dos parâmetros modais. Segundo Setúbal (2022), quando muitas peças ou conjuntos semelhantes são avaliados, a quantidade de

modos pode ser suficientemente grande para dificultar a avaliação dos resultados. Nesse caso, o principal critério utilizado é o MAC. Este critério tem a função de prover uma medição da consistência (grau de linearidade) entre estimativas de um vetor modal, fornecendo um fator de confiança adicional na avaliação dos vetores modais extraídos de diferentes locais de excitação (referência) ou de diferentes algoritmos de estimativa dos parâmetros modais.

Por outro lado, quando se deseja comparar uma análise modal numérica com a experimental, através da correlação entre os modos de vibração, uma abordagem adequada a ser seguida corresponde a comparação das formas modais experimentais com as formas modais numéricas. Neste sentido, o uso do MAC se torna uma ferramenta indispensável na validação do modelo numérico. O coeficiente MAC é obtido por meio da Equação 5.

$$\text{MAC}_{(i,j)} = \frac{|\{\Phi_i^r\}^T \{\Phi_j^e\}|^2}{(\{\Phi_i^r\}^T \{\Phi_i^r\})(\{\Phi_j^e\}^T \{\Phi_j^e\})}, \quad (5)$$

em que:  $\{\Phi_i^r\}$  é o vetor modal do modelo de referência do i-ésimo modo; e  $\{\Phi_j^e\}$  é o vetor modal do modelo calculado do j-ésimo modo;

O coeficiente MAC correlaciona os pares de vetores modais e seu valor varia entre 0 e 1. Quando MAC é igual a 1 significa que os vetores modais são idênticos e possuem uma boa correlação. Por outro lado, quando o coeficiente MAC é igual a 0 significa que os vetores modais são ortogonais entre si, sem correlação.

Há, no entanto, uma dependência espacial dos parâmetros de correlação em relação à função de cada Grau de Liberdade (GDL) individualmente denominado COMAC. WOO e VACCA (2022) correlacionam os graus de liberdade contidos em dois vetores modais, onde um deles é a condição de referência. O COMAC fornece uma indicação da contribuição de cada grau de liberdade nos valores do MAC. Os valores do COMAC variam, assim como os valores do MAC, de 0 a 1, conforme Equação 6.

$$\text{COMAC}_{(j)} = \frac{(\sum_{i=1}^n \{\Phi_i^r\}_j \{\Phi_i^e\}_j)^2}{(\sum_{i=1}^n \{\Phi_i^r\}_j \{\Phi_i^r\}_j)(\sum_{i=1}^n \{\Phi_i^e\}_j \{\Phi_i^e\}_j)} \quad (6)$$

### 3.4 Análises numéricas com o *software* Ansys

#### 3.4.1 Etapas Básicas no Método dos Elementos Finitos

As etapas básicas envolvidas em qualquer análise feita a partir do MEF são as seguintes:

- **Fase de pré-processamento**
  - Criar o domínio de solução e, em seguida, discretizá-lo em elementos finitos, isto é, subdividir o problema em nós e elementos;
  - Assumir uma função de forma para representar o comportamento físico de um elemento, isto é, uma função contínua é assumida de modo a representar a solução aproximada de um elemento;
  - Desenvolver as equações para um elemento;
  - Juntar os elementos para representar o problema inteiro e construir a matriz de rigidez global;
  - Aplicar as condições de contorno, condições iniciais e o carregamento.
  
- **Fase de solução**
  - Resolver um conjunto de equações algébricas lineares ou não-lineares simultaneamente para obter resultados nos nós, tais como, por exemplo, valores de deslocamento em um problema de mecânica dos sólidos ou valores de temperatura em um problema de transferência de calor ou valores de potencial elétrico em problemas de eletromagnetismo.
  
- **Fase de pós-processamento**
  - Obter outras informações importantes. Neste ponto, o interesse pode ser a determinação dos valores de tensões principais, fluxos de calor, etc.

Em geral, existem várias aproximações para formulação dos problemas pelo MEF, como Formulação Direta; Formulação da Energia Potencial Total Mínima; e Formulação dos Resíduos Ponderados. Entretanto, é importante observar que as

etapas básicas envolvidas em qualquer análise de elementos finitos são as mesmas, independentemente de como o modelo de elementos finitos é gerado, ou seja, da formulação usada.

### 3.4.2 Análise modal

Em uma análise modal, as equações que governam esse tipo de modelagem negligenciam a dissipação de energia e, portanto, não consideram a matriz de amortecimento. Neste sentido, essas equações constituem um problema de autossolução, que nada mais é do que um mecanismo utilizado para a determinação de autovalores e autovetores associados, dados pela Equação 7, a seguir.

$$[k]\{\phi_i\} = \omega_i^2[M]\{\phi_i\} \quad (7)$$

Sendo:  $[k]$  Matriz de rigidez do sistema;  $\{\phi_i\}$  Vetor da forma modal do modo  $i$  ou autovetor;  $\omega_i$  Frequência natural do modo  $i$ , em que  $\omega_i^2$  é o autovalor; e  $[M]$  Matriz de massa do sistema.

O *software Ansys* possui diversos algoritmos para obter o modelo dinâmico de estruturas. Alguns dos mais utilizados são:

- Método do Subespaço;
- Bloco de Lanczos;
- Energia Dinâmica;
- Método Reduzido;
- Método Assimétrico;
- Método Amortecido.

Neste trabalho, utilizou-se o método de bloco de Lanczos para extração dos autovalores. Este método é muito utilizado para resolver problemas simétricos e com grande número de nós. Além de ser um método de rápida taxa de convergência para problemas com baixo amortecimento, este método torna-se a base teórica para o mecanismo de autossolução.

Destaca-se, ainda, que o uso do método do bloco de Lanczos para a resolução de problemas maiores (com cerca de cem mil graus de liberdade, por exemplo) pode gerar muitas equações de restrição, conduzindo a arquivos grandes para processamento.

É estabelecida na Tabela 2 a seguir, uma comparação entre quatro métodos de extração modais muito utilizados dentro do *software Ansys*.

Tabela 2 - Características de métodos de extração modais disponíveis no *software Ansys*.

<b>Método de Solução</b>	<b>Aplicação</b>
Subespaço	Serve para encontrar alguns modos (cerca de quarenta) de modelos grandes; É recomendado quando o modelo consiste de um sólido regular e elemento do tipo casca; Trabalha bem, quando se possui memória limitada.
Bloco de Lanczos	Serve para encontrar muitos modos (quarenta ou mais) de modelos grandes; É recomendado quando o modelo consiste de um sólido irregular e elementos do tipo casca ou a combinação desses dois elementos; Trabalha mais rápido, porém requer cerca de 50 % a mais de memória do que o método do subespaço.
Energia Dinâmica	Serve para encontrar poucos modos (cerca de vinte) de modelos grandes; É recomendado quando se quer processamento rápido de autovalores de modelos de mais de cem mil graus de liberdades; Em modelos onde a discretização é grosseira, as frequências naturais são aproximadas.
Reduzido	Encontra todos os modos (modelos com menos de dez mil graus de liberdades); Pode ser utilizado para encontrar alguns modos (cerca de quarenta) de modelos maiores com a seleção de um grau de liberdade mestre; A precisão da frequência depende da seleção deste.

Fonte: Setúbal (2022).

### 3.4.3 Análise Harmônica

A análise harmônica estuda como sistemas respondem a excitações periódicas (harmônicas), e é usada para entender o comportamento em regime permanente quando os sistemas são excitados por forças que variam no tempo de forma harmônica.

Para obter as funções de resposta em frequência de inertância, por exemplo, ou seja, aceleração dividido pela força, os sistemas a serem analisados com uma força, tendo frequência variável dentro da faixa que contém os modos obtidos na análise modal, devem ser excitados.

De acordo com a biblioteca do *software Ansys®*, existem três métodos para a solução de problema de excitação harmônica, a saber: o método completo, o reduzido e o da superposição modal. O método completo resolve o problema forçado para sistemas considerando todos os seus graus de liberdade, de translação ou de rotação, variando os passos de carga em uma faixa de frequência predeterminada pelo usuário.

Durante a solução, este procedimento resolve o problema de autovalor e autovetor, para fornecer a resposta harmônica dos sistemas nas regiões de ressonância (caso existam frequências naturais na faixa de frequência em análise), onde ocorrem amplificações consideráveis nas amplitudes de vibrações, por este motivo esta análise requer um custo computacional elevado.

O método reduzido é uma adaptação do completo. A diferença básica reside no fato de este procedimento considerar apenas o grau mestre de liberdade, que é a direção preferencial de solução, reduzindo as dimensões das matrizes contendo as propriedades dinâmicas dos sistemas analisados e simplificando os cálculos numéricos, o que reduz bastante o tempo de processamento.

O método da superposição modal é um procedimento um pouco mais trabalhoso, porém, de resultados precisos e bem rápidos. Para executar este método, deve-se inicialmente calcular o modelo modal da estrutura a ser analisada por um método que não leve em consideração o amortecimento modal, tal como o método do Bloco de Lanczos, por exemplo. Com o modelo modal calculado, deve-se expandi-lo, ou seja, obter os coeficientes de participação modal, que fazem com que a solução harmônica tenha validade dentro de toda a faixa de frequência em análise.

A superposição modal baseia-se exatamente nos coeficientes de participação modal para gerar uma resposta harmônica dentro da faixa a ser estudada. Para que se analise com correção toda esta faixa, é recomendado no *help* do *software Ansys®*, que a frequência máxima de excitação harmônica da estrutura seja, pelo menos, 50% maior do que a frequência do último modo presente dentro deste limite. Isto é feito com o intuito de se obter os resíduos superiores presentes nas FRF's de receptância. Os resíduos consideram a influência dos modos de ordem superior e inferior nos modos a serem analisados.

Com a expansão modal realizada, pode-se analisar harmonicamente a estrutura com um tempo mínimo de processamento, o que faz com que este método seja os mais rápidos dos três.

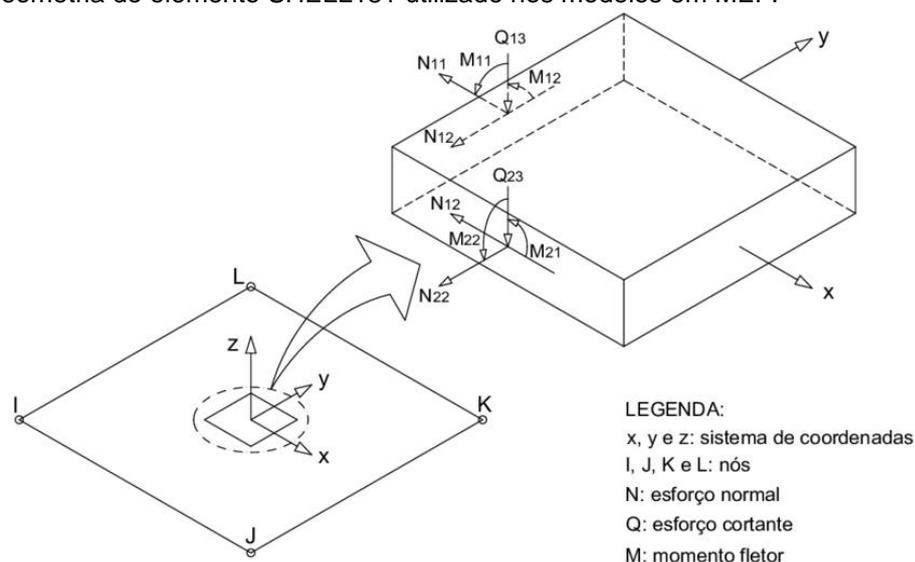
#### 3.4.4 Elementos finitos utilizados na modelagem no *software Ansys*

Para modelar numericamente a chapa, foi utilizado o elemento finito do tipo elemento de casca estrutural de 4 nós (SHELL181).

O SHELL181 é adequado para analisar estruturas de casca fina a moderadamente espessa. É um elemento de quatro nós com seis graus de liberdade em cada nó: translações nas direções  $x$ ,  $y$  e  $z$  e rotações em torno dos eixos  $x$ ,  $y$  e  $z$ . (Se a opção de membrana for usada, o elemento terá apenas graus de liberdade translacionais). A opção triangular degenerada deve ser usada apenas como elementos de preenchimento na geração de malha. O SHELL181 é adequado para aplicações lineares, de grande rotação e/ou de grande deformação não linear. A mudança na espessura da casca é contabilizada em análises não lineares. No domínio do elemento, os esquemas de integração completa e reduzida são suportados. O SHELL181 pode ser usado para aplicações em camadas para modelagem de cascas compostas ou construção em sanduíche. A precisão na modelagem de cascas compostas é governada pela teoria de formação de cisalhamento de primeira ordem (geralmente chamada de teoria de casca de Mindlin-Reissner). A formulação do elemento é baseada em medidas logarítmicas de tensão e tensão verdadeira. A cinemática do elemento permite deformações finitas da membrana (alongamento). No entanto, as mudanças de curvatura dentro de um incremento de tempo são consideradas pequenas.

Na Figura 3, pode-se observar o elemento descrito. Ela mostra a geometria, as localizações dos nós e o sistema de coordenadas do elemento para este elemento. O elemento é definido por informações de seção de casca e por quatro nós (I, J, K e L).

Figura 3 – Geometria do elemento SHELL181 utilizado nos modelos em MEF.



Fonte: Santos, Vieira e Paiva (2022).

### 3.5 Aprendizado de Máquina

Cada categoria de aprendizado de máquina é caracterizada por suas técnicas e algoritmos distintos, projetados para se adequar a uma variedade de problemas e conjuntos de dados. A geração de conhecimento computacional requer um vasto conjunto de exemplos, que são transformados em hipóteses derivadas dos dados. As abordagens de aprendizado de máquina são centradas nos dados, ou seja, elas adquirem conhecimento de forma autônoma a partir de grandes volumes de dados.

Segundo Lu et al. (2024), o aprendizado de máquina é um método que permite que os sistemas de computador melhorem e otimizem automaticamente o desempenho, aprendendo padrões e regras a partir dos dados. Ele se concentra na descoberta de padrões, na realização de previsões ou na tomada de decisões com base em dados, por meio da construção e treinamento de modelos.

De acordo com Tucci (2024), é importante notar que o sucesso do aprendizado de máquina depende não apenas da quantidade, mas também da qualidade dos dados disponíveis. Dados precisos e bem rotulados podem melhorar significativamente a eficácia dos algoritmos de aprendizado de máquina. Além disso, a escolha do algoritmo certo para o problema certo é crucial, pois cada algoritmo tem suas próprias forças e limitações. Portanto, um entendimento profundo do problema e dos dados disponíveis é essencial para o sucesso do aprendizado de máquina.

De acordo com Lai (2020), existem três tipos principais de aprendizado de máquina:

- **Aprendizado Supervisionado:** Este tipo envolve o uso de um conjunto de dados rotulado, onde as saídas desejadas são conhecidas. O objetivo é treinar um modelo que possa fazer previsões precisas para novos dados não rotulados. A finalidade do algoritmo é criar um classificador capaz de identificar corretamente a categoria de novas amostras que ainda não foram classificadas. Quando os rótulos da classe são discretos, essa tarefa é conhecida como classificação, e quando os valores são contínuos, é chamada de regressão.
- **Aprendizado Não Supervisionado:** os exemplos são apresentados ao algoritmo sem qualquer tipo de rótulo ou classificação prévia. O algoritmo, então, procura por padrões e similaridades nos atributos desses exemplos para agrupá-los. Esse processo é conhecido como clusterização. O algoritmo examina os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma

maneira, formando agrupamentos ou *clusters*. Esses clusters são formados com base na proximidade dos exemplos no espaço de atributos, ou seja, exemplos semelhantes são agrupados juntos. Após a determinação dos agrupamentos, geralmente é necessária uma análise posterior para interpretar o que cada agrupamento representa no contexto do problema que está sendo analisado. Essa análise pode envolver a identificação de características distintivas de cada *cluster*, a atribuição de rótulos aos clusters ou a utilização dos *clusters* para fazer previsões sobre novos exemplos. É importante notar que, ao contrário do aprendizado supervisionado, o aprendizado não supervisionado não tem uma “resposta correta” clara, e a qualidade dos resultados podem variar dependendo dos parâmetros e suposições do algoritmo.

- **Aprendizado por Reforço:** é um tipo de aprendizado de máquina onde um agente aprende a tomar decisões através de um processo de tentativa e erro. O agente interage com um ambiente, realiza ações e recebe *feedback* na forma de recompensas ou punições. Este *feedback* ajuda o agente a ajustar suas ações futuras para maximizar a recompensa total ao longo do tempo. Segundo Shen (2024), este tipo de aprendizado é especialmente útil em situações em que a sequência de ações é importante e o agente deve considerar as consequências a longo prazo de suas ações.

De acordo com Mnih (2015), o Aprendizado por Reforço é comumente utilizado em uma variedade de aplicações, incluindo jogos, navegação de robôs, controle de sistemas, otimização de recursos e muito mais. Em todas essas aplicações, o objetivo é aprender uma estratégia para escolher ações com base no estado atual, que maximize a recompensa total. Um aspecto importante do Aprendizado por Reforço é que ele permite que os agentes aprendam a partir da interação direta com o ambiente, sem a necessidade de exemplos de treinamento rotulados fornecidos por um supervisor. Isso o torna uma ferramenta poderosa para problemas onde o conhecimento prévio é limitado ou a geração de exemplos de treinamento rotulados é impraticável.

De acordo com Setúbal (2022) o uso de Aprendizado de Máquina para solucionar problemas nem sempre é fácil e precisa de alguns pré-requisitos, como um bom conjunto de exemplos. Muitas vezes a base de exemplos precisa ser construída e atualizada constantemente. Como os dados nem sempre são bons, faz-se necessário o uso de técnicas que melhorem a qualidade dos dados. Logo, nem todo algoritmo de Aprendizado de Máquina resolve todo tipo de problema, sendo

necessário a seleção dos conjuntos de algoritmos apropriados para o problema que se precisa resolver. Sendo assim, nos tópicos a seguir são apresentados os algoritmos de Aprendizado de Máquina que melhor se ajustaram ao conjunto de dados fornecido.

### 3.5.1 Regressor de floresta aleatória

Florestas aleatórias são um conjunto de árvores de decisão, onde cada uma depende dos valores de um vetor amostral independente e com a mesma distribuição para todas as árvores do conjunto (BREIMAN, 2001). De acordo com Cutler (2011), o crescimento de um grupo de árvores e a permissão para que votem na classe mais comum resultaram em melhorias significativas na precisão da classificação. Vetores aleatórios são geralmente gerados para governar o crescimento de cada árvore no conjunto. Breiman (2001) menciona um exemplo inicial, a metodologia conhecida como bagging, que utiliza uma seleção aleatória (sem reposição) dos exemplos do conjunto de treinamento para cultivar cada árvore. Ele também menciona outro exemplo em seu trabalho, a seleção por divisão aleatória, onde em cada nó a divisão é escolhida aleatoriamente entre as  $K$  melhores divisões.

O elemento comum em todos esses procedimentos é que, para a  $k$ -ésima árvore, um vetor aleatório  $\theta_k$  é gerado, independente dos vetores aleatórios passados  $\theta_1, \dots, \theta_{k-1}$ , com a mesma distribuição e uma árvore é cultivada usando o conjunto de treinamento e  $\theta_k$ , resultando em um classificador  $h(\mathbf{x}, \theta_k)$ , onde  $\mathbf{x}$  é um vetor de entrada. Por exemplo, na técnica de ensacamento, o vetor aleatório  $\Theta$  é formado pelas contagens em  $N$  compartimentos, que são o resultado de  $N$  dardos lançados aleatoriamente nos compartimentos, onde  $N$  é a quantidade de exemplos no conjunto de treinamento. Na seleção por divisão aleatória,  $\Theta$  é composto por uma série de números inteiros aleatórios independentes entre 1 e  $k$ . A característica e a dimensionalidade de  $\Theta$  são determinadas pelo seu papel na construção das árvores. Após a geração de um grande número de árvores, elas votam na classe mais frequente. Segundo (BREIMAN, 2001; JOHANSSON ET AL., 2014), esse procedimento é chamado de floresta aleatória.

**Definição 1** – Uma floresta aleatória é um classificador que consiste em uma coleção de classificadores estruturados em árvore  $\{h(\mathbf{x}, \theta_k), k = 1, \dots\}$  em que  $\{\theta_k\}$

são vetores aleatórios identicamente distribuídos independentes e cada árvore lança um voto para a classe mais popular na entrada  $\mathbf{x}$ .

### 3.5.1.1 Caracterizando a precisão de florestas aleatórias

A priori, a precisão de uma floresta aleatória está relacionada com a sua convergência. Dado um conjunto de classificadores  $h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_k(\mathbf{x})$ , e com o conjunto de treinamento extraído aleatoriamente da distribuição do vetor aleatório  $y, \mathbf{x}$ , a função de margem é definida como demonstrado na Equação 8.

$$mg(\mathbf{x}, y) = av_k I(h_k(\mathbf{x}) = y) - \max_{j \neq y} av_k I(h_k(\mathbf{x}) = j), \quad (8)$$

em que  $I(h_k(\mathbf{x}) = y)$  ou  $I(h_k(\mathbf{x}) = j)$  é a função do indicador.

Para a classe certa, a margem mede até que ponto o número médio de votos em  $\mathbf{x}, y$ , excede o voto médio para qualquer outra classe. Sendo a confiança na classificação diretamente proporcional a margem. O erro de generalização é dado de acordo com a Equação 9.

$$PE^* = P_{\mathbf{x}, y}(mg(\mathbf{x}, y) < 0), \quad (9)$$

em que os subscritos  $\mathbf{x}, y$  indicam que a probabilidade é sobre o espaço  $\mathbf{x}, y$ .

Logo, para florestas aleatórias,  $h_k(\mathbf{x}) = h_k(\mathbf{x}, \Theta_k)$ .

Breiman (2001) e Cutler (2011), afirmam que para um grande número de árvores, segue-se da Lei Forte dos Grandes Números e da estrutura da árvore que:

**Teorema 1.** *À medida que o número de árvores aumenta, quase certamente para todas as sequências  $\Theta_1, \dots$   $PE^*$  converge para:*

$$P_{\mathbf{x}, y}(P_{\Theta}(h(\mathbf{x}, \Theta) = y) - \max_{j \neq y} P_{\Theta}(h(\mathbf{x}, \Theta) = j) < 0) \quad (10)$$

Isso implica em florestas aleatórias não super ajustadas à medida que mais árvores são adicionadas, no entanto, geram um valor limite do erro de generalização.

Segundo Henkel, Weijtjens e Devriendt (2021), a Lei dos Grandes Números é aplicada nos casos em que as variáveis são aleatórias independentes, identicamente distribuídas com média finita e existência do quarto momento central.

De acordo com Setúbal (2022), para florestas aleatórias, um limite superior pode ser derivado para o erro de generalização em termos de dois parâmetros que são medidas de quão precisos são os classificadores individuais e da dependência entre eles. A interação entre esses dois fornece a base para entender o funcionamento das florestas aleatórias.

**Definição 2** – A função de margem para uma floresta aleatória é dada pela Equação 11:

$$mr(\mathbf{x}, y) = P_{\theta}(h(\mathbf{x}, \theta) = y) - \max_{j \neq y} P_{\theta}(h(\mathbf{x}, \theta) = j) \quad (11)$$

e a robustez do conjunto de classificadores  $\{h(\mathbf{x}, \theta)\}$ , pela Equação 12.

$$s = E_{\mathbf{x}, y} mr(\mathbf{x}, y), \quad (12)$$

onde  $E_{\mathbf{x}, y}$  é o erro de generalização médio quadrático.

Assumindo que  $s \geq 0$ , a inequação de *Chebychev* resulta em

$$PE^* \leq \text{var}(mr)/s^2 \quad (13)$$

Uma expressão mais reveladora para a variância de  $mr$  é derivada do seguinte:

$$\hat{j}(\mathbf{x}, y) = \arg \max_{j \neq y} P_{\theta}(h(\mathbf{x}, \theta) = j) \quad (14)$$

Neste sentido,

$$mr(\mathbf{x}, y) = P_{\theta}(h(\mathbf{x}, \theta) = y) - P_{\theta}(h(\mathbf{x}, \theta) = \hat{j}(\mathbf{x}, y)) = E_{\theta}[I(h(\mathbf{x}, \theta) = y) - I(h(\mathbf{x}, \theta) = \hat{j}(\mathbf{x}, y))] \quad (15)$$

**Definição 3** – A função de margem bruta é dada pela Equação 16:

$$rmg(\theta, \mathbf{x}, y) = I(h(\mathbf{x}, \theta) = y) - I(h(\mathbf{x}, \theta) = \hat{j}(\mathbf{x}, y)), \quad (16)$$

onde:  $mr(\mathbf{x}, y)$  é a expectativa de  $rmg(\theta, \mathbf{x}, y)$  em relação a  $\theta$ .

Para qualquer função  $f$  da identidade (Equação 17) em que  $\theta, \theta'$  são independentes com a mesma distribuição.

$$[E_{\Theta}f(\Theta)]^2 = E_{\Theta,\Theta'}f(\Theta)f(\Theta') \quad (17)$$

Isso implica que:

$$mr(\mathbf{x}, y)^2 = E_{\Theta,\Theta'}rmg(\Theta, \mathbf{x}, y)rmg(\Theta', \mathbf{x}, y) \quad (18)$$

A partir da Equação 18 tem-se:

$$\text{var}(mr) = E_{\Theta,\Theta'}\text{cov}_{\mathbf{x},y}rmg(\Theta, \mathbf{x}, y)rmg(\Theta', \mathbf{x}, y) = E_{\Theta,\Theta'}(\rho(\Theta, \Theta')sd(\Theta)sd(\Theta')), \quad (19)$$

em que:  $\rho(\Theta, \Theta')$  é a correlação entre  $rmg(\Theta, \mathbf{x}, y)$  e  $rmg(\Theta', \mathbf{x}, y)$ , mantendo  $\Theta, \Theta'$  fixo.

$sd(\Theta)$  é o desvio padrão de  $rmg(\Theta, \mathbf{x}, y)$  mantendo  $\Theta$  fixo.

Então:

$$\text{var}(mr) = \bar{\rho}(E_{\Theta}sd(\Theta))^2 \leq \bar{\rho}E_{\Theta}\text{var}(\Theta), \quad (20)$$

em que  $\bar{\rho}$  é o valor médio da correlação; isso é:

$$\bar{\rho} = E_{\Theta,\Theta'}(\rho(\Theta, \Theta')sd(\Theta)sd(\Theta'))/E_{\Theta,\Theta'}(sd(\Theta)sd(\Theta')) \quad (21)$$

Portanto,

$$E_{\Theta}\text{var}(\Theta) \leq E_{\Theta}(E_{\mathbf{x},y}rmg(\Theta, \mathbf{x}, y))^2 - s^2 \leq 1 - s^2 \quad (22)$$

Combinando as Equações 13, 20 e 22, resulta que:

**Teorema 2.** *Um limite superior para o erro de generalização é dado por*

$$PE^* \leq \bar{\rho}(1 - s^2)/s^2 \quad (23)$$

Embora o limite possa ser indefinido, ele desempenha o mesmo papel indicativo para florestas aleatórias que os limites para outros classificadores. Isso indica que os dois parâmetros que influenciam o erro de generalização em florestas aleatórias são a potência dos classificadores individuais na floresta e a correlação entre eles em relação às funções de margem bruta. A razão  $\frac{\bar{c}}{s^2}$  representa a correlação dividida pelo quadrado da força  $s^2$ , sendo que valores menores são melhores.

**Definição 4** – A razão  $\frac{c}{s^2}$  para uma floresta aleatória é definida pela Equação 24.

$$\frac{c}{s^2} = \frac{\bar{\rho}}{s^2} \quad (24)$$

Existem simplificações na situação de duas classes. Neste sentido, a função margem é representada pela Equação 25.

$$mr(\mathbf{x}, y) = 2P_{\Theta}(h(\mathbf{x}, \Theta) = y) - 1 \quad (25)$$

A exigência de que a robustez seja positiva (ver Equação 13), torna-se semelhante à condição familiar de aprendizagem fraca  $E_{\mathbf{x},y}P_{\Theta}(h(\mathbf{x}, \Theta) = y) > 0.5$ . A função de margem bruta é  $2I(h(\mathbf{x}, \Theta) = y) - 1$  e a correlação  $\bar{\rho}$  está entre  $I(h(\mathbf{x}, \Theta) = y)$  e  $I(h(\mathbf{x}, \Theta') = y)$ . Se os valores de  $y$  forem considerados +1 e -1, então

$$\bar{\rho} = E_{\Theta, \Theta'}[\rho(h(\cdot, \Theta), h(\cdot, \Theta'))], \quad (26)$$

sendo que  $\bar{\rho}$  é a correlação entre dois membros diferentes da floresta calculados, adotando a distribuição  $\Theta, \Theta'$ .

Acima de duas classes, a medida da robustez, definida pela Equação 27 depende da floresta, assim como as árvores individuais, pois  $\hat{j}(\mathbf{x}, y)$  é determinado pela floresta.

Outra abordagem é possível:

$$PE^* = P_{\mathbf{x},y}(P_{\Theta}(h(\mathbf{x}, \Theta) = y) - \max_{j \neq y} P_{\Theta}(h(\mathbf{x}, \Theta) = j) < 0) \leq \sum_j P_{\mathbf{x},y}(P_{\Theta}(h(\mathbf{x}, \Theta) = y) - P_{\Theta}(h(\mathbf{x}, \Theta) = j) < 0), \quad (27)$$

e definindo:

$$s_j = E_{\mathbf{x},y}(P_{\Theta}(h(\mathbf{x}, \Theta) = y) - P_{\Theta}(h(\mathbf{x}, \Theta) = j)) \quad (28)$$

Para ser a robustez do conjunto de classificadores  $h(\mathbf{x}, \Theta)$  em relação à classe  $j$ . Essa definição de robustez independe da floresta. Pela inequação de *Chebyshev*, assumindo que todo  $s_j > 0$ :

$$PE^* \leq \sum_j \text{var}(P_{\Theta}(h(\mathbf{x}, \Theta) = y) - P_{\Theta}(h(\mathbf{x}, \Theta) = j)) / s_j^2 \quad (29)$$

as variâncias na Equação 3.29 podem ser expressas em termos de correlações médias através da utilização de identidades semelhantes às usadas para se chegar na Equação 3.20. Breiman (2001) não usou estimativas das quantidades na Equação 3.29 em seu estudo empírico, entretanto, o autor acredita que elas seriam interessantes em problemas de múltiplas classes.

### 3.5.1.2 Usando features aleatórias

Segundo Steven (2017) certas florestas aleatórias mencionadas na literatura apresentam um erro de generalização consistentemente inferior em comparação com outras. Ele destacou que a divisão aleatória é superior ao ensacamento, por exemplo. Outro ponto relevante é a diminuição do erro de generalização quando há introdução de ruído aleatório nas saídas. No entanto, de acordo com Breiman (2001), nenhuma dessas três florestas se compara ao desempenho do Adaboost ou de outros algoritmos de reponderação adaptativa do conjunto de treinamento.

Para aprimorar a precisão, a aleatoriedade introduzida deve minimizar a correlação  $\bar{\rho}$ , mantendo a robustez do método. As florestas analisadas envolvem o uso de entradas selecionadas aleatoriamente ou combinações de entradas em cada nó para cultivar e desenvolver cada árvore. As florestas resultantes oferecem uma precisão que compete favoravelmente com o Adaboost.

De acordo com Setúbal (2022), esta classe de procedimentos tem características desejáveis:

- Sua precisão é tão boa quanto o *Adaboost* e às vezes melhor.
- É relativamente robusta à discrepâncias (*outliers*) e a ruídos.
- É mais rápido do que a metodologia de ensacamento (*bagging*) ou da *Adaboost*.
- Fornece estimativas internas úteis de erro, robustez, correlação e importância variável.
- É simples e facilmente paralelizável.

### 3.5.1.3 Usando estimativa *Out-of-Bag* (OOB) para monitorar erro, força e correlação

De acordo com Cutler (2011), quando uma amostra de inicialização é retirada dos dados, algumas observações não entram na amostra de inicialização. Eles são chamados de “*out-of-bag data*”, dados prontos para uso, e são extremamente úteis para estimar o erro de generalização e a importância das variáveis. Portanto, para estimar o erro de generalização, observa-se que se as árvores forem grandes, as previsões obtidas ingenuamente usando todas as árvores serão excessivamente otimista se usado para prever a variável de resposta para observações que estavam no conjunto de treinamento. Por esse motivo, a previsão da variável de resposta para observações que estavam no conjunto de treinamento só é feita usando árvores para as quais a observação está fora do saco. Essas previsões são chamadas de previsões prontas para uso.

Em determinados casos de aplicação do algoritmo de florestas aleatórias, o ensacamento é empregado juntamente com a seleção aleatória de características. Cada novo conjunto de treinamento é extraído, com reposição, do conjunto de treinamento original. Posteriormente, uma árvore é cultivada no novo conjunto de treinamento, utilizando a seleção aleatória das características. Neste cenário, as árvores cultivadas não são podadas.

Existem duas justificativas para o uso do ensacamento:

- ✓ A primeira é que esse procedimento parece incrementar a precisão quando características aleatórias são utilizadas;
- ✓ A segunda é que o ensacamento pode ser empregado para fornecer estimativas contínuas do erro de generalização (PE\*) do conjunto combinado de árvores, bem como estimativas de robustez e correlação.

Essas estimativas são realizadas de forma *out-of-bag*, conforme explicado a seguir.

Levando-se em consideração um método para construir um classificador a partir de qualquer conjunto de treinamento. Dado um conjunto de treinamento específico  $T$ , formam-se conjuntos de treinamento bootstrap  $T_k$ , em seguida, devem-se construir classificadores  $h(x, T_k)$  e permitir que eles votem para formar o preditor ensacado. Para cada  $y, \mathbf{x}$  no conjunto de treinamento, agregam-se os votos apenas sobre os classificadores para os quais  $T_k$  não contém  $y, \mathbf{x}$ . Assim, a estimativa *out-of-*

bag para o erro de generalização é a taxa de erro do classificador OOB no conjunto de treinamento.

O estudo de estimativas de erro para classificadores ensacados, apresentado por Breiman (2001), demonstra que a estimativa out-of-bag é tão precisa quanto a utilização de um conjunto de teste do mesmo tamanho do conjunto de treinamento. Logo, o autor a utilização da estimativa de erro OOB pode eliminar a necessidade de um conjunto de teste reservado. Em cada conjunto de treinamento de bootstrap, aproximadamente um terço das instâncias são deixadas de fora. Portanto, as estimativas out-of-bag são baseadas na combinação de apenas cerca de um terço dos classificadores da combinação principal em andamento. Como a taxa de erro diminui à medida que o número de combinações aumenta, as estimativas out-of-bag tenderão a superestimar a taxa de erro atual. Para obter estimativas imparciais out-of-bag, é necessário ultrapassar o ponto em que o erro do conjunto de teste converge.

A força e a correlação também podem ser estimadas utilizando métodos out-of-bag. Isso fornece estimativas internas que são úteis para compreender a precisão da classificação e como aprimorá-la.

#### 3.5.1.4 Florestas aleatórias para regressão

Ainda segundo Breiman (2001), florestas aleatórias são formadas pelo crescimento de árvores dependendo de um vetor aleatório  $\theta$ , assim, o preditor de árvore  $h(\mathbf{x}, \theta)$  assume valores numéricos em oposição aos rótulos de classe. O conjunto de treinamento é construído independentemente da distribuição do vector aleatório  $\mathbf{x}, y$ , sendo os valores de saída, numéricos. Na Equação 30, é mostrado o erro de generalização médio quadrático para qualquer preditor numérico  $h(X)$ .

$$E_{\mathbf{x},y}(y - h(\mathbf{x}))^2 \quad (30)$$

O preditor de floresta aleatória é formado tomando a média sobre  $k$  das árvores  $h(\mathbf{x}, \theta_k)$ . Da mesma forma que no caso de classificação, é válido o seguinte:

**Teorema 3.** *Como o número de árvores na floresta vai ao infinito, então*

$$E_{\mathbf{x},y}(y - av_k h(\mathbf{x}))^2 \rightarrow E_{\mathbf{x},y}(y - E_{\theta}(h(\mathbf{x}, \theta)))^2 \quad (31)$$

denota o lado direito de Equação 31 como o erro de generalização da floresta ( $PE^*(floresta)$ ). O erro médio de generalização de uma árvore é então definido como:

$$PE^*(\text{árvore}) = E_{\Theta} E_{x,y} (y - h(\mathbf{x}, \Theta))^2 \quad (32)$$

**Teorema 4.** Suponha-se que para todo  $\Theta$ ,  $E_y = E_x h(\mathbf{x}, \Theta)$ . Então

$$PE^*(floresta) \leq \bar{\rho} PE^*(\text{árvore}), \quad (33)$$

em que:

$\bar{\rho}$  é a correlação ponderada entre os resíduos  $y - h(\mathbf{x}, \Theta)$  e  $y - h(\mathbf{x}, \Theta')$  onde  $\Theta, \Theta'$  são independentes.

Uma vez que:

$$PE^*(floresta) = E_{x,y} [E_{\Theta} (y - h(\mathbf{x}, \Theta))]^2 = E_{\Theta} E_{\Theta'} E_{x,y} (y - h(\mathbf{x}, \Theta))(y - h(\mathbf{x}, \Theta')), \quad (34)$$

o termo à direita na Equação 34 é uma covariância e pode ser escrito como:

$E_{\Theta} E_{\Theta'} (\rho(\Theta, \Theta') sd(\Theta) sd(\Theta'))$ , em que:  $sd(\Theta) = \sqrt{E_{x,y} (y - h(\mathbf{x}, \Theta))^2}$  define a correlação

ponderada como:

$$\bar{\rho} = E_{\Theta, \Theta'} (\rho(\Theta, \Theta') sd(\Theta) sd(\Theta')) / (E_{\Theta} sd(\Theta))^2, \quad (35)$$

então,  $PE^*(floresta) = \bar{\rho} (E_{\Theta} sd(\Theta))^2 \leq \bar{\rho} PE^*(\text{árvore})$ .

O Teorema (4) indica os requisitos para florestas de regressão precisas, tais como: baixa correlação entre resíduos e árvores de baixo erro. A floresta aleatória diminui o erro médio das árvores empregadas pelo fator  $\rho$ . A aleatoriedade empregada precisa visar a baixa correlação. As demonstrações das formulações apresentadas nesta sessão 3.7 podem ser vistas nos apêndices do trabalho de Breiman (2001).

### 3.5.2 Algoritmo k-NN (*k-Nearest Neighbor*)

Uma maneira de predizer o valor  $y$  de um novo exemplo consiste em comparar esse exemplo com outros cuja classe é conhecida e atribuir a classe do caso mais

próximo. Nesse sentido o algoritmo *k-Nearest Neighbor* (kNN) é um algoritmo de aprendizado supervisionado do tipo lazy, introduzido por Aha et al. (1991). O conceito central desse algoritmo é identificar os  $k$  exemplos com rótulos mais similares ao exemplo ainda não classificado e, baseando-se nos rótulos desses exemplos similares, determinar a classe do exemplo não rotulado. Os algoritmos do tipo kNN demandam pouco esforço durante a fase de treinamento. No entanto, o custo computacional para classificar um novo exemplo é consideravelmente alto, já que, esse exemplo terá que ser comparado com todos os exemplos presentes no conjunto de treinamento.

Para a implementação do kNN, é necessário definir quais exemplos rotulados, ou seja, exemplos de treinamento, devem ser retidos; qual a métrica que estabelece a similaridade entre o exemplo não classificado e os exemplos de treinamento; e quantos/quais dos vizinhos mais próximos devem ser levados em conta.

A quantidade de exemplos de treinamento a serem lembrados tem influência direta no tempo de busca pelos exemplos mais próximos do exemplo a ser classificado, pois é necessário comparar esse exemplo com todos os armazenados (Alpaydin, 2014). Dependendo do domínio, essa quantidade de exemplos pode ser muito grande e tornar o processo lento, até o ponto de não atender ao requisito de tempo máximo de resposta para determinado problema. Ao invés de utilizar muitos exemplos de treinamento, o ideal é armazenar somente os exemplos mais representativos de cada classe, resumindo a informação mais importante em um conjunto menor de exemplos. Em (Aha et al., 1991) são descritas algumas estratégias para selecionar os exemplos mais representativos de cada classe, a partir do conjunto de exemplos rotulados disponíveis, contribuindo para a redução do custo para classificar novos exemplos e do espaço ocupado em memória pelos exemplos de treinamento.

Yunsheng et al. (2017) afirma que o KNN adota o conceito de “aprendizado preguiçoso”, pois o algoritmo não cria um modelo até que seja necessário fazer uma previsão. Isso tem a vantagem de considerar apenas os dados pertinentes para a análise do novo padrão de entrada, tornando-se, por isso, um modelo localizado. No entanto, uma desvantagem do KNN é que todos os dados de treinamento precisam ser armazenados e consultados para identificar os vizinhos mais próximos.

Seja  $N_k(x')$  o conjunto formado pelos  $k$  padrões de treinamento  $x \in \mathbb{R}^{K \times 1}$  mais próximos ao dado de entrada  $x'$ . As saídas associadas a estes padrões de treinamento são denotadas por  $y_i(x \in N_k(x')), j = 1, \dots, k$ .

Em regressão, a saída do KNN para um novo dado de entrada  $x'$  pode ser escrita de forma geral como:

$$\hat{y}(x') = \frac{\sum_{j=1}^k w_j y_j(x \in N_k(x'))}{\sum w_j} \quad (36)$$

Para obter uma estimativa mais suave, podemos usar uma função kernel cujo efeito diminui com o aumento da distância:

$$\hat{p} = \frac{1}{Nd_k(x)} \sum_{t=1}^N K\left(\frac{x-x^t}{d_k(x)}\right) \quad (37)$$

Isto é como um estimador de kernel com parâmetro de suavização adaptativo  $h = d_k(x)$ .  $K(\cdot)$  é normalmente considerado o *kernel* gaussiano.

Segundo Abbass, Awais e Nguyen (2024), outra questão relevante está relacionada com a definição da medida utilizada para determinar o grau de similaridade entre o exemplo a ser rotulado e os exemplos no conjunto de treinamento. Diversas medidas têm sido propostas, entre as quais estão as medidas de distância e de correlação. Quando o conjunto de dados é descrito por atributos numéricos, as medidas de distância podem ser devidamente aplicadas para o cálculo da similaridade entre os exemplos, tal que menor distância corresponde a maior similaridade. Diversos índices de proximidade têm sido propostos para o cálculo da similaridade entre pares de exemplos  $(E_i, E_j)$ , os quais devem satisfazer as seguintes condições:

- i.  $dist(E_i, E_j) \geq 0, \forall(i, j)$  (positividade)
- ii.  $dist(E_i, E_j) = 0$  se e somente se  $E_i = E_j$  (identidade)
- iii.  $dist(E_i, E_j) = dist(E_j, E_i)$  (simetria)

Para que um índice de proximidade seja considerado uma métrica, este deve satisfazer, além das três propriedades anteriores, a propriedade de desigualdade triangular:

- iv.  $dist(E_i, E_j) \leq dist(E_i, E_q) + dist(E_q, E_j), \forall(i, j, q)$

Considerando os atributos dos exemplos como dimensões de um espaço multidimensional, a descrição de cada exemplo corresponde a um ponto nesse

espaço, i.e.,  $E_i = (x_{i1}, x_{i2}, \dots, x_{in})$ . Minkowsky estabeleceu uma maneira genérica para calcular a distância entre dois pontos no espaço n-dimensional de acordo com o valor do parâmetro  $d$ , o qual determina a medida utilizada:

$$\text{dist}(E_i, E_j) = \left( \sum_{l=1}^n |x_{il} - x_{jl}|^d \right)^{\frac{1}{d}} \quad (38)$$

À medida que o valor de  $d$  aumenta, a forma geométrica composta por pontos equidistantes do centro se aproxima de um quadrado. Quando  $d$  tende ao infinito, esses pontos formam precisamente um quadrado. A medida de Minkowsky é chamada de distância de Manhattan quando  $d = 1$  e define a distância Euclidiana quando  $d = 2$ . Aggarwal e colaboradores (2001) debatem a adequação da medida de Minkowsky para conjuntos de dados de alta dimensão, sugerindo que  $d = 1$  ou  $2$  são mais pertinentes do que  $d \geq 3$ .

Segundo Yunsheng et al. (2017), a regressão kNN é um algoritmo importante e menos preocupante em comparação com a classificação kNN, mas existem alguns estudos sobre este tema. Uma vez que existem algumas instâncias ruidosas nos dados, elas têm um efeito negativo no desempenho do regressor, portanto, essas instâncias devem ser removidas antes do treinamento.

### 3.5.3 Modelos de Árvore de Decisão

Árvores de decisão (DTs) são um método de aprendizagem supervisionado não paramétrico usado para classificação e regressão, cujo objetivo é criar um modelo que preveja o valor de uma variável alvo, aprendendo regras de decisão simples inferidas a partir dos recursos dos dados.

Uma árvore pode ser vista como uma aproximação constante por partes, onde os dados divididos em classes de interesse, são usados para construir regras que classificam casos novos ou antigos com máxima precisão.

Esta abordagem, às vezes conhecida como indução de regra, tem várias vantagens, por exemplo: processo de raciocínio por trás do modelo é verificável ao se examinar a árvore. Isso está em contraste com outras técnicas de modelagem caixa preta em que a lógica interna pode ser difícil de trabalhar. A visualização da árvore de decisão, permite avaliar como os atributos nos dados, dividem ou particionam os dados relevantes ao problema.

As Árvores de Decisão têm por característica incluir automaticamente em sua regra apenas os atributos realmente importantes para uma tomada de decisão, ignorando os atributos que não contribuem com a precisão da árvore. Esse processo tende a produzir informações muito úteis sobre os dados e ser utilizado para reduzir os dados para campos relevantes antes de treinar outra técnica de aprendizado, como uma rede neural.

Outro ponto importante diz respeito ao fato de esse modelo de Aprendizado de Máquina requerer pouca preparação de dados. Outras técnicas geralmente requerem a normalização de dados, criação de variáveis fictícias e remoção de valores em branco. Algumas combinações de árvores e algoritmos suportam valores ausentes.

### 3.5.3.1 Modelos de Árvores Aleatórias

Modelos de árvore Aleatórias são utilizados para desenvolver sistemas de classificação que prevejam ou classifiquem observações futuras com base em um conjunto de regras de decisão.

O modelo de Arvore Aleatórias é construído por meio de particionamento recursivo, onde os nós são divididos com base nos valores dos recursos de entrada para minimizar a variação geral ou outra métrica especificada, considerando todas as variáveis de saída. O processo recursivo continua até que um critério de parada seja atendido, como uma profundidade de árvore especificada ou um número mínimo de amostras em um nó folha (Czajkowski, Jurczuk e Kretowski, 2023).

Dados divididos em classes de interesse são utilizados para criar regras que possam ser usadas para classificar casos antigos ou novos com a máxima precisão. Este método, também referido como indução de regras, apresenta vários benefícios. Em primeiro lugar, permite com que as Árvores Aleatórias sejam frequentemente consideradas interpretáveis e autoexplicativas, sendo constantemente exploradas (Czajkowski, Jurczuk e Kretowski, 2023). Isso se diferencia de outras técnicas de modelagem de caixa preta, onde a lógica interna pode ser complexa de compreender. Em segundo lugar, o processo inclui automaticamente na sua regra apenas os atributos que realmente importam na tomada de decisão, baseado em divisões de recursos em uma condição booleana (Verdadeiro ou Falso) que resulta no maior ganho de informação (Khandelwal e Dalai, 2024). Atributos que não contribuem para a precisão da árvore são ignorados. Isto permite a geração de informações muito úteis

sobre os dados, podendo ser utilizado para preparação de dados, reduzindo-os a campos relevantes antes de treinar outra técnica de aprendizagem.

Os resultados do modelo de árvore de decisão podem ser convertidos em uma coleção de regras se - então (um conjunto de regras), que em muitos casos mostram as informações de uma forma mais compreensível. A apresentação da árvore de decisão é útil quando se deseja ver como os atributos nos dados podem dividir ou particionar a população em subconjuntos relevantes para o problema.

Vários algoritmos estão disponíveis para realizar análises de classificação e segmentação. Todos esses algoritmos executam basicamente o mesmo processo: examinam todos os campos do seu conjunto de dados para encontrar aquele que fornece a melhor classificação ou previsão, dividindo os dados em subgrupos. O processo é aplicado recursivamente, dividindo os subgrupos em unidades cada vez menores até que a árvore seja finalizada (conforme definido por certos critérios de parada). Os campos de destino e de entrada utilizados na construção da árvore podem ser contínuos (intervalo numérico) ou categóricos, dependendo do algoritmo utilizado.

### 3.5.3.2 Método da Árvore CHAID

O CHAID, ou *Chi-squared Automatic Interaction Detection*, é um método de classificação para construir árvores de decisão usando estatísticas de qui-quadrado para identificar divisões ideais.

O CHAID primeiro examina as tabulações cruzadas entre cada um dos campos de entrada e o resultado, e testa a significância usando um teste de independência qui-quadrado. Se mais de uma dessas relações forem estatisticamente significativas, o CHAID selecionará o campo de entrada que for mais significativo (menor valor de  $p$ ). Se uma entrada tiver mais de duas categorias, elas serão comparadas e as categorias que não mostrarem diferenças no resultado serão reduzidas juntas. Isso é feito ao unir sucessivamente o par de categorias que mostrarem a diferença menos significativa.

Esse processo de mesclagem de categoria para quando todas as categorias restantes diferirem no nível de teste especificado. Para campos de entrada nominal, quaisquer categorias podem ser mescladas e, para um conjunto ordinal, apenas categorias contínuas podem ser mescladas.

O CHAID pode gerar árvores não binárias, significando que algumas divisões possuem mais de duas ramificações. Isso, portanto, tende a criar uma árvore mais

larga do que os métodos de crescimento binários. O CHAID funciona para todos os tipos de entradas e aceita ambas as ponderações de caso e variáveis de frequência.

Nesse método pode-se gerar árvores não binárias, o que significa que algumas divisões têm mais de duas ramificações. Os campos de destino e de entrada podem ser um intervalo numérico (contínuo) ou categóricos.

Baseado no Teste de qui-quadrado (M2) o método CHAID acumula os desvios quadrados padronizados entre as frequências observadas e as frequências esperadas, sendo calculado pela Equação (39) proposta por Karl Pearson (Rodrigues, 2005):

$$\chi^2 = \sum_i \left[ \frac{(O_t - O_E)^2}{E_t} \right], \quad (39)$$

onde:  $t$  é a célula da tabela de contingência;  $O_t$  é a frequência observada na célula; e  $E_t$  é a frequência esperada da célula.

Quanto maior o valor de  $\chi^2$ , maior será a probabilidade de as frequências observadas estarem divergindo das frequências esperadas. Dessa forma, valores elevados indicam dependência, ou seja, interações entre a variável resposta e as variável explicativa.

A frequência esperada pode ser definida como:

$$E = \frac{l \times c}{n}, \quad (40)$$

onde:  $l$  total marginal da linha;  $c$  total marginal da coluna; e  $n$  total.

A estatística qui-quadrado tem distribuição com Graus de Liberdade (GL) ou nível de significância que representa a máxima probabilidade de erro que se tem ao rejeitar uma hipótese é calculado pela:

$$G_L = (m - 1) \times (n - 1) \quad (41)$$

onde:  $m$  - Número de linhas da tabela de contingência;  $n$  - Número de colunas da tabela de contingência.

A confirmação da relação entre as variáveis é realizada através da comparação entre a estatística de teste e o valor crítico da distribuição, que é determinado pelo nível de significância, conhecido como *p-value*, geralmente 5%, e pelos Graus de Liberdade da estatística. Se a estatística de teste for maior que o valor crítico, que é

o valor tabelado para o qui-quadrado, então a hipótese alternativa de que há uma relação entre as variáveis é aceita.

O método CHAID classifica as categorias semelhantes da variável explicativa que é submetida ao teste, a partir das categorias anteriores da variável que é submetida ao CHAID em relação à variável resposta. Como a variável explicativa pode ter muitas categorias, a questão é identificar quais podem ser agrupadas. Para tanto, o método cria uma tabela cruzada para cada par de categorias anteriores da variável explicativa.

Um teste para cada tabela cruzada é realizado, calculando-se a estatística  $\chi^2$  e o *p-value*, para cada par de categorias em questão, o par de categorias que apresenta o maior valor dentro da distribuição  $\chi^2$  é então agrupado. O processo se repete até o ponto que nenhuma das categorias restantes possa ser considerada homogênea. Caso o valor de significância seja abaixo do qual uma variável é significativa para ser considerada preditora, a variável é desconsiderada.

São adotadas como condição de parada situações como, o fato de não existirem mais variáveis independentes a serem avaliadas, profundidade máxima da árvore foi alcançada ou todos os registros no nó têm o mesmo valor para todos os campos preditores utilizados pelo modelo.

### 3.5.3.3 Árvore XGBoost (*Extreme Gradient Boosting*)

O modelo de Árvore XGBoost é uma implementação avançada de um algoritmo de impulsionamento de gradiente com um modelo de árvore como o modelo base. O princípio deste modelo consiste em Impulsionar algoritmos iterativamente, aprender classificadores fracos e, em seguida, adicioná-los a um classificador forte final.

Segundo Xing, Tiang e Peng (2022) árvore de decisão XGBoost, como uma técnica de aprendizado de máquina, é capaz de fornecer previsões precisas para conjuntos de dados tabulares com uma boa interpretabilidade de previsão. Xie et al. (2020) afirma que este método é uma versão avançada do algoritmo de aumento de gradiente e foi projetado para alcançar não apenas alta precisão, mas também baixo risco de *overfitting*.

O gradiente *boosting* é uma das técnicas mais poderosas para construção de modelos preditivos e pode ser interpretado como um algoritmo de otimização em uma função objetivo adequada (Friedman, 2001). O aumento de gradiente contém três

elementos principais, que são uma função de perda a ser otimizada, um modelo fraco para fazer previsões e um modelo aditivo para adicionar modelos fracos para minimizar a função de perda. Este modelo envolve um procedimento iterativo no qual os parâmetros da etapa subsequente são atualizados com base no resíduo da etapa anterior para otimizar a função objetivo.

Segundo Hoan (2021), como uma melhoria de um algoritmo simples de aumento de gradiente, a regularização é adicionada à função objetivo com uma função de perda para superar o sobreajuste. A função objetivo ( $J$ ) do modelo é expresso como

$$J(\theta_G) = L(\theta_G) + \Omega(\theta_G) \quad (42)$$

Onde  $\theta_G$  denota os parâmetros treinados e  $L(\theta_G)$  a função de perda de treinamento, que é usada para avaliar a previsão do modelo. O termo de regularização é denotado como  $\Omega(\theta_G)$ , que controla a complexidade do modelo. No modelo ensemble, as pontuações de predição de todas as árvores são somadas para obter a pontuação final. Equação (43) expressa a saída do modelo, ou seja,  $\hat{y}_i$ :

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (43)$$

$x_i$  é o vetor de variáveis de entrada com  $i$  número de entradas,  $K$  é o número de árvores,  $f_k$  denota a função de pontuação de uma estrutura de árvore independente para estimar a saída no espaço funcional  $F$ , e  $F$  é o conjunto de todas as árvores de classificação e regressão possíveis (CARTs). A função objetivo do modelo é expressa como:

$$J(\theta) = \sum_{i=1}^N L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (44)$$

onde  $N$  é o número de previsões. Durante a etapa de reforço, a previsão  $\hat{y}_i$  na  $t$ -ésima iteração é expressa como:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \epsilon f_t(x_i) \quad (45)$$

Onde  $\epsilon$  é chamado de tamanho do passo ou taxa de aprendizagem. Portanto, a função objetivo na rodada  $t$  pode ser escrita como:

$$J^{(t)} = \sum_{i=1}^N L\left(y_i, \hat{y}_i^{(t-1)} + \epsilon f_t(x_i)\right) + \Omega(f_t) \quad (46)$$

O termo de regularização na rodada  $t$ , é definido como

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2, \quad (47)$$

onde  $T$  é o número de folhas da árvore,  $w_j$  é o peso da  $j$ -ésima folha,  $\lambda$  e  $\gamma$  são os parâmetros do termo de regularização para controlar a complexidade de cada folha e dimensionar a penalidade, respectivamente.

Na prática, a árvore cresce avidamente e divide uma folha em duas. De acordo com Hoan (2021) a Eq. (48) é utilizada para pontuar um nó folha durante a divisão. Esta fórmula é composta por quatro termos, que por sua vez representam as pontuações da nova folha esquerda ( $G_L$ ), nova folha direita ( $G_R$ ), folhas originais esquerda e direita ( $H_L, H_R$ ), e a regularização da folha adicional.

$$Gain = \frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} + \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (48)$$

A árvore para de crescer quando o ganho se torna menor que  $\gamma$ .

#### 3.5.4 Redes Neurais MLP (*Multi-layer Perceptron*)

Uma rede neural pode aproximar uma ampla gama de modelos preditivos com demandas mínimas na estrutura e suposição do modelo. O formato dos relacionamentos é determinado durante o processo de aprendizado. Se um relacionamento linear entre o destino e os preditores for apropriado, os resultados da rede neural deverão ficar muito próximos dos resultados de um modelo linear tradicional. Se um relacionamento não linear for mais apropriado, a rede neural aproximará automaticamente a estrutura de modelo "correta".

Xuan et al. (2023), afirma que a adversidade para essa flexibilidade é que a rede neural não é facilmente interpretável. Se a capacidade de interpretação do modelo não for importante, será possível obter boas predições utilizando uma rede neural.

Redes Neurais são modelos simples do modo com que o sistema nervoso opera. As unidades básicas são neurônios, que normalmente são organizados em camadas (Brandic, 2024).

De acordo com Kufel (2023) uma rede neural é um modelo simplificado da maneira com que o cérebro humano processa informações. Ele funciona ao simular

muitas unidades de processamento interconectadas que lembram versões de neurônios abstratas.

As unidades de processamento são organizadas em camadas. Geralmente há três partes em uma rede neural: uma camada de entrada, com as unidades representando os campos de entrada, uma ou mais camadas ocultas e uma camada de saída, com uma unidade ou unidades representando um ou mais campos de destino. As unidades são conectadas com intensidades (ou ponderações) de conexão variadas. Os dados de entrada são apresentados na primeira camada e os valores são propagados de neurônio para neurônio na próxima camada. Por fim, um resultado é entregue a partir da camada de saída.

Esse método aprende através da análise dos registros individuais, das previsões para cada registro e de ajustamentos nas ponderações sempre que uma previsão incorreta é realizada. A rede continua a melhorar suas previsões até que um ou mais critérios de parada tenham sido atendidos.

O treinamento continua em pelo menos um ciclo (passagem de dados) e poderá ser interrompido quando o tempo máximo de treinamento for excedido, o número máximo de ciclos de treinamento for excedido ou quando a precisão mínima especificada for alcançada. O algoritmo de treinamento também parará se o erro no conjunto de prevenção ao super ajuste não diminuir após cada ciclo.

Inicialmente, todas as ponderações são aleatórias e as respostas vindas da rede provavelmente não têm sentido. A rede aprende por meio de treinamento. De acordo com Kufel (2023), os exemplos para os quais a saída é conhecida são repetidamente apresentados à rede e as respostas que ela fornece são comparadas com os resultados conhecidos. As informações a partir desta comparação são transmitidas de volta por meio da rede, alterando gradualmente as ponderações. Conforme o treinamento progride, a rede se torna cada vez mais precisa em replicar os resultados conhecidos. Depois de treinada, a rede pode ser aplicada em casos futuros nos quais o resultado é desconhecido.

### **3.6 Problemas de múltiplas saídas**

Um problema de múltiplas saídas é um problema de aprendizado supervisionado com várias saídas para prever, ou seja, quando  $Y$  é uma matriz  $2d$  de

forma  $(n_{amostras}, n_{saídas})$  onde  $n_{amostras}$  consiste nos valores conhecidos e  $n_{saídas}$  os valores a prever.

Quando não existe correlação entre os resultados, n modelos independentes devem ser construídos, um para cada produto, cada modelo prevendo, independentemente, cada um dos n resultados. No entanto, onde os valores de saída estão relacionados com a mesma entrada, um modelo único capaz de prever simultaneamente todos os n resultados se mostra mais viável. Uma das vantagens de um único modelo é que, nesse caso, requer-se menor tempo de treinamento, uma vez que apenas um único estimador é construído. A precisão da generalização do estimador resultante pode muitas vezes ser aumentada.

No que diz respeito às árvores de decisão, esta estratégia pode ser facilmente utilizada para apoiar problemas de múltiplos resultados. Isso requer as seguintes alterações:

- Armazene n valores de saída em folhas, em vez de 1;
- Use critérios de divisão que calculem a redução média em todos os n resultados.

### 3.7 Considerações sobre o capítulo

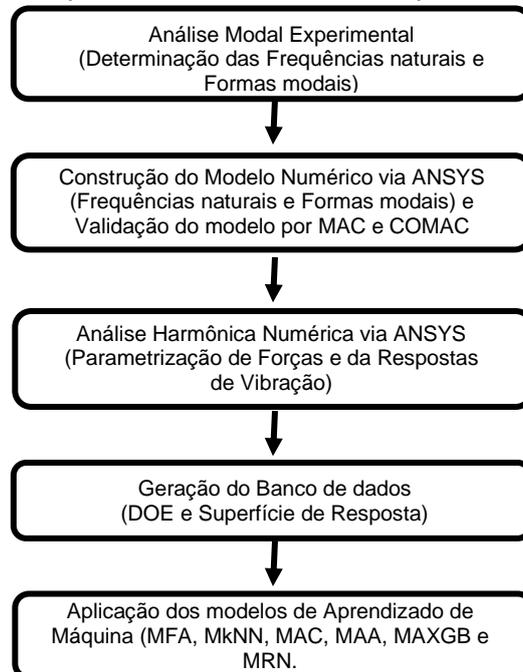
Neste capítulo foram tratados os principais bases teóricas que subsidiaram esta tese. Primeiro apresentou-se a metodologia DOE, demonstrando o uso do método de superfície de resposta com delineamento composto central. Abordou-se também a metodologia de correlação dos modelos experimentais e teóricos como pré-requisito para validação dos modelos em MEF. Em seguida, foi apresentado a teoria referente a análise numérica em elementos finitos que será realizada no *software Ansys®*. Por fim, foi apresentado a fundamentação teórica referente às metodologias de Florestas Aleatórias, *k-Nearest Neighbor*, Árvore Aleatória, Árvore CHAID, árvore XGBoost e Redes Neurais MLP.

No capítulo 4 será apresentada a metodologia utilizada nesta tese para a obtenção dos objetivos propostos, iniciando pelo fluxograma das etapas fundamentais realizadas para a obtenção do objetivo do trabalho, que será detalhada nas seções subsequentes, finalizando com a apresentação dos métodos utilizados para a avaliação dos modelos de aprendizado de máquinas.

## 4 METODOLOGIA

Este trabalho se propõe a resolver a identificação de sistemas multiferças através da resolução de um problema inverso, onde, a partir dos dados de vibração, obtém-se as forças atuantes no Sistema. Um fluxograma foi criado para facilitar o entendimento do processo metodológico o qual é apresentado na Figura 4. O fluxograma apresenta a metodologia usada para identificação das forças de excitação em detrimento das respostas de vibração geradas por um modelo numérico computacional em MEF.

Figura 4 – Fluxograma das etapas fundamentais realizadas para a obtenção do objetivo do trabalho.



Fonte: Elaborada pelo autor do trabalho.

Primeiramente foi realizado uma análise modal experimental em laboratório, com a finalidade de determinar as frequências naturais e formas modais associadas da estrutura. A partir do modelo experimental, um modelo computacional foi gerado e calibrado pelos resultados experimentais. O modelo foi então validado pelo MAC e COMAC.

A análise harmônica do modelo numérico em MEF foi então realizada, contemplando 49 pontos de aplicação de forças, com a determinação da aceleração média dos 49 pontos a cada nova posição da força.

Para a extrapolação dos resultados foi utilizado o DOE e SRM. Esse procedimento permite tornar o banco de dados muito mais robusto. O banco de dados foi então utilizado para avaliar os modelos de regressão: Modelo de Floresta Aleatória, Modelo *k-Nearest Neighbor*, Modelo de Árvore CHAID, Modelo de Árvore Aleatória, Modelo de Árvore XGBoost e Modelo de Rede Neural MLP.

A avaliação do desempenho de cada método de Machine Learning foi feita através do coeficiente de determinação ( $R^2$ ), do erro relativo médio e do tempo de processamento. Cada etapa realizada é apresentada no fluxograma da Figura 4 e detalhada, nas seções que se seguem.

## 4.1 Análise experimental

### 4.1.1 Análise modal experimental

A análise modal é um processo através do qual pode-se descrever uma estrutura em termos de suas características naturais: as frequências naturais, os fatores de amortecimento e as formas modais, ou seja, suas propriedades dinâmicas.

Para tanto, é necessário que o sistema seja excitado, sua resposta adquirida e os dados tratados, para que então, as propriedades possam ser obtidas através de métodos de extração de parâmetros modais.

Comumente, excitadores do tipo martelo de impacto ou excitadores de vibração são utilizados para excitar o sistema e dispositivos como: acelerômetros, vibrômetros ou medidores de deslocamentos, que são utilizados para quantificar a resposta do sistema.

Geralmente, dados no domínio do tempo fornecem informações muito úteis, porém, é conveniente manusearmos os dados que estão no domínio do tempo e transformá-los para o domínio da frequência, utilizando artifícios como a transformada de Fourier, onde obtêm-se a Função Resposta em Frequência (FRF) e através de métodos de extração modal, determinar as propriedades dinâmicas do sistema.

Dependendo da quantidade medida, um instrumento de medição de vibração é denominado de acelerômetro, vibrômetro ou medidor de deslocamento. Os medidores de deslocamento atuais são baseados no princípio da variação do campo magnético entre a estrutura e o sensor, sendo indicado para superfícies ferromagnéticas, sendo sua aplicação recomendada para grandes deslocamentos. Os

acelerômetros e vibrômetros são dispositivos baseados no princípio mecânico da ressonância, mas distinguem-se quanto à grandeza medida, pois os acelerômetros são recomendados para fenômenos onde há pequenos deslocamentos, já o vibrômetro é mais aplicado em fenômenos que possuem amplitudes intermediárias.

Entre os demais sensores, o acelerômetro é aquele que possui maior aplicação para medição de vibração, até mesmo nos casos em que a grandeza de interesse é o deslocamento ou a velocidade, uma vez que, eletronicamente, a integração é mais simples que a derivação temporal do sinal medido. Entretanto, a aplicação de um acelerômetro depende da sua faixa de medição e de sua sensibilidade à excitação.

A impedância de entrada e resposta em frequência do condicionador de sinais, utilizado em conjunto com o acelerômetro, é um fator que norteia o limite inferior da medição, a menos que, o condicionador seja específico para trabalhar em baixas frequências, assim a resolução da medição é influenciada pela impedância interna do acelerômetro.

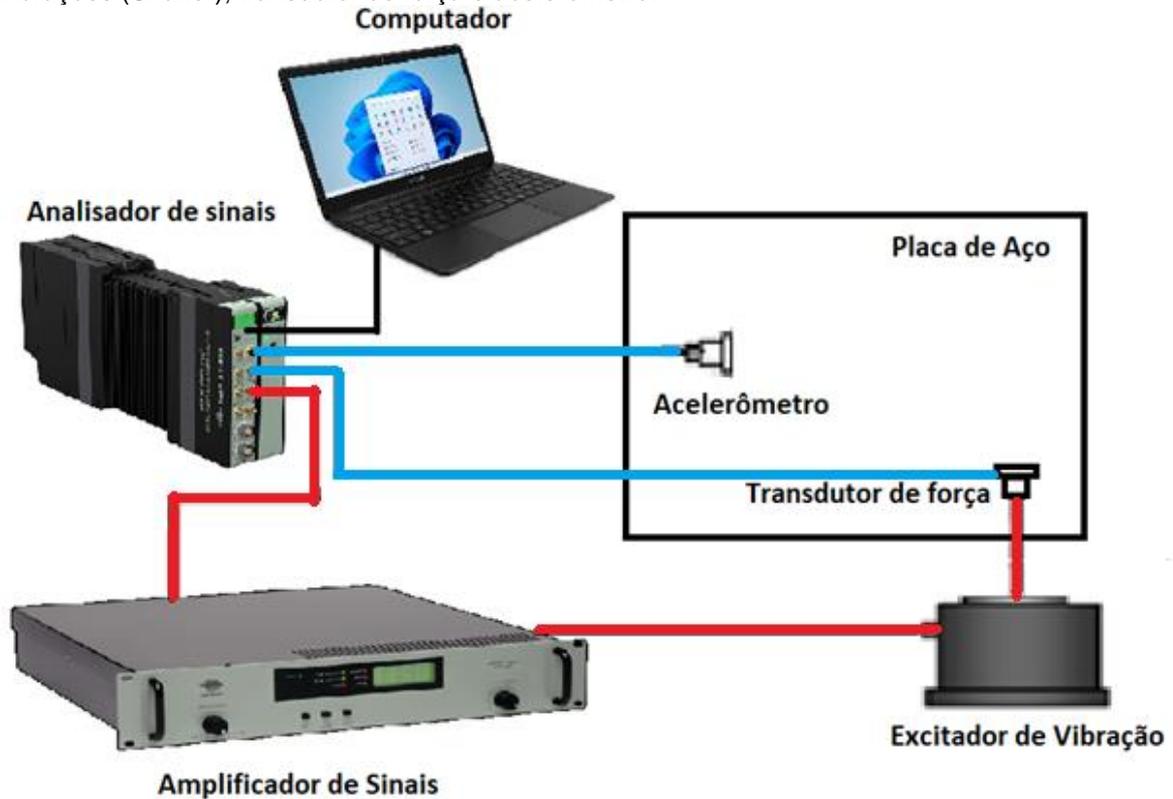
Ruídos, erros nos procedimentos de medição e nas localizações de sensores, falhas no processamento digital, dentre outros, são fatores que prejudicam a qualidade dos dados obtidos experimentalmente, dificultando a atuação dos processos posteriores de identificação de parâmetros modais (Setúbal, 2022). Outros fatores também cooperam para a vulnerabilidade das medições, como o ruído nos cabos, a umidade atmosférica, a fixação, radiação, temperatura e a sensibilidade transversal do acelerômetro. Onde a sensibilidade transversal consiste na imperfeição de montagem do acelerômetro, onde a direção de seu eixo sensível a vibração deixa de ser perpendicular à superfície de referência. Assim, durante uma medição, esta imperfeição promove o surgimento do sinal contaminado pela vibração, na direção paralela à superfície de referência. Sendo assim, tais influências desses fatores devem ser eliminadas na medida do possível, tendo em vista que algumas delas estarão sempre presentes nas medições.

Nesse trabalho, o método de extração de parâmetros modais foi realizado no domínio da frequência, com base nas funções respostas medidas, com medição tanto da força aplicada ao sistema, mediante o uso de uma célula de carga aplicada ao excitador de vibração, bem como sua resposta, com a utilização de acelerômetro varrendo a estrutura.

Um esquema básico do sistema de medição utilizado, com capacidade de gerar vibrações (em vermelho) e de capturar sinais de força e de resposta (em azul), é

apresentado na Figura 5. A cadeia de experimento é composta por gerador interno de sinais da placa do microcomputador, amplificador de potência e excitador de vibração, transdutores, pré-amplificadores e placa de aquisição do analisador.

Figura 5 – Sistema básico de medição usado na análise modal experimental usando o excitador de vibrações (Shaker), transdutor de força e acelerômetro.



Fonte: Elaborada pelo autor do trabalho.

No esquema de medição apresentado na Figura 5, é mostrado o uso de um computador com placa de aquisição de sinais, permitindo uma saída e duas entradas de sinais. O sinal proveniente da saída precisou ser amplificado, por meio de um amplificador de potência, para então, alimentar o excitador de vibração (*shaker*).

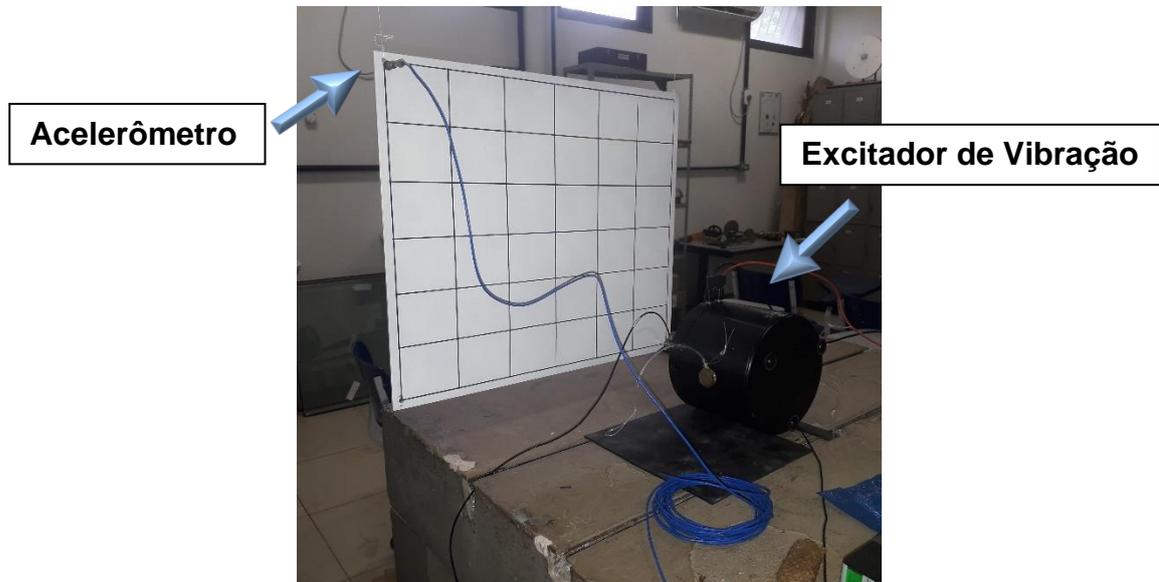
Na ligação mecânica entre o excitador de vibração e a estrutura foi utilizado um transdutor de força, com a finalidade de gerar um sinal elétrico proporcional à força aplicada na estrutura. Apesar de que o sinal de força fornecido para o excitador de vibração seja definido pelo usuário, e, portanto, supostamente conhecido, é importante que seja adquirido o sinal de força por meio de um transdutor de força, entre outros fatores, permitindo a determinação da fase do sinal e para eliminação da influência de possíveis perdas na conexão com o sistema.

Na captação do movimento foi utilizado um acelerômetro (piezoelétrico), que, como dito, gera um sinal elétrico proporcional à aceleração do ponto ao qual está montado.

Para a realização do ensaio, uma placa de aço com dimensões de 420 mm x 360 mm e 3 mm de espessura foi fixada suspensa por fios flexíveis (nylon). Como a suspensão é bastante flexível, o conjunto suspensão/corpo rígido apresenta frequências naturais, associada aos modos de corpo rígido, bastante baixas, porém, ainda distantes das frequências naturais correspondentes aos modos reais de vibração. Para essa configuração na forma de pêndulo, pode-se aproximar a estrutura como se fosse um pêndulo simples, obtendo então a frequência natural  $\omega_n = \sqrt{g/l}$ , onde  $g$  é a aceleração da gravidade e  $l$  é o comprimento efetivo do cabo, do ponto superior de fixação ao centro de gravidade da massa.

Uma malha de medição com um offset de 10 mm das bordas, foi desenhada na chapa, contemplando 49 pontos de medições. Cada ponto foi espaçado um do outro por uma distância de 66,2 mm, na horizontal, e de 56,7 mm, na vertical, sendo, portanto, sete linhas e sete colunas. A força de excitação foi posicionada de forma fixa no ponto 49, por ser um local que consegue excitar uma quantidade maior de modos. Com o acelerômetro foram feitas medidas em cada interseção das linhas horizontais com as verticais nas localizações 1 a 49, mudando sua fixação a cada medição, seguindo a sequência numérica que será apresentada mais adiante (Figura 9). A chapa com o acelerômetro no ponto 1 e excitador de vibração no ponto 49 é mostrado na figura 6.

Figura 6 - Modelo experimental: chapa suspensa com o acelerômetro no ponto 1 e excitador de vibração no ponto 49.



Fonte: Elaborada pelo autor do trabalho.

Os 49 pontos foram estabelecidos na parte frontal da chapa, iniciando de cima para baixo e da esquerda para direita (ver Figura 6), selecionados para a medição da vibração. A direção da excitação e das respostas é perpendicular à superfície da chapa.

Ainda na Figura 6 pode-se observar o sistema de medição constituído de um acelerômetro (PCB 353B16), um sensor de força (B&K 8001) tipo célula de carga e um excitador de vibração (B&K 4809). Um amplificador de sinais (B&K 2716), um analisador de sinais (B&K 3160-B-042) com *software Pulse Labshop* e um *notebook*, podem ser visualizados na Figura 7.

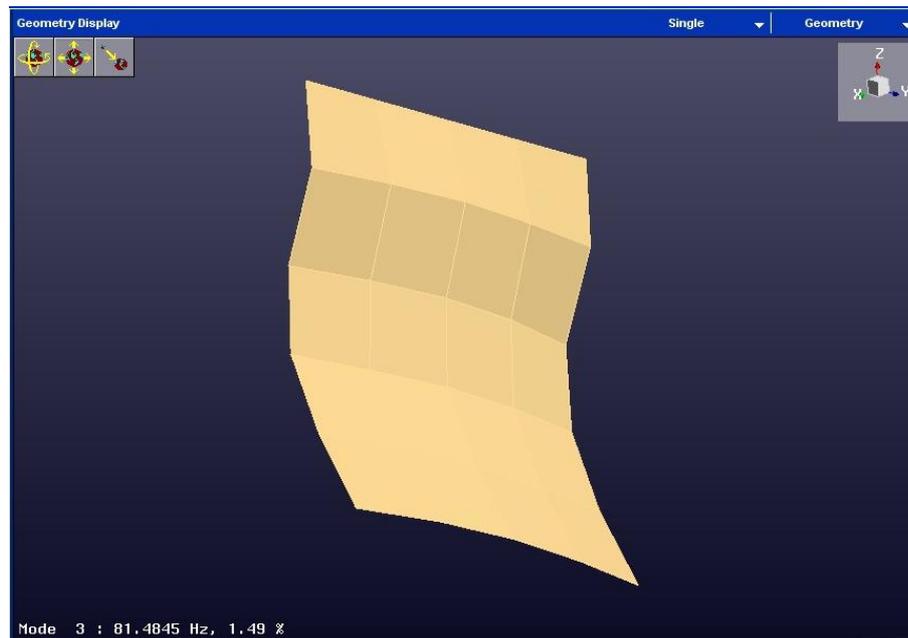
Figura 7 - Aparato experimental: amplificador de sinais (B&K 2716), um analisador de sinais (B&K 3160-B-042) e um notebook com software Pulse Labshop.



Fonte: Elaborada pelo autor do trabalho.

Através da análise modal experimental, foram determinados os valores das frequências naturais do sistema, os quais serviram para validar o modelo numérico computacional. Esse procedimento será descrito com maiores detalhes no Capítulo 4.2. As FRF's do tipo inércia, foram extraídas com o espectro cruzado entre um acelerômetro móvel e o sensor de força (célula de carga). A unidade da inércia no sistema internacional é  $m/Ns^2$ . Os parâmetros modais foram extraídos com o uso do *software TestLab*. Este *software* extrai os parâmetros modais de uma estrutura, em função das FRF's extraídas. Foram fornecidas as FRF's salvas em um arquivo universal com extensão do tipo \*.uff. Com isso, é possível visualizar a FRF dos pontos da malha e a média de todas elas, bem como as frequências naturais e as formas modais extraídas através da análise das bandas de frequências. Na figura 8 é mostrado o modo de vibração gerado pelo *software TestLab*, referente a frequência 81,48 [Hz] e amortecimento modal 1,49%.

Figura 8 - Modo de vibração gerado pelo software TestLab, referente a frequência 81,48 [Hz] e amortecimento modal 1,49%.



Fonte: Elaborada pelo autor do trabalho.

Os modelos modais foram extraídos pelo *software TestLab*, que usa como base o método *POLYMAX* de extração dos parâmetros modais. Através da modelagem da chapa, é possível, com os dados experimentais, verificar a maneira como a estrutura em análise se comporta em função da frequência e verificar quais as frequências naturais da chapa.

## 4.2 Análises numéricas com elementos finitos

Esta seção do capítulo tem como objetivo a criação do modelo numérico computacional da chapa usando o Método de Elementos Finitos (MEF) com o uso do *software ANSYS*. Através dos resultados da análise modal experimental, dos dados e parâmetros da chapa e dos resultados obtidos pelo *software TestLab*, o modelo computacional numérico foi construído, calibrado, onde os valores das frequências naturais e formas modais associadas, foram utilizados para esse fim.

### 4.2.1 Análise modal numérica

O processo de análise por elementos finitos deve seguir uma ordem, que consiste no pré-processamento, onde são definidos a geometria e os parâmetros do

sistema, a escolha do tipo de elemento a ser utilizado, criação da malha, atribuição das condições de contorno e definição do tipo de análise; após, tem-se a etapa de solução, onde é definido o tipo de solução a ser utilizado. O método a ser escolhido depende, primeiramente, do tamanho do modelo e da aplicação em particular. Para a solução da análise modal foi utilizado o método *Block Lanczos* que é usado tipicamente em modelos complexos em que há mistura de elementos sólido/casca/viga etc, permite a extração eficiente de grande número de modos (mais de 40 modos), apresenta uma extração eficiente de modos numa faixa de frequência e manipula bem os modos de corpo rígido. Além disso, foi adotado, também, o modelo de superposição modal para extração dos modos, no qual as formas modais foram expandidas e utilizadas nas análises harmônicas descritas na próxima seção; por fim, tem-se os pós-processamentos, onde é feito o tratamento dos resultados obtidos.

Para a realização da análise modal numérica, deve-se primeiro criar um modelo computacional que apresente as características do modelo real, como a geometria e propriedades do material. Para tanto, foi determinado a densidade do material com base no volume e massa da chapa, sendo o módulo de elasticidade colocado inicialmente como uma aproximação, com posterior adequação de acordo com as frequências naturais determinadas pela análise modal experimental realizada. Os valores adotados para as propriedades da chapa após a calibração do modelo são mostrados na tabela 3.

Tabela 3 – Propriedades do aço usadas nos modelos numéricos.

<b>Propriedades do aço</b>	
Módulo de <i>Young</i>	200 GPa
Massa específica	8135 kg/m <sup>3</sup>
Coefficiente de <i>Poisson</i>	0,3

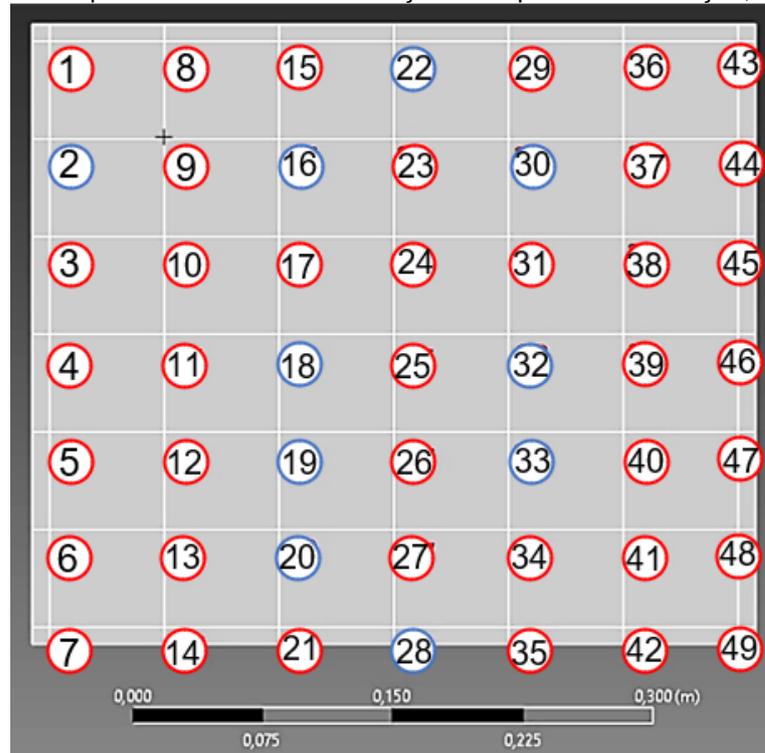
Fonte: Elaborada pelo autor do trabalho.

Durante a construção da geometria da chapa, também foram criados pontos que representam as posições em que foram medidas as respostas de vibração da chapa, dessa forma, as respostas geradas pelo modelo computacional deverão apresentar maior fidedignidade com relação ao modelo real, conforme figura 9.

Para a criação do modelo em elementos finitos da chapa, utilizou-se o elemento SHELL181, que se adequa muito bem as características do sistema avaliado (ver seção 3.4.4). Na Figura 10, pode ser vista a geometria do modelo com detalhe para a

discretização utilizada, de acordo com a malha de medição realizada experimentalmente na chapa.

Figura 9 - Geometria computacional com as localizações dos pontos de medição;

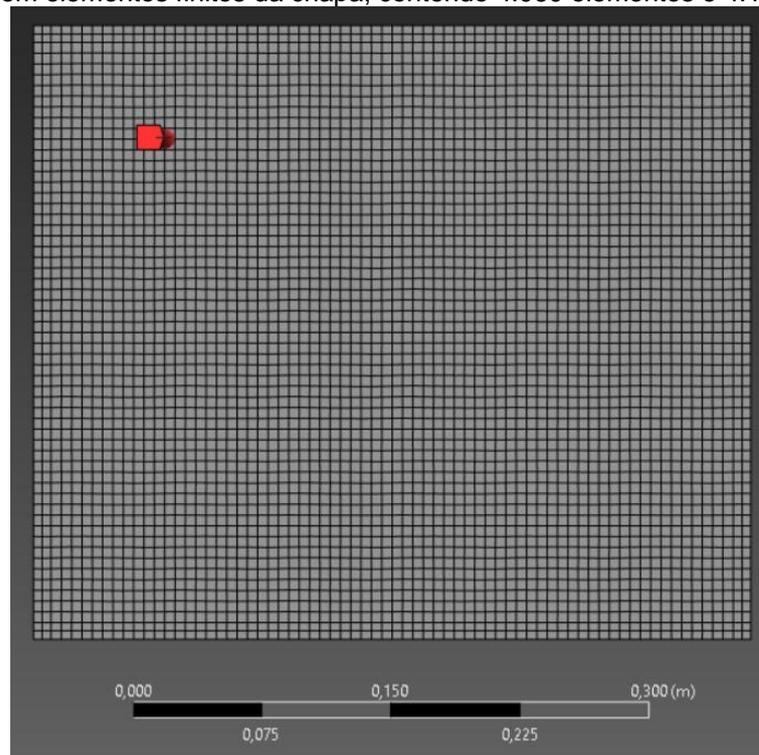


Fonte: Elaborada pelo autor do trabalho.

Os pontos destacados em azul na figura 9, representam os pontos indispensáveis para a caracterização do sistema, esses detalhes serão detalhados na seção de resultados.

Como condição de contorno foi adotado a condição livre – livre, de forma a simular a condição adotada na análise modal experimental. Foi realizado também uma análise de convergência de malha, onde a malha adotada dispõe de 4.060 elementos e 4.129 nós, conforme mostrada na Figura 10.

Figura 10 - Malha em elementos finitos da chapa, contendo 4.060 elementos e 4.129 nós.



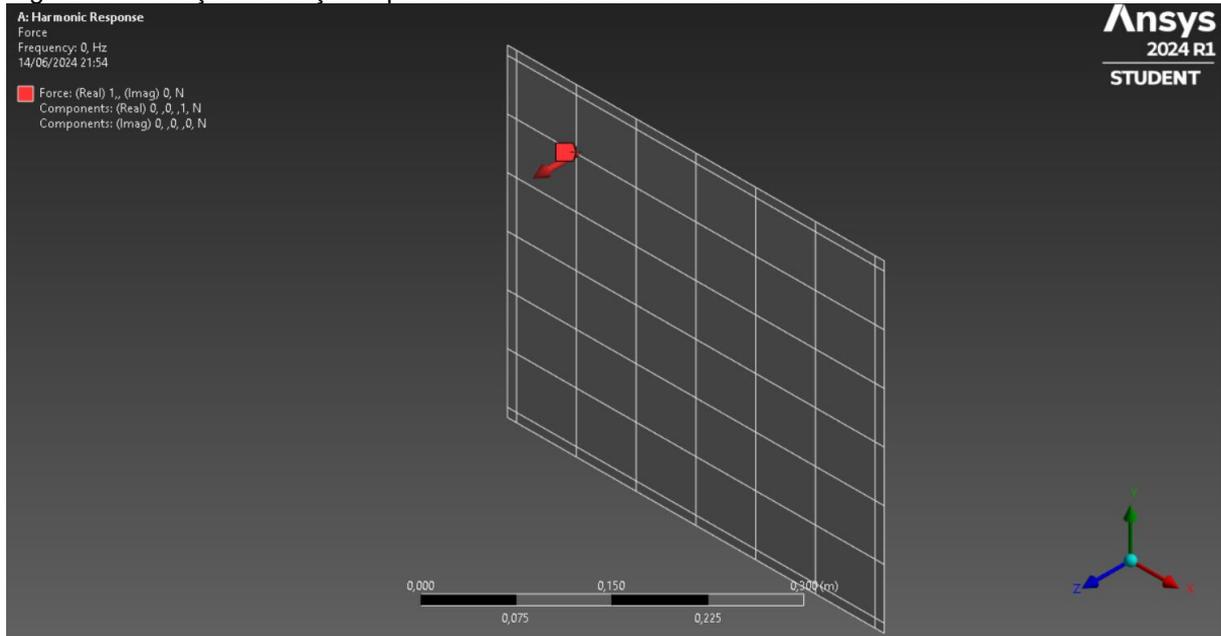
Fonte: Elaborada pelo autor do trabalho.

O modelo foi validado de acordo com o MAC e COMAC. Esse modelo validado, permitirá a construção do banco de dados, que será realizado a partir da análise harmônica em conjunto com o DOE e SRM.

#### 4.2.2 Análise harmônica numérica

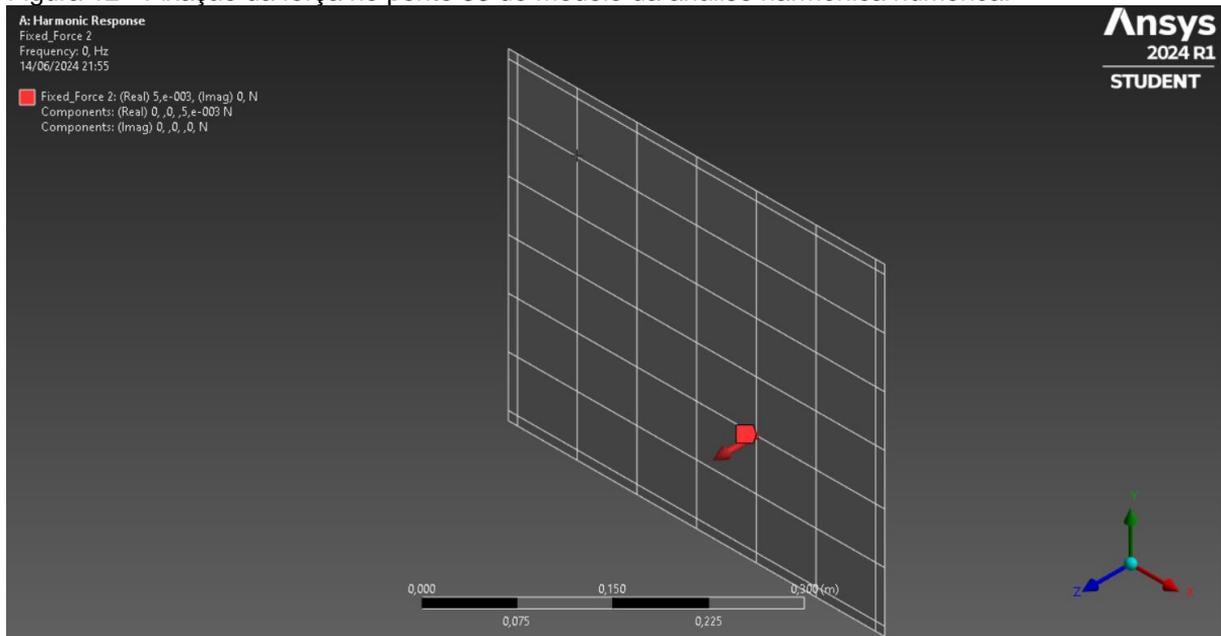
Após a calibração do modelo modal numérico com os resultados da análise modal experimental, realizou-se as análises harmônicas. Uma força foi inserida em cada ponto da malha de simulação (49 pontos), perpendicular ao plano do modelo (direção Z), mudando de posição após cada aquisição de dados, de forma a contemplar toda a malha de medição, criada com base no modelo experimental. Para cada fixação da força em determinado ponto, uma análise harmônica foi realizada. Nas Figuras 11 e 12 podem ser observadas as fixações das forças nos pontos 9 e 33, respectivamente, com a aplicação de uma força.

Figura 11 - Fixação da força no ponto 9 do modelo da análise harmônica numérica.



Fonte: Elaborada pelo autor do trabalho.

Figura 12 - Fixação da força no ponto 33 do modelo da análise harmônica numérica.

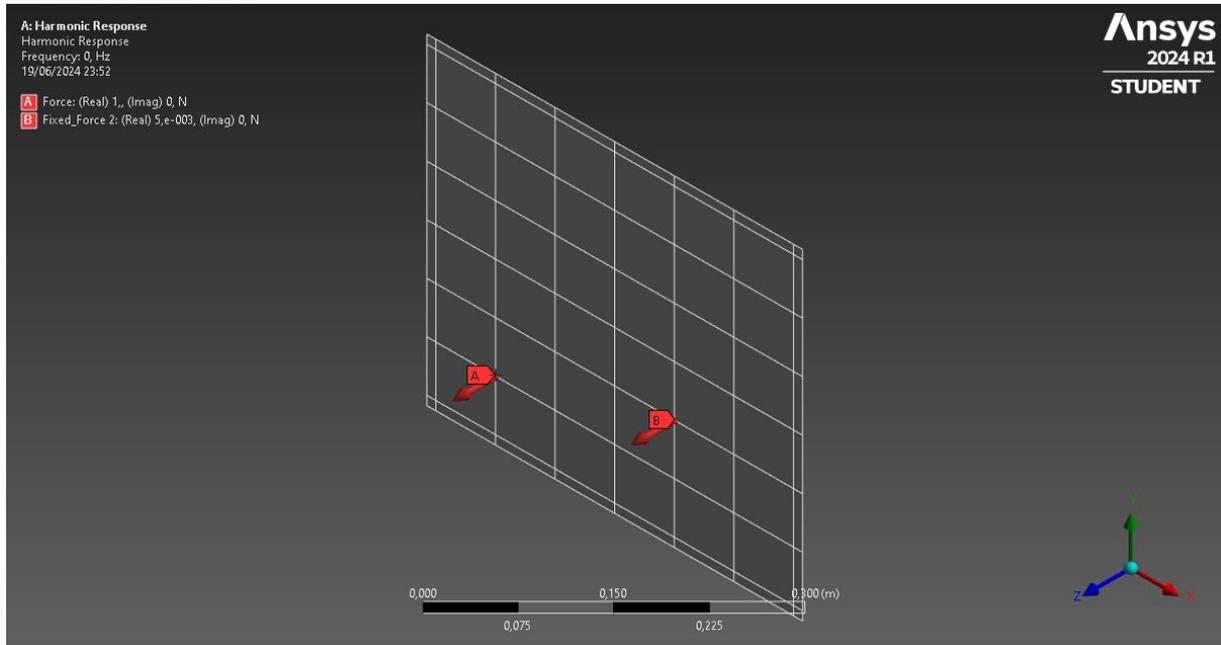


Fonte: Elaborada pelo autor do trabalho.

Após varrer todos os 49 pontos, uma segunda força foi fixada no ponto 33, com magnitude 5mN, e outra força varreu então os 49 pontos novamente. As forças foram aplicadas de forma perpendicular ao plano do modelo (direção Z), mudando de posição apenas uma das forças após cada aquisição de dados, de forma a contemplar toda a malha de medição (49 pontos), criados com base no modelo experimental, mantendo a força do ponto 33 fixa. Para cada posição da força, uma análise

harmônica foi realizada e 49 resultados de vibração aquirisitado. Na Figura 13, pode ser observadas as fixações das forças durante para a análise com duas forças.

Figura 13 - Fixação da força fixa no ponto 33 e força móvel no ponto 13 do modelo da análise harmônica numérica.



Fonte: Elaborada pelo autor do trabalho.

### 4.3 Aplicação do Modelo de Superfície de Resposta usando *Design Exploration*

O processo descrito no capítulo anterior resultou num conjunto de dados de resposta de vibração dos 49 pontos definidos de acordo com o procedimento experimental, gerando um total de 2401 respostas. Ou seja, para cada uma das 49 posições de aplicação de força foram geradas 49 respostas de vibração, uma para cada um dos 49 pontos de análise, conforme definido no procedimento experimental, cada resposta contendo 122.500 linhas de dados, para o caso em que apenas uma força é aplicada e 122.500 linhas de dados para o caso em que duas forças são aplicadas, totalizando 245.000 linhas de dados. Dessa forma o banco de dados é composto por 245.000 linhas de dados e 53 colunas.

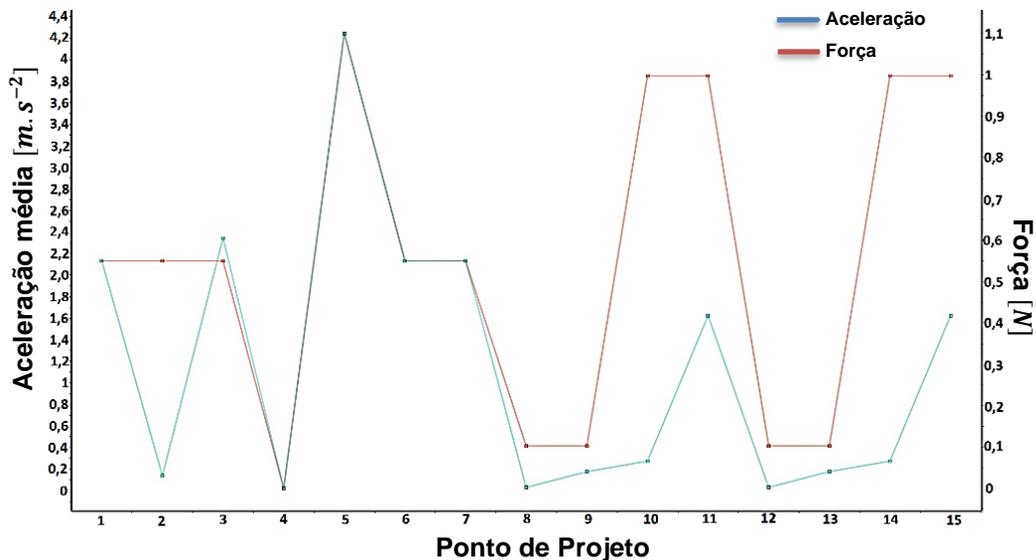
Para a correta seleção do modelo de Aprendizado de Máquina a ser utilizado é importante a compreensão da relação entre as variáveis de entrada (parâmetros das forças) e saída (aceleração média) parametrizadas. Uma forma de conhecer as relações entre essas variáveis, é usar um delineamento de experimento de superfície

de resposta, que extrapola essas informações, gerando uma superfície com as relações entre as variáveis.

O DOE utilizado foi configurado com tipo de delineamento CCD e projeto autodefinido, que otimiza o DOE com base no número de parâmetros de entrada.

Na Figura 14, é demonstrado a relação entre a magnitude de aceleração e a amplitude da força no nó 01 da malha de simulação, levando em consideração 15 configurações de projeto em análise. Devido o modelo já ter sido validado anteriormente, assume-se que esses valores configuram a reprodução da resposta gerada em laboratório. No entanto, para alimentar um modelo de aprendizado de máquina, é essencial que um banco de dados robusto esteja disponível. Porém, a construção de um banco de dados significativo, seja de forma experimental, seja através de análises harmônicas, demandaria muito esforço e tempo, o que vai de encontro com os objetivos deste trabalho. Neste sentido, o uso de superfície de resposta permitirá a interpolação dos valores nessas múltiplas dimensões, tornando o banco de dados muito mais robusto.

Figura 14 - Pontos de projeto versus parâmetros.



Fonte: Elaborada pelo autor do trabalho.

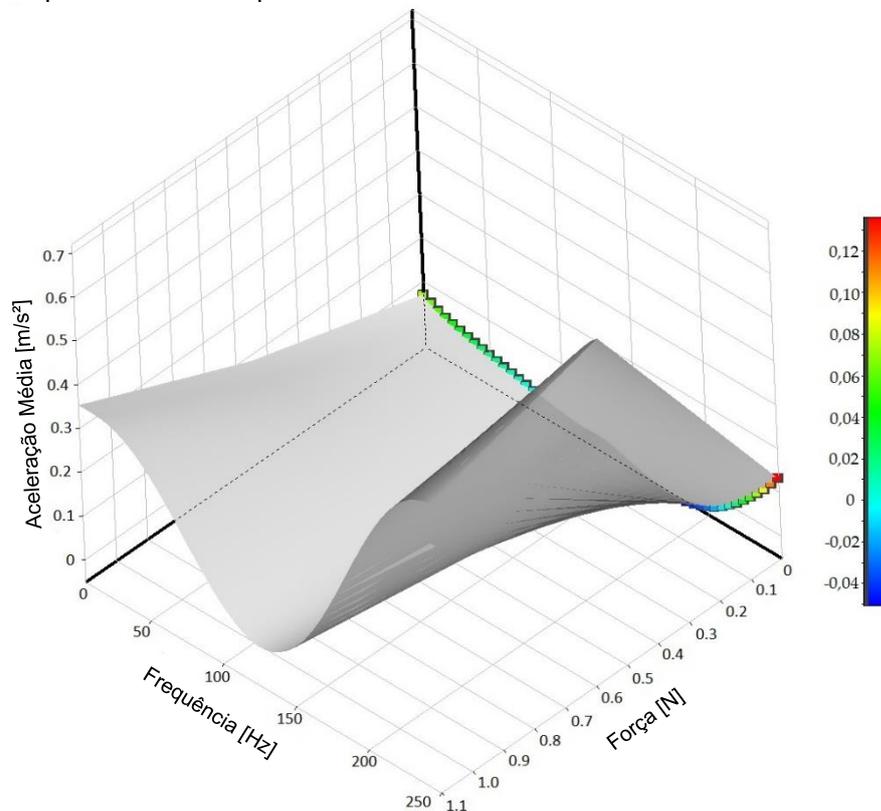
#### 4.3.1 Modelo de Superfície de resposta

Para a aplicação do modelo de Superfície de Resposta, foi utilizado um meta modelo de superfície de resposta padrão, que usa polinômios completos de segunda ordem para interpolar os valores nas múltiplas dimensões, sendo necessário apenas um refinamento manual. Para a geração da superfície de resposta, todas as demais

configurações foram mantidas na forma padrão. Na figura 15 é mostrado a superfície de resposta para aceleração no ponto 20, em função da componente de força no ponto 40 e em função da frequência.

Como na análise harmônica, a cada passo, tem-se somente um valor de amplitude da força para todas as respostas, na faixa de frequência especificada, o gráfico da superfície de resposta mostra apenas uma fileira colorida, as demais regiões são exibidas em cinza, a qual representa o espaço total interpolado pela superfície de resposta.

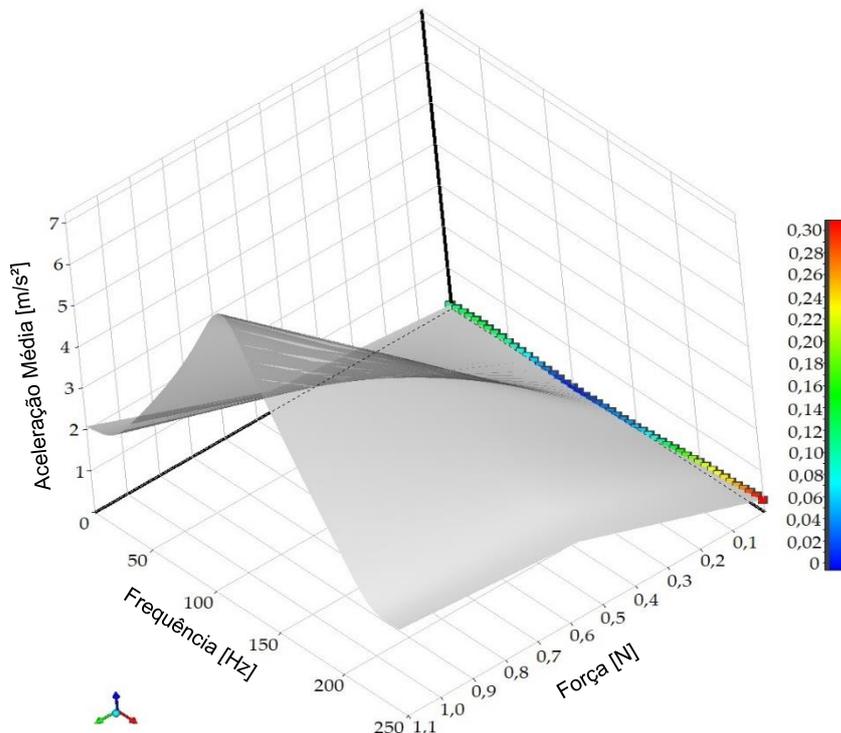
Figura 15 - Superfície de resposta para aceleração no ponto 20, em função da componente de força no ponto 40 e da frequência.



Fonte: Elaborada pelo autor do trabalho.

Na Figura 16, a superfície de resposta mostra a amplitude média da aceleração no ponto 49, em relação à componente de força no ponto 33 e em função da frequência em Hz.

Figura 16 - Superfície de resposta para aceleração no ponto 49, em função da componente de força no ponto 33 e da frequência.



Fonte: Elaborada pelo autor do trabalho.

Pela análise das Figuras 15 e 16 pode-se observar que não há linearidade entre as variáveis estudadas. O conhecimento dessa relação é importante pois permite conhecer como um parâmetro de saída selecionado muda em função das variações dos parâmetros de entrada. Dessa forma, um modelo de aprendizado de máquina não linear deve se ajustar melhor ao conjunto de dados do modelo.

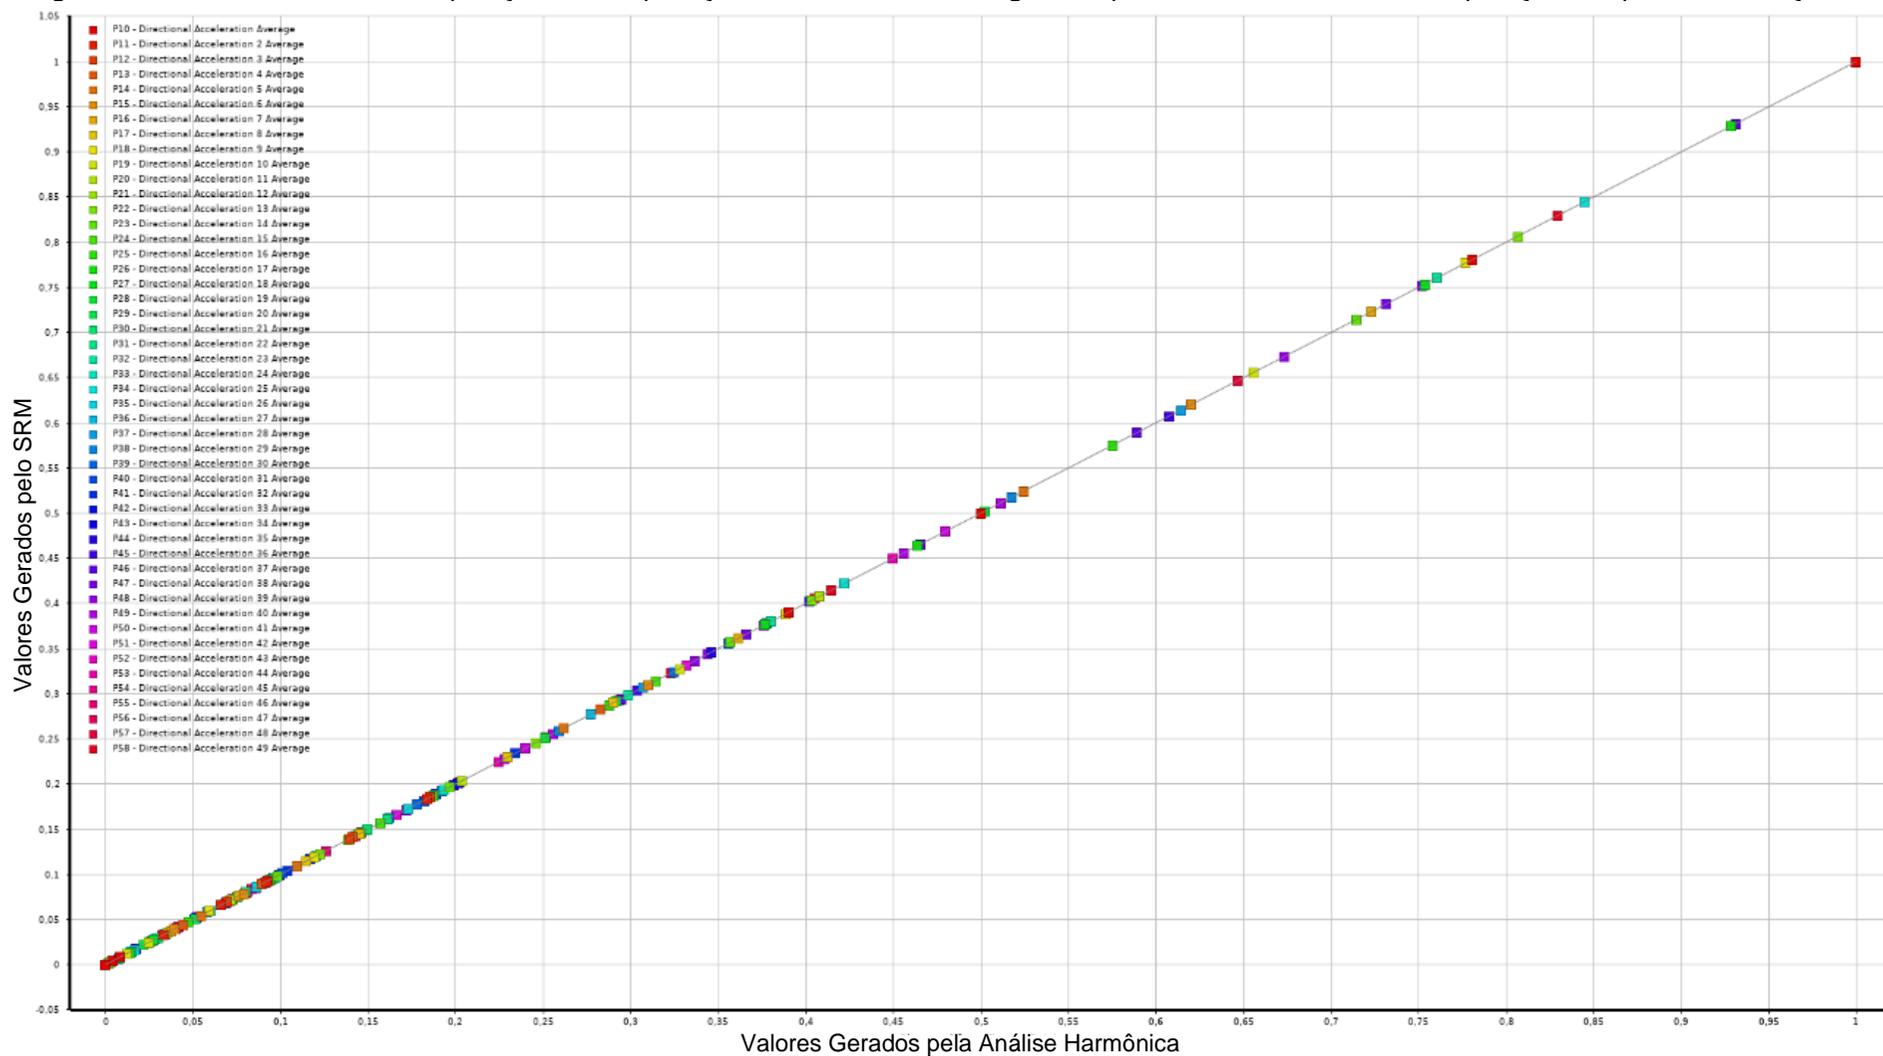
#### 4.3.2 Geração Numérica do Banco de dados usando (DOE e SRM)

Para geração do banco de dados via DOE, primeiramente foi utilizado uma única força com amplitude que variou com passo de 0,1mN, iniciando de 0,1mN até 5mN e, para cada valor de amplitude, variou-se a frequência da força com passo de 5Hz, iniciando de 5Hz até 250Hz, contemplando pelo menos dois modos ressonantes da estrutura. Com isso, o banco de dados gerado pela SRM tem 122.500 linhas e 53 colunas. Na Figura 17 é apresentado uma comparação entre os valores da superfície de resposta previstos versus os pontos gerados pela análise harmônica com aplicação de uma força. Os valores das acelerações obtidos pela análise harmônica numérica nos 49 pontos estão representados por quadrados coloridos (*design points*), enquanto os valores preditos pelo SRM estão representados como círculos. O fato de os dados

se ajustarem de forma linear em uma linha a  $45^\circ$  demonstra que há uma forte consistência entre os dados gerados pela análise Harmônica e os dados extrapolados pelo SRM, demonstrando que o meta modelo de superfície de resposta padrão, através de polinômios completos de segunda ordem para interpolar os valores nas múltiplas dimensões foi adequado.

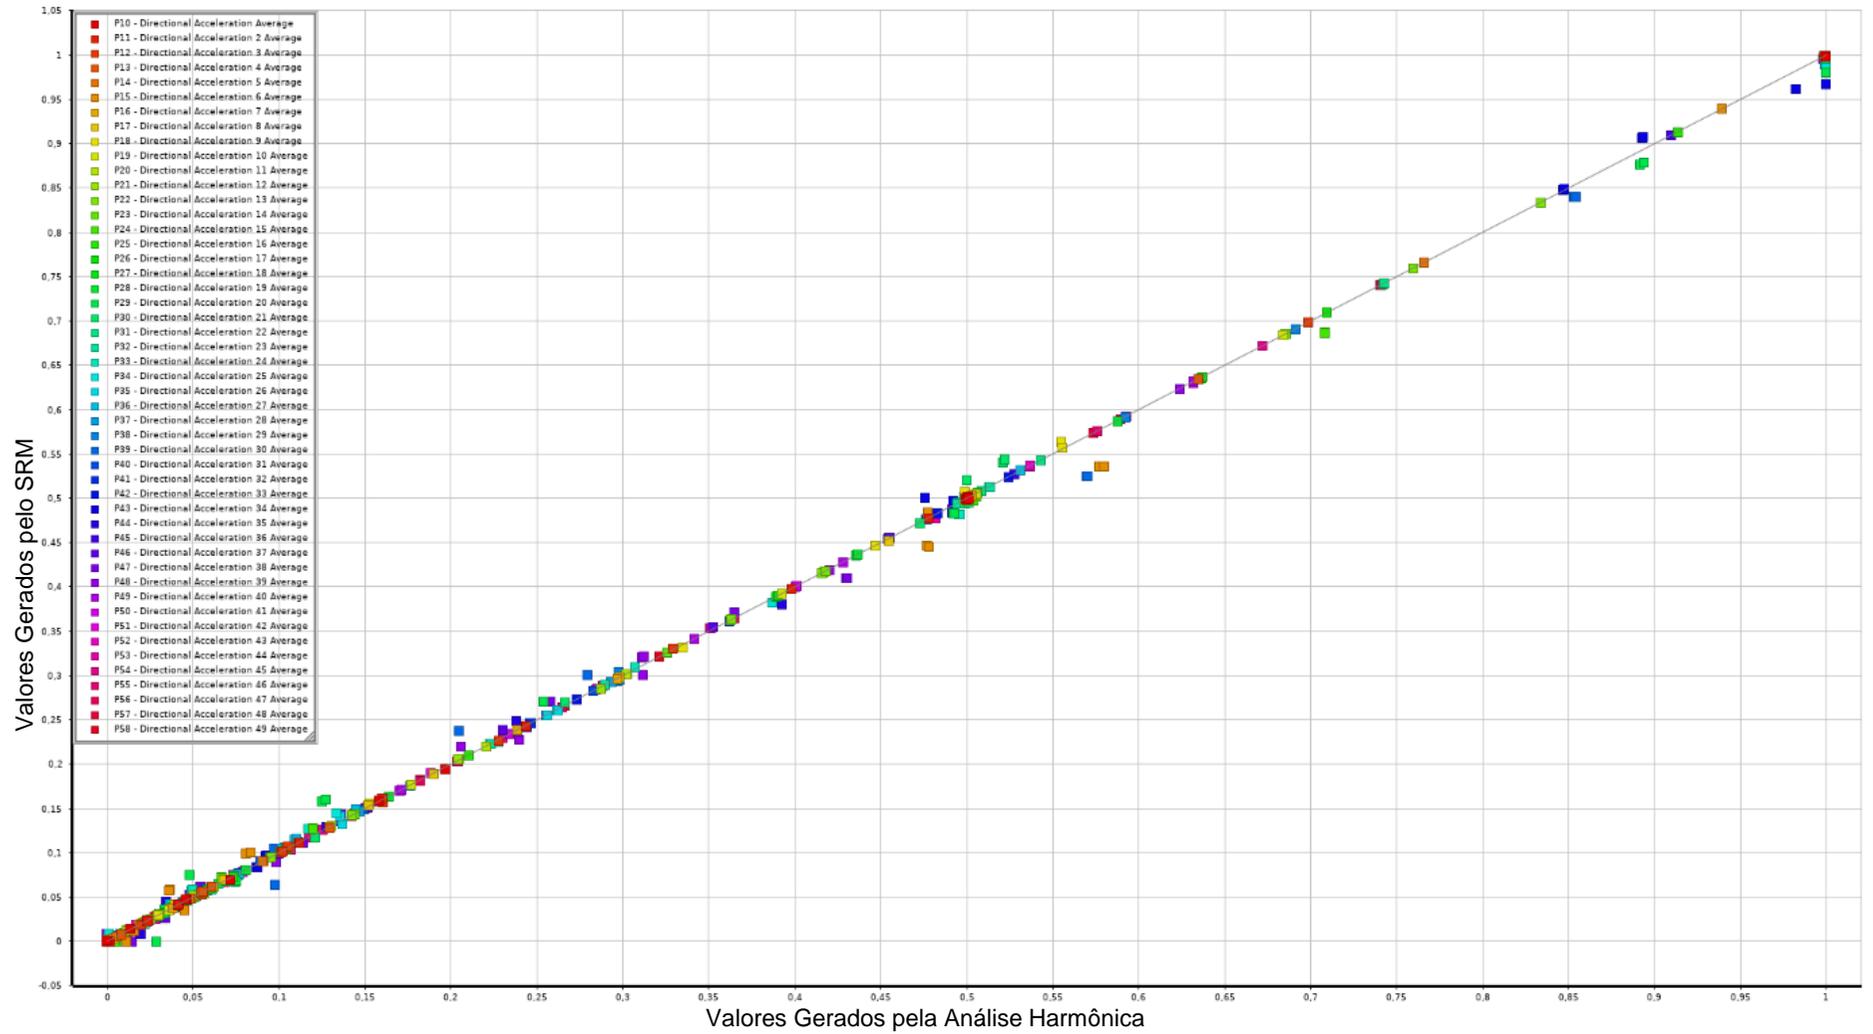
Um segundo conjunto de dados via DOE foi gerado, utilizando uma força com amplitude que variou com passo de 0,1mN, iniciando de 0,1mN até 5mN e, uma força com amplitude com magnitude 5mN fixa no ponto 33. Para cada valor de amplitude, variou-se a frequência das forças com passo de 5Hz, iniciando de 5Hz até 250Hz, contemplando pelo menos dois modos ressonantes da estrutura. Essa força gerou 49 superfícies de resposta para cada posição da força (49 posições), totalizando 2401 superfícies de resposta. Com isso, o banco de dados gerado pela SRM com a configuração de duas forças possui 122.500 linhas e 53 colunas. Na Figura 18 é apresentado uma comparação entre os valores da superfície de resposta previstos versus os pontos gerados pela análise harmônica, para a força variável no ponto 40 e força fixa no ponto 33.

Figura 17 - Retas em 45° com a comparação entre a predição do SRM e os valores gerados pela análise harmônica com aplicação de apenas uma força.



Fonte: Elaborada pelo autor do trabalho.

Figura 18 - Reta em 45° com a comparação entre a predição do SRM e os valores gerados pela análise harmônica para o modelo com duas forças.



Os valores das acelerações obtidos pela análise harmônica numérica nos 49 pontos estão representados por quadrados coloridos (design points), enquanto os valores preditos pelo SRM estão representados como círculos. Assim como na análise com uma força, para duas forças, uma tendência de ajuste dos dados em forma linear em uma linha a 45° foi verificada, demonstrando que há uma forte consistência entre os dados gerados pela análise Harmônica e os dados extrapolados pelo SRM. Dessa forma, fica evidente que o meta modelo de superfície de resposta padrão, através de polinômios completos de segunda ordem para interpolar os valores nas múltiplas dimensões foi adequado para o modelo.

O banco de dados gerado, é, então, composto pelos dados na configuração com uma e duas forças, totalizando 245.000 linhas e 53 colunas.

#### 4.4 Aprendizado de máquinas

Seis modelos de aprendizado de máquinas foram utilizados: Floresta Aleatória, Algoritmo k-NN (*k-Nearest Neighbor*), Árvores Aleatórias, Árvore CHAID, Árvore XGBoost e Redes Neurais MLP. Modelos de regressão foram utilizados pelo fato de os dados serem constituídas de variáveis contínuas. O conjunto de dados foi inicialmente separado de forma randômica para treinar os modelos de regressão, onde 80% foram utilizados para treinamento e 20% para teste do modelo treinado, seguindo a metodologia apresentada por (BREIMAN, 2001 e Setúbal,2022).

A divisão entre os conjuntos de treino e teste é um aspecto essencial para garantir que o modelo seja bem treinado e avaliado corretamente. Não existe um percentual fixo e ideal para todas as situações, mas alguns padrões amplamente aceitos são usados, dependendo do tipo de problema, do tamanho dos dados e das necessidades do modelo. Segundo Bishop (2006) e Murphy (2012), é uma prática comum dividir o conjunto de dados em 80% para treino e 20% para teste. Essa divisão é frequentemente usada em conjuntos de dados grandes e bem distribuídos. A divisão 80/20 permite que o modelo tenha uma boa quantidade de dados para treinar, ao mesmo tempo em que reserva uma porção razoável para teste.

A base de dados gerada pela SRM, considerando o banco completo possui 245.000 linhas e 53 colunas, sendo 49 *features* compostas pelas respostas de vibração nos 49 pontos da malha de simulação e 4 classes, sendo elas, número de forças, a amplitude da força, frequência de excitação e ponto de aplicação das forças.

Com o objetivo de analisar “redundâncias” nos dados, o número de *features*, previamente foi realizado uma análise do grau de importância de cada *features* na predição dos modelos de regressões, isso foi realizado utilizando os próprios algoritmos de Regressão. A correlação entre as *features* remanescentes foram realizadas com base na correlação de *Spearman* de acordo com o especificado por SHAIKH e BARBÉ (2019) e Setúbal (2022).

O índice de *Spearman* compreende valores entre 0 e 1, quanto mais próximo de 1 o índice, menor será a correlação entre as *features* e seus grupos. Desta forma, quanto maior a correlação entre as *features*, mais redundantes são suas informações para o modelo e, neste caso, pode-se excluir uma delas do banco de dados, sem prejudicar a acurácia do modelo. Esse procedimento é vantajoso pois reduz o número de dados a ser utilizado para a construção dos modelos de regressão. E com isso o tempo de processamento.

#### 4.5 Avaliação de desempenho dos modelos de Aprendizado de máquinas

Serão adotados como procedimento de avaliação de modelos, as métricas estatísticas: coeficiente de determinação ( $R^2$ ) conforme equação (49), que segundo Brandic (2024), é utilizado como uma medida da quantidade de variação nos dados reais representada pelo modelo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (Y - Y_i)^2} \quad (49)$$

Outra métrica adotada foi o erro relativo médio (ERM), o qual é descrito na equação 50:

$$ERM = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right| \quad (50)$$

As métricas calculadas foram utilizadas para comparar os modelos em termos de sua capacidade preditiva. Além disso, o tempo de execução do “código de execução” também será utilizado como métrica de avaliação.

#### 4.6 Considerações sobre o capítulo

Nesta seção foram apresentadas as metodologias utilizadas nesta tese para a obtenção do objetivo proposto. Inicialmente foi realizado uma análise modal experimental na chapa suspensa, os resultados foram utilizados para a calibração do

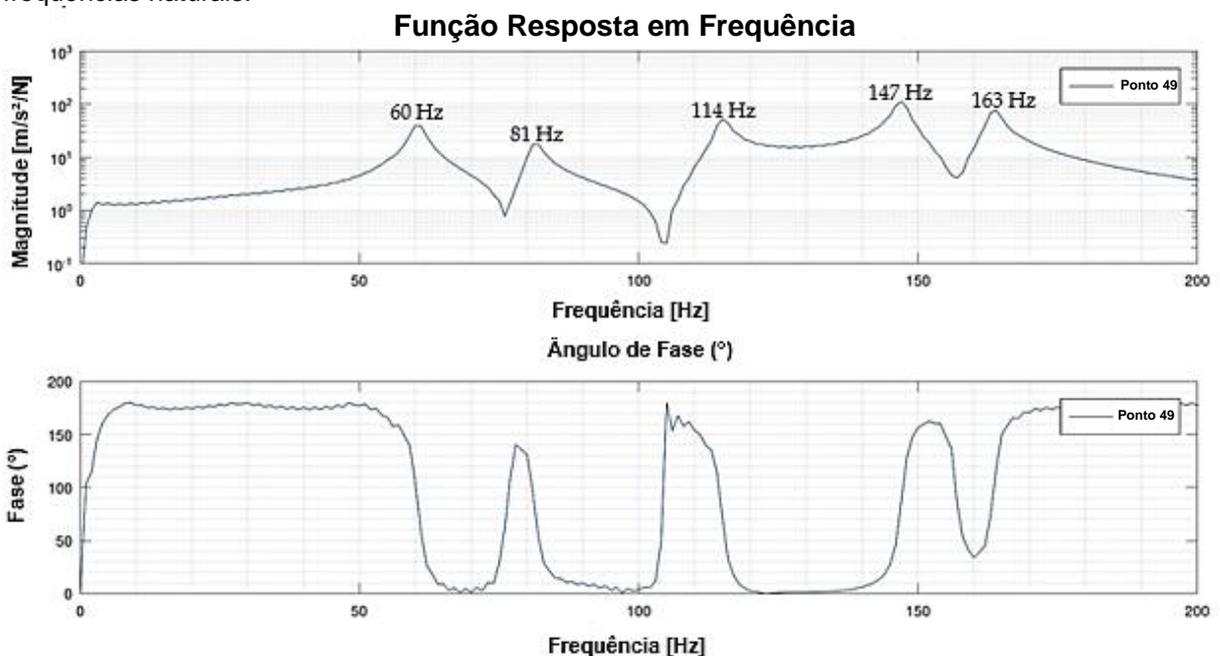
modelo numérico computacional, o que foi feito através da análise modal numérica. A validação foi realizada pelo MAC e COMAC. Uma análise modal foi realizada considerando uma e duas forças atuando sobre a estrutura. Para expandir os resultados foram utilizados o DOE e SRM, com isso um banco de dados robusto foi gerado. O banco de dados foi, então, utilizado para treinar seis modelos de aprendizado de máquinas, os quais foram avaliados segundo seu poder de previsão, pelas métricas Coeficiente de correlação, erro relativo médio e tempo de processamento. Na próxima seção serão apresentados e discutidos os resultados obtidos.

## 5 RESULTADOS E DISCUSSÕES

A análise modal experimental tem por finalidade identificar as frequências ressonantes da estrutura por meio do sinal do tipo FRF, assim como a suas formas modais de vibração e amortecimentos modais associados. Isso pode ser feito pela análise do diagrama de Bode, onde são visualizadas as amplitudes de vibração e seus respectivos ângulos de fase. Uma frequência ressonante pode ser identificada quando um pico de amplitude de vibração aparece associada a um ângulo de fase de  $\pm 90^\circ$ . Através de um software de extração de parâmetros modais pode-se visualizar, também, as formas modais e amortecimentos modais da estrutura.

Na figura 19 é mostrado o diagrama de bode da medição pontual do tipo inertância medida no ponto 49, que é caracterizada pelas suas antirressonâncias (picos decrescentes). Pela análise da figura pode-se verificar as cinco primeiras frequências ressonantes da estrutura, próximas as frequências: 60 [Hz], 81 [Hz], 114 [Hz], 147 [Hz] e 163 [Hz], o que pode ser verificado pelos ângulos de fase associados de  $\pm 90^\circ$ .

Figura 19 - Função Resposta em Frequência pontual da chapa destacando as cinco primeiras frequências naturais.

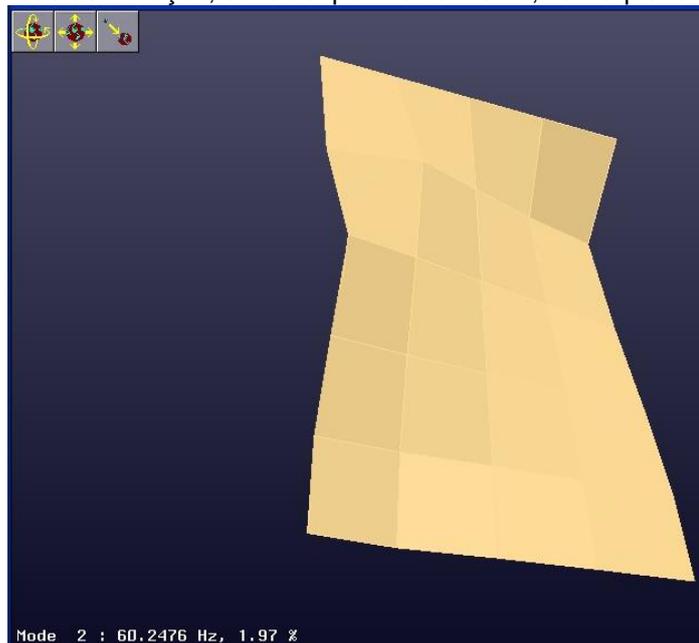


Fonte: Elaborada pelo autor do trabalho.

Os valores ressonantes identificados pela análise modal experimental foram utilizados para calibrar o modelo computacional em MEF. Esse modelo será utilizado posteriormente para a realização da Análise Harmônica.

Na Figura 20 é mostrado a forma modal de vibração da chapa, associada à sua primeira frequência natural. Essa imagem foi gerada por meio das FRF's medidas durante a análise modal experimental. Isso é conseguido pela leitura dos arquivos .uff gerados durante a medição e seleção das frequências ressonantes.

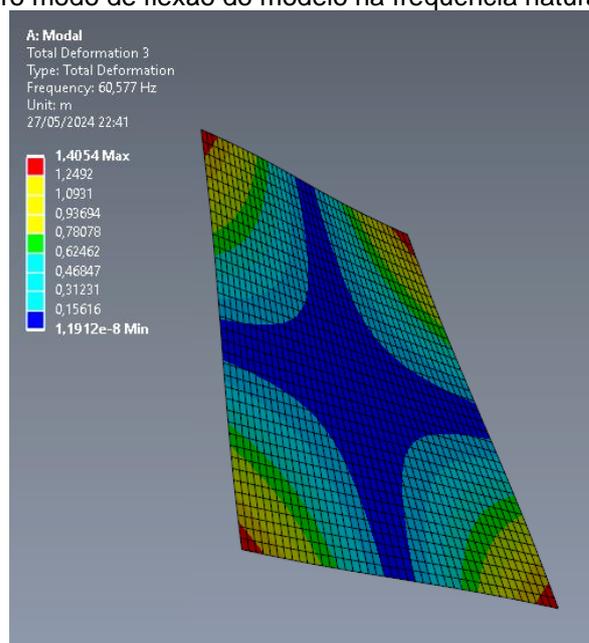
Figura 20 - Primeiro modo de vibração, obtido experimentalmente, na frequência natural de 60,24 Hz.



Fonte: Elaborada pelo autor do trabalho.

Na Figura 21 é mostrado a forma modal de vibração da chapa, associada à sua primeira frequência natural, gerada a partir do módulo numérico computacional em MEF, já calibrado. Pode-se observar a equivalências na forma modal nas duas imagens para a frequência natural apresentada, aproximadamente 60,58 Hz.

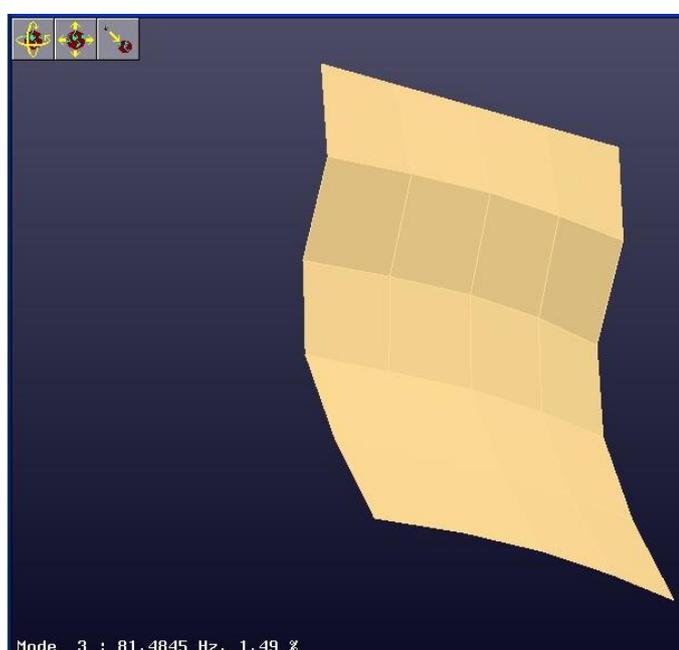
Figura 21 - Primeiro modo de flexão do modelo na frequência natural de 60,58 Hz.



Fonte: Elaborada pelo autor do trabalho.

O modo mostrado na Figura 22, foi extraído com o *software TestLab* para a frequência de 81,4845 Hz com fator de amortecimento de 1,49%, conforme mostrado.

Figura 22 - Segundo modo de flexão, obtido experimentalmente, na frequência natural de 81,48 Hz.

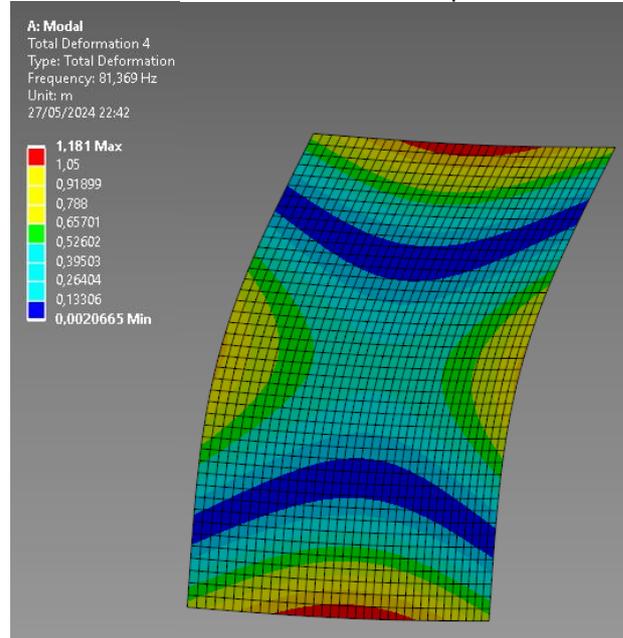


Fonte: Elaborada pelo autor do trabalho.

O modo mostrado na Figura 23 foi gerado pelo modelo em MEF, já calibrado pelos valores encontrados pelo diagrama de bode e com análise de convergência

realizados. Pode-se verificar a equivalência entre os valores das frequências e a formas modais entre as análises experimental e numérica.

Figura 23 - Segundo modo de flexão do modelo na frequência natural de 81,369 Hz.



Fonte: Elaborada pelo autor do trabalho.

Uma comparação das frequências naturais experimentais com as frequências naturais obtidas numericamente pelo modelo em MEF, é mostrada na tabela 4.

Tabela 4 – Comparação das frequências naturais obtidas experimentalmente com as frequências obtidas pelo modelo em MEF.

	Modo 1	Modo 2	Modo 3	Modo 4	Modo 5	Modo 6	Modo 7	Modo 8	Modo 9	Modo 10
Experimental	60,24	81,48	115,87	147,06	164,57	232,48	282,94	291,86	312,45	363,36
MEF	60,58	81,37	118,64	148,48	166,11	236,8	287,49	293,44	320,4	372,11
Erro (%)	0,56	0,14	2,40	0,97	0,94	1,86	1,61	0,54	2,54	2,41

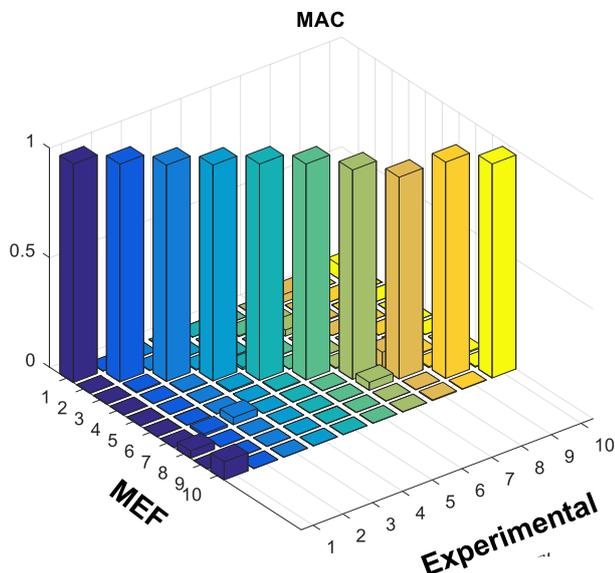
Fonte: Elaborada pelo autor do trabalho.

A comparação entre as frequências naturais obtidas experimentalmente com as frequências obtidas pelo modelo em MEF, mostradas na tabela 4, demonstram a coerência na calibração dos modelos, o que é evidenciado pelos baixos erros encontrados, quando comparadas as frequências naturais, numéricas e experimentais. A fim de validar a calibração do modelo computacional, também foi realizado o cálculo do MAC e COMAC, considerando os 10 primeiros modos obtidos experimentalmente e através do modelo computacional via MEF calibrado.

Os números obtidos pelo MAC podem ser empregados para comparar duas formas modais que foram obtidas a partir de dois métodos distintos de estimativa de parâmetros modais, utilizando os mesmos dados de teste. Quando dois vetores têm uma relação linear, o valor MAC tende a ser próximo de um. Na figura 24 é mostrado

o gráfico do MAC para os modos gerados pelos modelos experimental e numérico via MEF.

Figura 24 - Gráfico com valores do MAC para os modos gerados pelos modelos experimental e numérico via MEF.

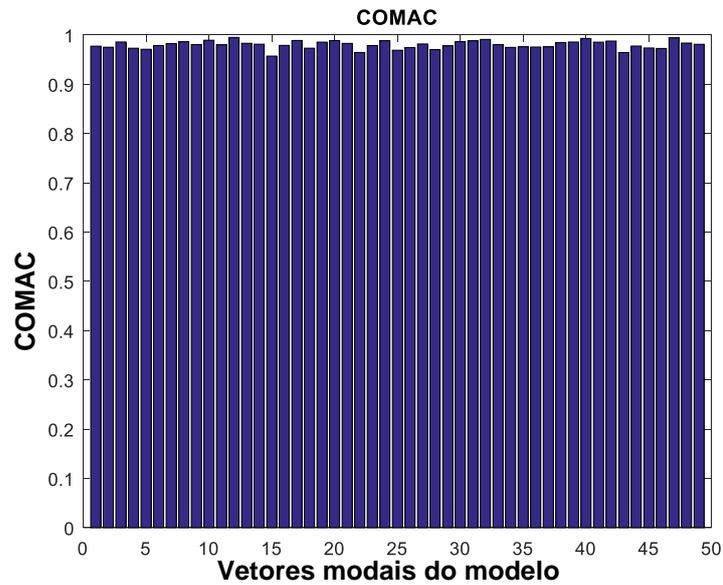


Fonte: Elaborada pelo autor do trabalho.

Pela análise do MAC, Figura 24, pode-se observar que os valores dos modos da diagonal, que relacionam os valores obtidos pela análise Modal experimental da chapa e os valores obtidos pela análise Modal computacional via MEF, ficaram próximos de 1, evidenciando a forte correlação entre os modelos estudados.

O COMAC é uma ampliação do Critério de Garantia Modal (MAC), onde o objetivo do COMAC é descobrir quais graus de liberdade na medição estão afetando negativamente o valor MAC. O COMAC pode ser calculado entre modos de diferentes algoritmos de identificação. Assim como o MAC, o COMAC apresenta valores que variam de 0 a 1. Na figura 25, são mostrados os resultados do COMAC, obtidos pela comparação dos modelos.

Figura 25 - Valores do COMAC usados na comparação dos GDL dos modos experimentais e numéricos via MEF.



Fonte: Elaborada pelo autor do trabalho.

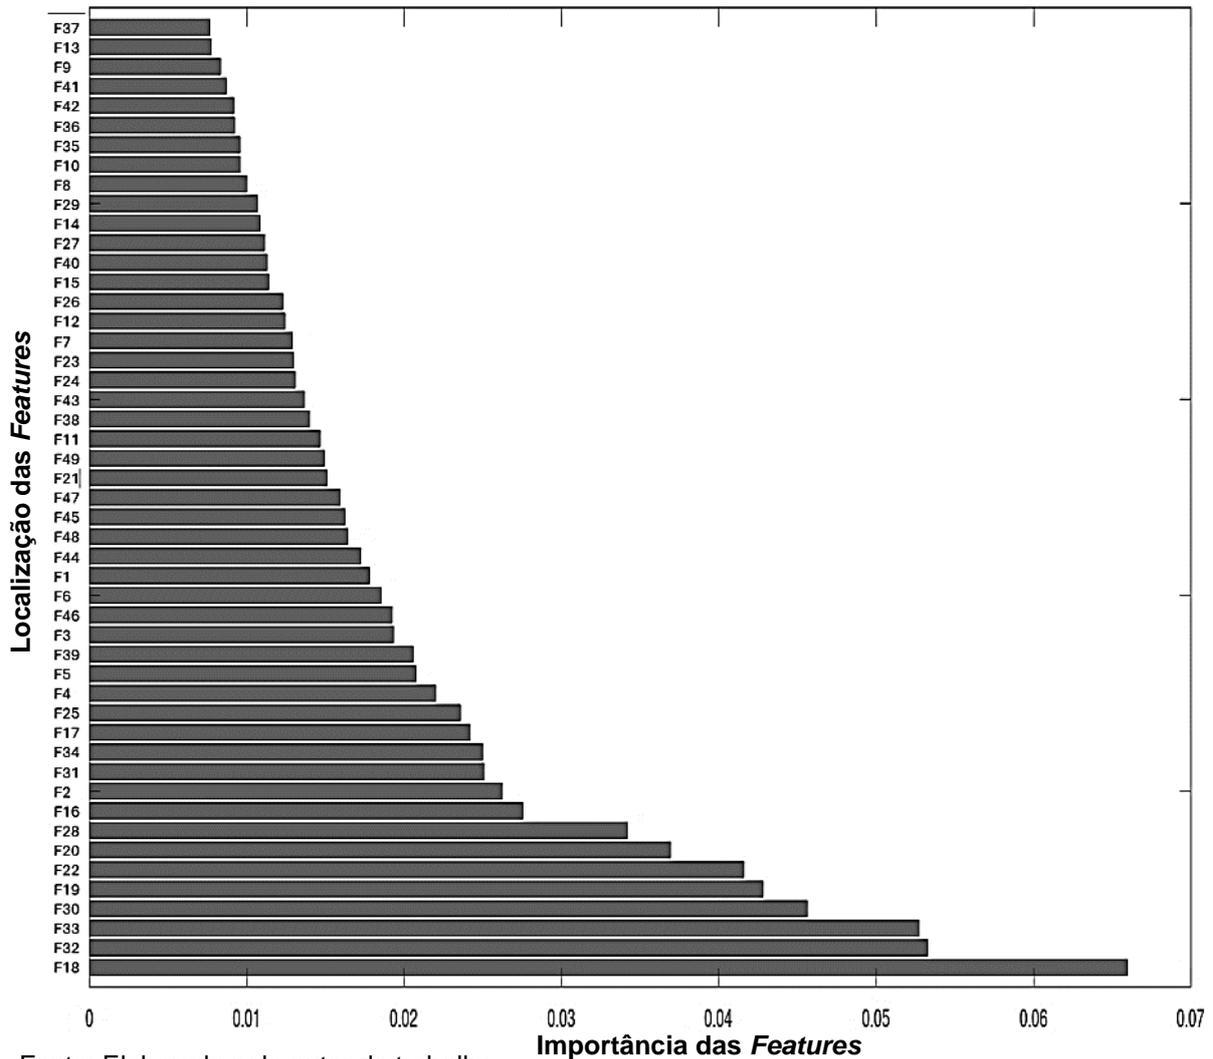
Pela análise da figura 25, verifica-se que o COMAC também evidencia a boa correlação entre os GDL dos modos, o que é indicado pelos níveis próximos de 1.

A escolha do número de modos a ser estudada dependerá do tipo de problema a avaliar. Para esta tese, foi considerado a análise das respostas de vibração do sistema de 0 [Hz] a 250 [Hz], contemplando pelo menos dois modos de vibração.

Por meio do banco de dados utilizou-se um algoritmo que fornece o ranking de importância das *features*. Quanto maior a redução do erro em *splits* de decisões tomada com base em uma determinada *feature*, mais importante a variável será.

Foram adotadas inicialmente 49 *features*, compostas pelas respostas de aceleração em cada um dos 49 pontos adotados para a análise do sistema considerado. A Figura 26 mostra o gráfico da importância percentual das 49 *features* e suas respectivas posições em que se encontram no modelo, conforme descrito na metodologia.

Figura 26 - Importância das localizações das medições de vibração (features) e suas respectivas contribuições percentuais, na acuracidade do modelo.

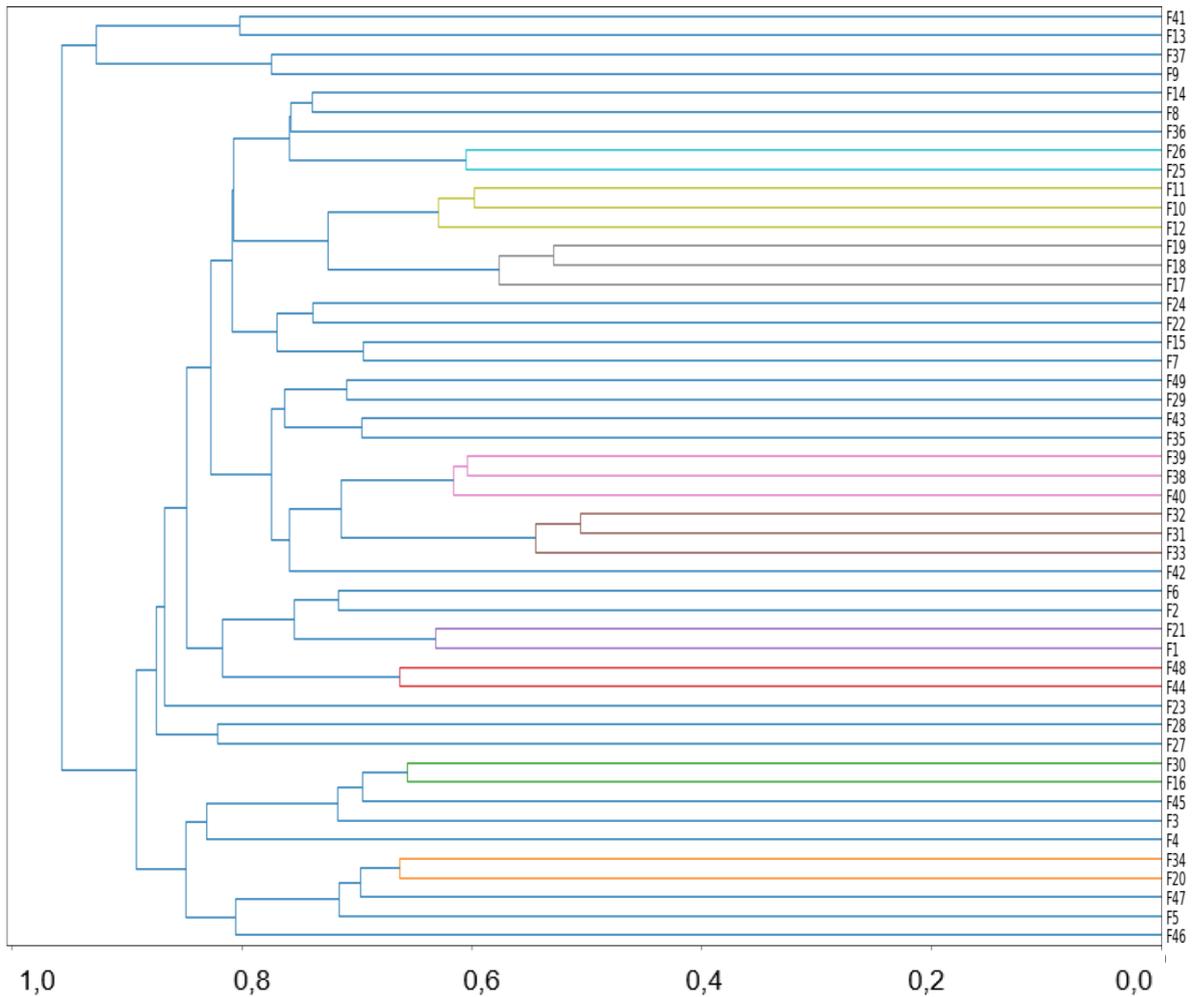


Fonte: Elaborada pelo autor do trabalho.

A *feature 37* (F37), referente ao ponto de medição 37 (ver Figura 26), possui contribuição abaixo de 1% na predição do modelo. A *feature 30* (F30), referente ao ponto de medição 30, apresenta uma importância de 5%, aproximadamente, na predição do modelo. A *feature 18* foi a variável mais importante para o modelo, com uma importância de aproximadamente 6,6%.

Outra importante fonte de informações para os modelos em Aprendizado de máquinas é dendrograma de *Spearman*, que foi gerado para as 49 variáveis analisadas neste trabalho. Na figura 27 é mostrado o dendrograma de *Spearman* do modelo adotado.

Figura 27 - Dendrograma de Spearman apresentando a correlação entre as 49 variáveis.



Fonte: Elaborada pelo autor do trabalho.

Todas as 49 *features* possuem pouca correlação, dado o fato de que suas informações só apresentam relativa correlação a partir de índices de *Spearman* próximos de 60% (ver Figura 27), refletindo, portanto, na baixa redundância de informações. Logo, conclui-se que todas as 49 *features* analisadas possuem relevância para o modelo.

Após a análise e validação da relevância de cada *feature* para o banco de dados, os dados foram utilizados para treino e teste dos métodos de aprendizado de máquinas: Floresta Aleatória, Algoritmo kNN (*k-Nearest Neighbor*), Árvores Aleatórias, Árvore CHAID, Árvore XGBoost e Redes Neurais MLP. Os Dados foram separados de forma que 80% dos dados foram utilizados para o treino dos modelos e 20% para o teste dos modelos. Adotou-se o método de análise sem reposição com seleção aleatória dos dados.

Para a análise, foram configurados como features preditoras, inicialmente, as respostas de vibração geradas pelo modelo computacional via MEF, nos 49 pontos de medição considerados e como variáveis preditas o número de forças atuantes na estrutura, as suas localizações, as magnitudes e a frequência de excitação das forças aplicadas. Uma análise considerando as respostas de vibração (*features*) nos 22 pontos de medição mais relevantes e após as 10 respostas de vibração (*features*) nos 10 pontos de medição mais relevantes, também foi realizada, com a finalidade de identificar o impacto da redução no número de medições na acurácia de cada modelo. Os pontos de maior importância foram definidos de acordo com o gráfico de importância das *features* de cada modelo.

Na Tabela 5 são mostrados os resultados dos Modelos de Aprendizado de Máquinas considerando 49, 22 e 10 pontos de medição.

Tabela 5 – Comparação das métricas de predição entre os Modelos de Aprendizado de Máquinas.

Modelo	Nº de Features	R <sup>2</sup>	Erro Relativo (%)	Nº de Features	R <sup>2</sup>	Erro Relativo (%)	Nº de Features	R <sup>2</sup>	Erro Relativo (%)
<b>Floresta Aleatória</b>	49	1,0	0,1	22	0,998	0,1	10	0,998	0,2
Tempo de processamento	1 min 22 s			1 min 08 s			59 s		
<b>k-NN</b>	-	-	-	22	1,0	0,012	10	1,0	0,013
Tempo de processamento	-			1 min 02 s			56 s		
<b>Árvore CHAID</b>	49	0,904	9,6	22	0,887	11,2	10	0,832	16,9
Tempo de processamento	1 min 25 s			1 min 17 s			1 min 07 s		
<b>Árvore Aleatória</b>	49	0,893	11,7	22	0,861	15,6	10	0,805	21,5
Tempo de processamento	1 min 27 s			1min 18 s			1 min 09 s		
<b>Arvore XGBoost</b>	49	0,882	13,7	22	0,830	19,8	10	0,759	27,2
Tempo de processamento	1 min 32 s			1 min 23 s			1 min 12 s		
<b>Rede Neural MLP</b>	49	0,863	13,6	22	0,629	37,1	10	0,433	56,8
Tempo de processamento	1 min 27 s			1 min 22 s			1 min 18 s		

Fonte: Elaborada pelo autor do trabalho.

Os seis modelos de Aprendizado de Máquinas adotados apresentaram boa correlação com o modelo experimental, conforme Tabela 5, no entanto, o modelo de floresta aleatória e o modelo k-NN foram os que melhores se ajustaram a previsão de forças, tendo o modelo de florestas aleatórias encontrado erros abaixo de 1% e o modelo k-NN prevendo os dados com 0,013% de erro.

Pela análise dos tempos de processamento, verifica-se que os modelos apresentaram resultados semelhantes, tendo o modelo k-NN apresentado os melhores tempos. Vale ressaltar que o modelo k-NN, para o modelo com 49 features não produziu resultados por extrapolar as configurações de máximo agrupamento e tempo de processamento configurado para o modelo, esse procedimento visa não considerar modelos demasiadamente robustos.

Tendo em vista a redução do número de features, os modelos k-NN e Floresta Aleatória mantiveram a seu poder de previsão, mesmo com a redução do número de pontos de medição considerados, para 10, ou seja, com apenas 10 medições na superfície da chapa, os modelos propostos são capazes de identificar o número de forças atuando na estrutura, além de suas frequências, magnitudes e localizações. Já os demais modelos demonstraram grande dependência de um número maior de medições para realizar a previsão. Os dez pontos mais importantes identificados, foram evidenciados em azul na figura 9 e suas importâncias podem ser verificadas pela figura 26.

Na tabela 6, é demonstrado o nível de acurácia dos modelos k-NN e Floresta aleatória para 10 pontos de medição, considerando as etapas de treino e teste.

Tabela 6 - Comparação dos erros de predição para os Modelos k-NN e Floresta Randômica nas fases de treino e teste, adotando-se 10 pontos de medição.

	k-NN				Floresta Aleatória			
	Treino	[%]	Teste	[%]	Treino	[%]	Teste	[%]
Acertos	195.958	99.992	48.994	99.987	195.804	99.9	48.902	99.8
Erros	42	0.008	6	0.013	196	0.1	99	0.2
Total	<b>196.000</b>	<b>100</b>	<b>49.000</b>	<b>100</b>	<b>196.000</b>	<b>100</b>	<b>49.000</b>	<b>100</b>

Fonte: Elaborada pelo autor do trabalho.

Para os modelos considerando 10 pontos de medição, foram utilizadas 196.000 *features* para treino e 49.000 *features* utilizadas para o teste dos modelos, onde o modelo k-NN falhou na previsão dos resultados 42 vezes em treino e 6 vezes em teste. Já o modelo de Floresta Aleatória falhou na previsão dos resultados 196 vezes durante

a fase de treino e 99 vezes na fase de teste, demonstrando o grande potencial da metodologia.

A fim de verificar a capacidade dos modelos em lidar com dados de sistemas reais, também foi realizado uma avaliação dos modelos k-NN e Floresta Aleatória, mediante dados obtidos por meio de uma análise harmônica experimental. Logo, um banco de dados composto por uma linha, contendo dados experimentais foi gerado e utilizado para avaliar os modelos k-NN e Floresta Aleatória.

O modelo de Floresta Aleatória obteve um *score* de 0.93, enquanto o modelo k-NN obteve um *score* de 0.96, o que demonstra a grande capacidade dos modelos criados em lidar com um problema real. Vale ressaltar que esse procedimento não tem por finalidade validar os modelos k-NN e Floresta Aleatória. Segundo Bishop (2006) e Murphy (2012) o procedimento de validação de um banco de dados robusto exige pelo menos 10% do banco de dados, porém, esse procedimento fornece uma perspectiva do potencial da metodologia em lidar com sistemas reais.

## 5.1 Considerações finais

Nesta seção foram apresentados os resultados obtidos desde a análise modal experimental em laboratório até a construção do banco de dados que foi utilizado para treino e teste dos algoritmos de Aprendizado de Máquinas.

Um modelo numérico computacional foi validado pelos resultados de análise modal experimental, através do MAC e COMAC. Uma análise harmônica foi realizada considerando uma e duas forças atuando na estrutura. Foram utilizados como dados de entrada a amplitude, frequência e posição das forças. Como saída foi considerado as acelerações médias em cada ponto. Para ampliar o banco de dados foram utilizados o DOE e SRM. Esses parâmetros foram utilizados para criar um banco de dados robusto. O grau de importância dos pontos de medição e a correlação entre as repostas de vibrações medidas, foram avaliados utilizando a importância das *features* e o dendograma de Spearman.

Foram avaliados seis modelos de aprendizado de máquinas segundo o coeficiente de correlação ( $R^2$ ), o erro médio relativo e o tempo de processamento, ressaltando um grande potencial em especial dos modelos k-NN e Floresta Aleatória. Por fim, também foi realizado uma avaliação dos modelos k-NN e Floresta Aleatória,

mediante dados obtidos por meio de uma análise harmônica experimental, utilizando um banco de dados composto por uma linha, contendo dados experimentais da análise harmônica experimental realizada na chapa, os modelos k-NN e Floresta Aleatória obtiveram *score* 0,96 e 0,93, respectivamente.

Na seção seguinte, serão apresentadas as principais considerações acerca das conclusões obtidas nesta tese.

## 6 CONCLUSÕES

Uma análise da literatura acadêmica revelou que muitos pesquisadores direcionaram suas energias para o desenvolvimento de modelos numéricos e analíticos sofisticados. Tais modelos visam identificar e simular as forças que atuam em uma ampla gama de sistemas para otimizar as condições de projeto e minimizar falhas e defeitos quando os sistemas estão em operação. A obtenção de informações precisas sobre as forças dinâmicas que influenciam esses sistemas vibratórios é obrigatória e especialmente relevante para fins de projeto ou diagnóstico, pois as mudanças nos esforços dinâmicos se refletem diretamente na vida útil dos componentes (falha por fadiga).

Uma vez que os artigos estudados exigem grandes esforços experimentais e matemáticos para reproduzir e localizar a força em estruturas pelo método inverso, a metodologia proposta visa reduzir o tempo e a complexidade no processo de identificação da força ativa em uma estrutura e superar problemas de mau condicionamento, normalmente encontrados em métodos tradicionais para resolver problemas inversos.

Este trabalho identificou sistemas multiforça utilizando o método inverso, com base em dados de vibração gerados em laboratório e os resultados subsidiaram a criação de um modelo numérico computacional em MEF, validado por MAC e COMAC. Juntamente com o DOE e o SRM, uma análise harmônica realizada gerou um banco de dados robusto, que foi utilizado para avaliar a capacidade de seis modelos de aprendizado de máquinas, avaliados de acordo com os parâmetros  $R^2$ , EMR e tempo computacional, para identificar sistemas multiforça.

Os modelos de aprendizado de máquina adotados mostraram excelente precisão na previsão de parâmetros de força, a saber, posição, magnitude, frequência e número de forças. O modelo k-NN conseguiu prever os parâmetros das forças com erros próximos a 0% e o modelo de Floresta Aleatória conseguiu prever com um erro máximo de 0,2%. Os modelos revelaram alto potencial para identificar sistemas multiforça.

O estudo também avaliou a eficiência dos modelos de aprendizado de máquina, reduzindo o número de pontos de medição considerados. Os modelos se mostraram capazes de fornecer excelentes resultados com 10 pontos de medição. Os modelos Árvore CHAID, Árvore Aleatória, Árvore XGBoost e Rede Neural MLP apresentaram

acurácia acima de 86% considerando o uso de 49 *features*, porém a redução do número de *features* para 10 impactou diretamente a acurácia desses modelos. Essa redução na precisão está ligada à relevância de cada *features* no poder de previsão desses modelos. Para esses modelos, o poder precisão está interligado ao uso de mais *features*, o que resulta em procedimentos experimentais mais dispendiosos.

Os resultados obtidos demonstram o grande potencial da metodologia desenvolvida para a identificação de sistemas multiforças, além de permitir, também, a determinação do número mínimo de pontos cruciais a serem medidos sem que haja perda da eficiência na identificação e caracterização das forças atuantes na estrutura. A determinação do número mínimo de pontos a serem medidos é importante, pois torna o processo de medição muito mais preciso, refletindo diretamente nos processos utilizados e no tempo gasto durante os procedimentos experimentais e, conseqüentemente, no processamento desses dados.

É importante salientar que o banco de dados, utilizado para treino e teste dos modelos, foi gerado de forma computacional, portanto, sem a presença de ruídos, os quais podem surgir durante um procedimento experimental. Para tanto, um banco de dados contendo uma linha de dados experimentais foi gerado, com a finalidade de avaliar o potencial desses modelos em lidar com dados experimentais, o que reduziu a precisão dos modelos, como esperado. Onde os modelos k-NN e Floresta Aleatória obtiveram score 0.96 e 0.93, respectivamente. No entanto, durante o procedimento de medição em campo, os resultados podem apresentar uma interferência muito mais significativa em termos de ruídos, do que quando comparado a um procedimento experimental realizado em um ambiente controlado, como em um laboratório. Logo, tendo em vista que a acurácia dos modelos adotados sofre grande influência da qualidade dos dados obtidos, os resultados, nesse caso, podem diferir dos resultados encontrados neste trabalho.

Outro fator importante, diz respeito ao fato de que, não houve nenhum tratamento no banco de dados. Essa manipulação em muitos casos pode ser benéfica para a eficácia dos modelos de aprendizado de máquinas e, também, podem impactar na acurácia dos modelos.

A presente tese de doutorado ainda gerou como produto, um artigo publicado em periódico Qualis A2, Engenharias IV:

Pinheiro, G.d.S.; Setúbal, F.A.d.N.; Filho, S.d.S.C.; Mesquita, A.L.A.; Nunes, M.V.A. Comparative Analysis of Machine Learning Techniques for Identifying Multiple Force Systems from Accelerometer Measurements. *Sensors* **2024**, *24*, 6675. <https://doi.org/10.3390/s24206675>

### **6.1 Sugestões para trabalhos futuros**

A metodologia proposta nessa tese foi realizada em um único estudo de caso. Neste sentido, ressalta-se a necessidade de experimentar a metodologia abordada em outros estudos de casos, para se ter uma maior confiabilidade do método proposto.

Desta forma, esta tese implementou uma ferramenta de suporte baseada em aprendizado de máquinas que pode ser integrada diretamente às áreas de engenharias elétrica, civil e mecânica, garantindo um aumento considerável na confiabilidade de projetos estruturais de equipamentos elétricos de potência como nos transformadores, projetos ferroviários, civis e mecânicos.

## REFERÊNCIAS

ABDULLAH, Mahir Faris; ZULKIFLI, Rozli; MORIA, Hazim; NAJM, Asmaa Soheil; HARUN, Zambri; ABDULLAH, Shahrir; GHOPA, Wan Aizon Wan; SULAIMAN, Noor Humam. Assessment of TiO<sub>2</sub> Nanoconcentration and Twin Impingement Jet of Heat Transfer Enhancement - A Statistical Approach Using Response Surface Methodology. *Energies*, vol. 14, no. 3, 1 Feb. 2021. <https://doi.org/10.3390/en14030595>.

ABBASS, M.J.; LIS, R.; AWAIS, M.; NGUYEN, T.X. Convolutional Long Short-Term Memory (ConvLSTM)-Based Prediction of Voltage Stability in a Microgrid. *Energies* 2024, 17, 1999. <https://doi.org/10.3390/en17091999>

AGGARWAL, C. C., HINNEBURG, A., e KEIM, D. A. (2001). On the surprising behavior of distance metrics in high dimensional space. In *Lecture Notes in Computer Science*, páginas 420–434. Springer.

Aha, D.W., Kibler, D. & Albert, M.K. Instance-based learning algorithms. *Mach Learn* 6, 37–66 (1991). <https://doi.org/10.1007/BF00153759>

ALMASI, Sara; GHOBADIAN, Barat; NAJAFI, Gholam Hassan; YUSAF, Talal; SOUFI, Masoud Dehghani; HOSEINI, Seyed Salar. Optimization of an ultrasonic-assisted biodiesel production process from one genotype of rapeseed (Teri (OE) R-983) as a novel feedstock using response surface methodology. *Energies*, vol. 12, no. 14, 2019. <https://doi.org/10.3390/en12142656>.

Alpaydin, E. (2014). *Introduction to Machine Learning*. MIT Press, Cambridge — MA, England.

ALTMAN, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *American Statistician*, 46(3), 175-185. <https://doi.org/10.1080/00031305.1992.10475879>

ANGUEBES-FRANSESCHI, Francisco; ABATAL, Mohamed; BASSAM, Ali; SOBERANIS, Mauricio A.Escalante; TZUC, Oscar May; BUCIO-GALINDO, Lauro; QUIROZ, Atl Victor Cordova; UCAN, Claudia Alejandra Aguilar; RAMIREZ-ELIAS, Miguel Angel. Esterification optimization of crude African palm olein using response surface methodology and heterogeneous acid catalysis. *Energies*, vol. 11, no. 1, 1 Jan. 2018. <https://doi.org/10.3390/en11010157>.

Ansys® Academic Research Mechanical, Release 2024 R1, Help System, Coupled Field Analysis Guide, ANSYS, Inc.

BARBARESI, A; CECCARELLI, M; MENICHETTI, G; TORREGGIANI, D; TASSINARI, P; BOVO, M. Application of Machine Learning Models for Fast and Accurate Predictions of Building Energy Need. *Energies* 2022, Vol. 15, Page 1266, vol. 15, no. 4, p. 1266, 9 Feb. 2022. DOI 10.3390/EN15041266. Available at: <https://www.mdpi.com/1996-1073/15/4/1266/htm>. Accessed on: 13 Apr. 2022.

BEEBE K.R.; PELL R.J.; SEASHOLTZ M.B. Chemometrics: a practical guide. Wiley, Sciarium, , p. 358, 1998. . Accessed on: 7 Mar. 2022.

BISHOP, Christopher M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. 738 p.

BHUSHAN, Shanti; BURGREN, Greg W.; BREWER, Wesley; DETTWILLER, Ian D. Development and validation of a machine learned turbulence model. *Energies*, vol. 14, no. 5, 1 Mar. 2021. <https://doi.org/10.3390/en14051465>.

BOX, G. E. P.; WILSON, K. B. On the Experimental Attainment of Optimum Conditions. *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 13, no. 1, p. 1–38, 1951. <https://doi.org/10.1111/J.2517-6161.1951.TB00067.X>.

BRANDIĆ I, PEZO L, VOĆA N, MATIN A. Biomass Higher Heating Value Estimation: A Comparative Analysis of Machine Learning Models. *Energies*. 2024; 17(9):2137. <https://doi.org/10.3390/en17092137>

BREIMAN, L. Random Forests. *University of California*, , p. 1–33, 2001.

BUONANNO, A.; CAPUTO, G.; BALOG, I.; FABOZZI, S.; ADINOLFI, G.; PASCARELLA, F.; LEANZA, G.; GRADITI, G.; VALENTI, M. Machine Learning and Weather Model Combination for PV Production Forecasting. *Energies* 2024, 17, 2203. <https://doi.org/10.3390/en17092203>

CHEN, Z., WANG, Z., KONG, X., DENG, L., Moving force identification based on the nonnegative flexible conjugate gradient least square method and experimental verification, *Journal of Sound and Vibration*, Volume 572, 2024, 118177, ISSN 0022-460X, <https://doi.org/10.1016/j.jsv.2023.118177>.

CHOI, H.G. THITE, A.N. THOMPSON, D.J. A threshold for the use of Tikhonov regularization in inverse force determination, *Applied Acoustics*, Volume 67, Issue 7, 2006, Pages 700-719, ISSN 0003-682X, <https://doi.org/10.1016/j.apacoust.2005.11.003>.

COSTARROSA, Laureano; LEIVA-CANDIA, David Eduardo; CUBERO-ATIENZA, Antonio José; RUIZ, Juan José; DORADO, M. Pilar. Optimization of the transesterification of waste cooking oil with mg-al hydrotalcite using response surface methodology. *Energies*, vol. 11, no. 2, 1 Feb. 2018. <https://doi.org/10.3390/en11020302>.

CUTLER, A., CUTLER, D., STEVENS, J. *Ensemble Machine Learning: Methods and Applications* (pp.157-176), Springer (2011). DOI: 10.1007/978-1-4419-9326-7\_5.

CZAJKOWSKI, M., JURCZUK, K., KRETOWSKI, M. Steering the interpretability of decision trees using lasso regression - an evolutionary perspective, *Information Sciences*, Volume 638, 2023, 118944, ISSN 0020-0255, <https://doi.org/10.1016/j.ins.2023.118944>.

DANG, Sanlei; PENG, Long; ZHAO, Jingming; LI, Jiajie; KONG, Zhengmin. A Quantile Regression Random Forest-Based Short-Term Load Probabilistic Forecasting Method. *Energies*, vol. 15, no. 2, 1 Jan. 2022. <https://doi.org/10.3390/en15020663>.

DOYLE, J.F. Determining the contact force during the transverse impact of plates. *Experimental Mechanics* 27, 68–72 (1987). <https://doi.org/10.1007/BF02318866>

DZIEDZIECH, Kajetan; MENDROK, Krzysztof; KUROWSKI, Piotr; BARSZCZ, Tomasz. Multi-Variant Modal Analysis Approach for Large Industrial Machine. *Energies* 2022, Vol. 15, Page 1871, vol. 15, no. 5, p. 1871, 3 Mar. 2022. DOI 10.3390/EN15051871. Available at: <https://www.mdpi.com/1996-1073/15/5/1871/htm>. Accessed on: 13 Apr. 2022.

FENG, Wei; LI, Qiaofeng; LU, Qiu Hai. Force localization and reconstruction based on a novel sparse Kalman filter. *Mechanical Systems and Signal Processing*, vol. 144, 1 Oct. 2020. <https://doi.org/10.1016/j.ymssp.2020.106890>.

FENG, Wei; LI, Qiaofeng; LU, Qiu Hai; WANG, Bo; LI, Chen. Time domain force localization and reconstruction based on hierarchical Bayesian method. *Journal of Sound and Vibration*, vol. 472, 28 Apr. 2020. <https://doi.org/10.1016/j.jsv.2020.115222>.

FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, p. 1189-1232, 2001.

GOUTAUDIER, Dimitri; GENDRE, Didier; KEHR-CANDILLE, Véronique; OHAYON, Roger. Single-sensor approach for impact localization and force reconstruction by using discriminating vibration modes. *Mechanical Systems and Signal Processing*, vol. 138, 1 Apr. 2020. <https://doi.org/10.1016/j.ymssp.2019.106534>.

HAALAND, Perry D. Experimental Design in Biotechnology. *Experimental Design in Biotechnology*, 25 Nov. 2020. DOI 10.1201/9781003065968. Available at: <https://www.taylorfrancis.com/books/mono/10.1201/9781003065968/experimental-design-biotechnology-perry-haaland>. Accessed on: 7 Mar. 2022.

HENKEL, Maximilian; WEIJTJENS, Wout; DEVRIENDT, Christof. Fatigue stress estimation for submerged and sub-soil welds of offshore wind turbines on monopiles using modal expansion. *Energies*, vol. 14, no. 22, 1 Nov. 2021. <https://doi.org/10.3390/en14227576>.

HOANG D. NGUYEN, G.T.T., Myoungsu S., Development of extreme gradient boosting model for prediction of punching shear resistance of r/c interior slabs, *Engineering Structures*, Volume 235, 2021, 112067, ISSN 0141-0296, <https://doi.org/10.1016/j.engstruct.2021.112067>.

HUANG, C.H. "An inverse non-linear force vibration problem of estimating the external forces in a damped system with time-dependent system parameters." *Journal of Sound and Vibration* 242 (2001): 749-765.

HUANG, N.; LU, G.; XU, D. A permutation importance-based feature selection method for short-term electricity load forecasting using random forest. *Energies*, vol. 9, no. 10, 1 Oct. 2016. <https://doi.org/10.3390/en9100767>.

JO, Seong Tae; SHIN, Hyo Seob; LEE, Young Geun; LEE, Ji Hun; CHOI, Jang Young. Optimal Design of a BLDC Motor Considering Three-Dimensional Structures Using the Response Surface Methodology. *Energies*, vol. 15, no. 2, 1 Jan. 2022. <https://doi.org/10.3390/en15020461>.

JOHANSSON, U.; BOSTRÖM, H.; LÖFSTRÖM, T.; LINUSSON, H. Regression conformal prediction with random forests. 97., 2014. *Machine Learning [...]. [S. l.]: Kluwer Academic Publishers, 2014. vol. 97, p. 155–176.* <https://doi.org/10.1007/s10994-014-5453-0>.

KANEKO, S.; TOMIGASHI, A.; ISHIHARA, T.; SHRESTHA, G.; YOSHIOKA, M.; UCHIDA, Y., Proposal for a method predicting suitable areas for installation of ground-source heat pump systems based on response surface methodology. *Energies*, vol. 13, no. 8, 1 Apr. 2020. <https://doi.org/10.3390/en13081872>.

KHANDELWAL, K.; DALAI, A.K. Prediction of Individual Gas Yields of Supercritical Water Gasification of Lignocellulosic Biomass by Machine Learning Models. *Molecules* 2024, 29, 2337. <https://doi.org/10.3390/molecules29102337>

KIM, Y. NELSON, P.A. Optimal regularisation for acoustic source reconstruction by inverse methods, *Journal of Sound and Vibration*, Volume 275, Issues 3–5, 2004, Pages 463-487, ISSN 0022-460X, <https://doi.org/10.1016/j.jsv.2003.06.031>.

KUFEL, J.; BARGIEŁ-Ł., K.; KOCOT, S.; KOŹLIK, M.; BARTNIKOWSKA, W.; JANIK, M.; CZOGALIK, Ł.; DUDEK, P.; MAGIERA, M.; LIS, A.; et al. What Is Machine Learning, Artificial Neural Networks and Deep Learning. Examples of Practical Applications in Medicine. *Diagnostics* 2023, 13, 2582. <https://doi.org/10.3390/diagnostics13152582>

KUN Du, Bo CHEN, A hybrid semi-supervised regression based machine learning method for predicting peak wind loads on a group of buildings, *Engineering Structures*, Volume 275, Part A, 2023, ISSN 0141-0296, <https://doi.org/10.1016/j.engstruct.2022.115245>.

LAI, J.-P.; CHANG, y.-m.; CHEN, C.-H.; Pai, P.F. Uma pesquisa de modelos de aprendizado de máquina em previsões de energia renovável. *Apl. Ciência*. 2020 , 10 , 5975. <https://doi.org/10.3390/app10175975>

LIN, Tzu-Kang; LIANG, Jui-Chang; ZHOU, Guang-Dong; YI, Ting-Hua; XIE, Mei-Xi; CIANG, Chia Chen; LEE, Jung-Ryul; BANG, Hyung-Joon. Structural health monitoring for a wind turbine system: a review of damage detection methods. *Measurement Science and Technology*, vol. 19, no. 12, p. 122001, 13 Oct. 2008. DOI 10.1088/0957-0233/19/12/122001. Available at: <https://iopscience.iop.org/article/10.1088/0957-0233/19/12/122001>. Accessed on: 7 Mar. 2022.

LIU, H.; LIU, T.; CHEN, Z.; WANG, H.; GAO, K.; ZHOU, Z.; TIAN, C.; CHEN, L. Optimization On Extrusion Process for Large Reinforced Thin-Walled Aluminum Profile Based On Experimental Design and Response Surface Method. *Forg. Stamp. Technol.* 2022, 47, 144–152.

LIU, Jie; SUN, Xingsheng; HAN, Xu; JIANG, Chao; YU, Dejie. A novel computational inverse technique for load identification using the shape function method of moving least square fitting. *Computers and Structures*, vol. 144, p. 127–137, 2014. <https://doi.org/10.1016/j.compstruc.2014.08.002>.

LU, Yiqi; LI, Yongpan; XIE, Da; WEI, Enwei; BAO, Xianlu; CHEN, Huafeng; ZHONG, Xiancheng. The application of improved random forest algorithm on the prediction of electric vehicle charging load. *Energies*, vol. 11, no. 11, 1 Nov. 2018. <https://doi.org/10.3390/en11113207>.

LU, Z. R.; LAW, S. S. Force Identification Based on Sensitivity in Time Domain. *Journal of Engineering Mechanics*, vol. 132, no. 10, p. 1050–1056, 1 Oct. 2006. DOI 10.1061/(ASCE)0733-9399(2006)132:10(1050). Available at: <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%290733-9399%282006%29132%3A10%281050%29>. Accessed on: 13 Apr. 2022.

MAIA, N M M; LAGE, Y E; NEVES, M M. Recent Advances on Force Identification in Structural Dynamics. 2012. DOI 10.5772/51650. Available at: <http://dx.doi.org/10.5772/51650>. Accessed on: 13 Apr. 2022.

MACIEJEWSKA, M.; AZIZAH, A.; SZCZUREK, A. IAQ Prediction in Apartments Using Machine Learning Techniques and Sensor Data. *Appl. Sci.* 2024, 14, 4249. <https://doi.org/10.3390/app14104249>

MING L. Wang, Timothy J. Kreitinger, Identification of force from response data of a nonlinear system, *Soil Dynamics and Earthquake Engineering*, Volume 13, Issue 4, 1994, Pages 267-280, ISSN 0267-7261, [https://doi.org/10.1016/0267-7261\(94\)90031-0](https://doi.org/10.1016/0267-7261(94)90031-0).

MNIH, V., KAVUKCUOGLU, K., SILVER, D., RUSU, A. A., VENESS, J., BELLEMARE, M. G., ... & HASSABIS, D. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540), 529-533.

MURPHY, E. T., Robotic excision of aortic valve papillary fibroelastoma and concomitant maze procedure, *Global Cardiology Science and Practice*, Volume 2012, Issue 2, Dec 2013, DOI: <https://doi.org/10.5339/gcsp.2012.27>

NAJAFI, Bahman; ARDABILI, Sina Faizollahzadeh; MOSAVI, Amir; SHAMSHIRBAND, Shahaboddin; RABCZUK, Timon. An intelligent artificial neural network-response surface methodology method for accessing the optimum biodiesel and diesel fuel blending conditions in a diesel engine from the viewpoint of exergy and energy analysis. **Energies**, vol. 11, no. 4, 1 Apr. 2018. <https://doi.org/10.3390/en11040860>.

POLIDORO, A. dos S. Otimização por Superfície de Resposta do Processo de Pirólise de Resíduo Oriundo do Torrador de Café (Silverskin) para a Produção de Bio-Óleo e Caracterização Química por Cromatografia Gasosa Bidimensional Abrangente Acoplada à Espectrometria de Massas Qu. 2016. 142 f. Dissertação – UFRGS, 2016.

QIAO, Baijie; CHEN, Xuefeng; LUO, Xinjie; XUE, Xiaofeng. A novel method for force identification based on the discrete cosine transform. **Journal of Vibration and Acoustics, Transactions of the ASME**, vol. 137, no. 5, 1 Oct. 2015. <https://doi.org/10.1115/1.4030616>.

QIAO, Baijie; ZHANG, Xingwu; GAO, Jiawei; CHEN, Xuefeng. Impact-force sparse reconstruction from highly incomplete and inaccurate measurements. **Journal of Sound and Vibration**, vol. 376, p. 72–94, 18 Aug. 2016. <https://doi.org/10.1016/j.jsv.2016.04.040>.

QIAO, Baijie; ZHANG, Xingwu; GAO, Jiawei; LIU, Ruonan; CHEN, Xuefeng. Sparse deconvolution for the large-scale ill-posed inverse problem of impact force reconstruction. **Mechanical Systems and Signal Processing**, vol. 83, p. 93–115, 15 Jan. 2017. <https://doi.org/10.1016/j.ymssp.2016.05.046>.

Qiao, B., Liu, J., Liu, J., Yang, Z., Chen, X., An enhanced sparse regularization method for impact force identification, *Mechanical Systems and Signal Processing*, Volume 126, 2019, Pages 341-367, ISSN 0888-3270, <https://doi.org/10.1016/j.ymssp.2019.02.039>.

QIU, Binbin; ZHANG, Meng; LI, Xu; QU, Xianqiang; TONG, Fushan. Unknown impact force localisation and reconstruction in experimental plate structure using time-series analysis and pattern recognition. **International Journal of Mechanical Sciences**, vol. 166, 15 Jan. 2020. <https://doi.org/10.1016/j.ijmecsci.2019.105231>.

RACCUGLIA P., ELBERT K.C., ADLER P.D.F., FALK C., WENNY M.B., MOLLO A., et al. Machinelearning-assisted materials discovery using failed experiments. *Nature* 2016; 533:73e6.

RANDALL J. ALLEMANG. The Modal Assurance Criterion –Twenty Years of Use and Abuse. **Sound And Vibration**, p. 14–21, 2003.

REN, Ang; LI, Qingquan; XIAO, Huaishuo. Influence analysis and prediction of ESDD and NSDD based on random forests. **Energies**, vol. 10, no. 7, 2017. <https://doi.org/10.3390/en10070878>.

REZAYAT, A.; NASSIRI, V.; DE PAUW, B.; ERTVELDT, J.; VANLANDUIT, S.; GUILLAUME, P. Identification of dynamic forces using group-sparsity in frequency domain. **Mechanical Systems and Signal Processing**, vol. 70–71, p. 756–768, 1 Mar. 2016. DOI 10.1016/J.YMSSP.2015.09.015. Available at: <https://researchportal.vub.be/en/publications/identification-of-dynamic-forces-using-group-sparsity-in-freque>. Accessed on: 7 Mar. 2022.

RUSHDI, M.A.; RUSHDI, A.A.; DIEF, T.N.; HALAWA, A.M.; YOSHIDA, S.; SCHMEHL, R. Power Prediction of Airborne Wind Energy Systems Using Multivariate Machine Learning. *Energies* 2020, 13, 2367. <https://doi.org/10.3390/en13092367>

Santos, W., Vieira, W., Paiva, J., Análise do efeito de deformações por cisalhamento em estruturas considerando excentricidade na ligação placa-viga. *Revista Tecnológica*. (2022). 30. 65-86. <https://doi.org/10.4025/revtecnol.v30i1.56590>.

SEGAL, Mark R. *Machine Learning Benchmarks and Random Forest Regression*. [S. l.: s. n.], 2003.

Setúbal, F.A.N., Sérgio, S.C.F., Soeiro, N.S., Mesquita, L.A.A. and Nunes, M.V.A. 2022. "Force Identification from Vibration Data by Response Surface and Random Forest Regression Algorithms" *Energies* 15, no. 10: 3786. <https://doi.org/10.3390/en15103786>

SHAIKH, Md Abu Hanif; BARBÉ, Kurt. Wiener-Hammerstein System Identification: A Fast Approach Through Spearman Correlation. *IEEE Transactions on Instrumentation and Measurement*, vol. 68, no. 5, p. 1628–1636, 1 May 2019. <https://doi.org/10.1109/TIM.2019.2896366>. Accessed on: 8 Mar. 2022.

SHEN, H.; SHEN, X.; CHEN, Y. Real-Time Microgrid Energy Scheduling Using Meta-Reinforcement Learning. *Energies* 2024, 17, 2367. <https://doi.org/10.3390/en17102367>

STEVEN J. RIGATTI; Floresta Aleatória. *J Insur Med*, 2017; 47 (1): 31–39. faça: <https://doi.org/10.17849/inasm-47-01-31-39.1>

STEVENS, K.K. Force identification problems—an overview, *Proceedings of the 1987 SEM Spring Conference on Experimental Mechanics*, Houston, TX, USA

TUCCI, M.; PIAZZI, A.; THOMOPULOS, D. Machine Learning Models for Regional Photovoltaic Power Generation Forecasting with Limited Plant-Specific Data. *Energies* 2024, 17, 2346. <https://doi.org/10.3390/en17102346>

WAMBACQ, J.; MAES, K.; REZAYAT, A.; GUILLAUME, P.; LOMBAERT, G. Localization of dynamic forces on structures with an interior point method using group sparsity. *Mechanical Systems and Signal Processing*, vol. 115, p. 593–606, 15 Jan. 2019. <https://doi.org/10.1016/j.ymssp.2018.06.006>.

WOO, Sangbeom; VACCA, Andrea. An Investigation of the Vibration Modes of an External Gear Pump through Experiments and Numerical Modeling. *Energies*, vol. 15, no. 3, 1 Feb. 2022. <https://doi.org/10.3390/en15030796>.

XIE, Yazhou et al. The promise of implementing machine learning in earthquake engineering: A state-of-the-art review. *Earthquake Spectra*, v. 36, n. 4, p. 1769-1801, 2020.

XING L., TIAN Q. L., PENG F., Long-term performance prediction framework based on XGBoost decision tree for pultruded FRP composites exposed to water, humidity and alkaline solution, *Composite Structures*, Volume 284, 2022, 115184, ISSN 0263-8223, <https://doi.org/10.1016/j.compstruct.2022.115184>

XU, X.; JIANG, F.; Li, J.; HUANG, H.; JIANG, C. Multi-Objective Optimization of a Multi-Cavity, Significant Wall Thickness Difference Extrusion Profile Mold Design for New Energy Vehicles. *Materials* 2024, 17, 2126. <https://doi.org/10.3390/ma17092126>

Xuan, P., Wu, X., Cui, H., Qiangguo J., Wang, L., Zhang, T., Nakaguchi, T., Duh, H.B.L., Multi-scale random walk driven adaptive graph neural network with dual-head neighboring node attention for CT segmentation, *Applied Soft Computing*, Volume 133, 2023, 109905, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2022.109905>.

YANG, Y.; GONG, N.; XIE, K.; LIU, Q. Predicting Gasoline Vehicle Fuel Consumption in Energy and Environmental Impact Based on Machine Learning and Multidimensional Big Data. *Energies* 2022, Vol. 15, Page 1602, vol. 15, no. 5, p. 1602, 22 Feb. 2022. DOI 10.3390/EN15051602. Available at: <https://www.mdpi.com/1996-1073/15/5/1602/htm>. Accessed on: 13 Apr. 2022.

YUE Liu, TIANLU Zhao, WANGWEI Ju, SIQI Shi, Materials discovery and design using machine learning, *Journal of Materiomics*, Volume 3, Issue 3, 2017, Pages 159-177, ISSN 2352-8478, <https://doi.org/10.1016/j.jmat.2017.08.002>.

YUNSHENG S., JIYE L., JING L., XINGWANG Z., An efficient instance selection algorithm for k nearest neighbor regression, *Neurocomputing*, Volume 251, 2017, Pages 26-34, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2017.04.018>.

ZHAO, Zhen; XU, Liang; GAO, Jianmin; XI, Lei; RUAN, Qicheng; LI, Yunlong. Multi-Objective Optimization of Parameters of Channels with Staggered Frustum of a Cone Based on Response Surface Methodology. *Energies*, vol. 15, no. 3, p. 1240, 8 Feb. 2022. DOI 10.3390/en15031240. Available at: <https://www.mdpi.com/1996-1073/15/3/1240>.

ZHANG, L., LIU, M., HONG, L., WANG, Z., ZHOU, Z., LIAO, W., An efficient impact force identification methodology via a single sensor utilizing the concept of generalized transmissibility, *Mechanical Systems and Signal Processing*, Volume 211, 2024, ISSN 0888-3270, <https://doi.org/10.1016/j.ymssp.2024>.

ZHOU, J., CAI, Y., DONG, L., ZHANG, B., PENG, Z., Data-physics hybrid-driven deep learning method for impact force identification, *Mechanical Systems and Signal Processing*, Volume 211, 2024, ISSN 0888-3270, <https://doi.org/10.1016/j.ymssp.2024.111238>.

## APENDICE A - RELAÇÃO ENTRE AS METODOLOGIAS UTILIZADAS NESSE TRABALHO E SUAS RESPECTIVAS ÁREAS DE CONHECIMENTO

Este trabalho apresenta uma forte interdisciplinariedade dentro da engenharia e seus resultados possibilitam a sua aplicação em diversas áreas. Com isso, esse tópico tem por finalidade apresentar a área de conhecimento de cada metodologia abordada nessa tese.

Quadro 1: Relação entre as metodologias utilizadas nesse trabalho e suas respectivas áreas de conhecimento.

Metodologia	Área de conhecimento
Análise Modal	Dinâmica dos Sistemas /
Análise Harmônica	Vibrações Mecânicas
Delineamento Composto Central / Superfície de Resposta	Estatística
Aprendizado de Máquinas	Ciência da Computação

Fonte: Autoria própria

A Análise Modal se constitui em uma metodologia que visa determinar as frequências naturais e formas modais associadas a um sistema. A Análise Modal pode ser Experimental, realizada através do fornecimento de energia vibratória ao sistema e consequente medição das respostas ou Análise Modal Numérica, nesse trabalho utilizou-se a análise através do Método de Elementos Finitos, no entanto equações analíticas também podem ser utilizadas, no entanto, o solucionamento através desse método tende a se tornar mais complexo conforme a complexidade do problema aumenta.

A análise harmônica estuda como sistemas respondem a excitações periódicas (harmônicas), e é usada para entender o comportamento em regime permanente quando os sistemas são excitados por forças que variam no tempo de forma harmônica. Tanto a análise modal, quanto a análise harmônica, se encontram dentro da dinâmica dos sistemas e vibrações mecânicas.

O delineamento de experimento (Design of Experiments – DOE) permite realizar uma análise das respostas de um experimento mediante entradas específicas e verificar como esses parâmetros se correlacionam. Um dos métodos DOE que apresenta grande vantagem reside na aplicação da metodologia de delineamento composto central (Central Composite Design – CCD). Por essa metodologia pode-se

explorar o espaço experimental de modo abrangente utilizando um número reduzido de medidas, além de, permitir gerar uma superfície de resposta através de um modelo matemático empírico validado estatisticamente. O método DOE / CCD está localizado dentro da área da estatística e é amplamente utilizado em pesquisa científica, engenharia, ciências biológicas, ciências sociais e economia.

Os métodos de aprendizado de máquinas (machine learning) pertencem à área da ciência da computação, mais especificamente ao campo da inteligência artificial (IA). Contudo, o aprendizado de máquinas é uma área multidisciplinar que também envolve aspectos de matemática, estatística e otimização, sendo amplamente aplicado em diversos domínios, como Ciência da Computação, Matemática e Estatística, Engenharia Elétrica e Engenharia de Controle e Ciências de Dados. Esses métodos possuem grande capacidade em identificar padrões e fazer previsões baseadas em grandes volumes de dados.

## ANEXO A – LINKS PARA ACESSO DOS ALGORÍTMOS DE APRENDIZADO DE MÁQUINAS

Para a análise com o método de aprendizado de máquinas foram considerados seis modelos de aprendizado de máquinas, Método de Florestas Aleatórias, Método kNN (k Nearest Neighbors), Método da Árvore CHAID, Método de Árvore Aleatória, Método da Árvore XGBoost e Método de Redes Nerais Multi Layer Perceptron.

Os códigos de cada método de aprendizado de máquina podem ser acessados gratuitamente no site do <https://scikit-learn.org> e são mostrados a seguir:

- Método de Florestas Aleatórias: <https://scikit-learn.org/dev/modules/generated/sklearn.ensemble.RandomForestRegressor.html>
- Método kNN (k Nearest Neighbors): <https://scikit-learn.org/dev/modules/generated/sklearn.neighbors.KNeighborsRegressor.html#sklearn.neighbors.KNeighborsRegressor>
- Método da Árvore CHAID: <https://scikit-learn.org/1.5/modules/tree.html>
- Método de Árvore Aleatória: <https://scikit-learn.org/stable/modules/generated/sklearn.RandomTreesRegressor.html>
- Método da Árvore XGBoost: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html#sklearn.ensemble.GradientBoostingRegressor>
- Método de Redes Nerais Multi Layer Perceptron: [https://scikit-learn.org/1.5/modules/generated/sklearn.neural\\_network.MLPRegressor.html#sklearn.neural\\_network.MLPRegressor](https://scikit-learn.org/1.5/modules/generated/sklearn.neural_network.MLPRegressor.html#sklearn.neural_network.MLPRegressor)