

DANIEL FERREIRA GONÇALVES

**CONTRIBUIÇÃO AO USO DE INTELIGÊNCIA
ARTIFICIAL PARA DETECÇÃO E DIAGNÓSTICO DE
FALHAS EM MÁQUINAS ROTATIVAS**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

2024

DANIEL FERREIRA GONÇALVES

**CONTRIBUIÇÃO AO USO DE INTELIGÊNCIA ARTIFICIAL PARA
DETECÇÃO E DIAGNÓSTICO DE FALHAS EM MÁQUINAS
ROTATIVAS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **DOUTOR EM ENGENHARIA MECÂNICA**.

Área de concentração: Mecânica dos Sólidos e Vibrações.

Orientador: Aldemir Ap. Cavallini Júnior

UBERLÂNDIA - MG

2024

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

G635 2024	<p>Gonçalves, Daniel Ferreira, 1989- Contribuição ao Uso de Inteligência Artificial para Detecção e Diagnóstico de Falhas em Máquinas Rotativas [recurso eletrônico] / Daniel Ferreira Gonçalves. - 2024.</p> <p>Orientador: Aldemir Aparecido Cavallini Junior. Tese (Doutorado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Mecânica. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.te.2024.293 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Engenharia mecânica. I. Cavallini Junior, Aldemir Aparecido, 1983-, (Orient.). II. Universidade Federal de Uberlândia. Pós-graduação em Engenharia Mecânica. III. Título.</p> <p style="text-align: right;">CDU: 621</p>
--------------	--

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Programa de Pós-graduação em Engenharia Mecânica				
Defesa de:	Tese de doutorado PPGEM				
Data:	28 de fevereiro de 2024	Hora de início:	09:00	Hora de encerramento:	12:00
Matrícula do Discente:	11913EMC001				
Nome do Discente:	Daniel Ferreira Gonçalves				
Título do Trabalho:	Contribuição ao uso de Inteligência Artificial par adeteccção e diagnóstico de falhas em máquinas rotativas				
Área de concentração:	Mecânica dos Sólidos e Vibrações				
Linha de pesquisa:	Dinâmica de Sistemas Mecânica				
Projeto de Pesquisa de vinculação:	Aplicação de técnica de inteligência artificial na captura de dados de máquinas para armazenamento de dados de anormalidades em servidores (Edge Analytics)				

Reuniu-se por meio de videoconferência a Banca Examinadora, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Professores Doutores: ALDEMIR APARECIDO CAVALLINI JR - FEMEC/UFU (Orientador); FRAN SÉRGIO LOBATO - UFU ; MARCUS ANTÔNIO VIANA DUARTE - FEMEC/UFU; TIAGO HENRIQUE MACHADO - UNICAMP; THIAGO GAMBOA RITTO - UFRJ.

Iniciando os trabalhos o presidente da mesa, Dr. ALDEMIR APARECIDO CAVALLINI JR - FEMEC/UFU, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação

interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Aldemir Aparecido Cavalini Junior, Professor(a) do Magistério Superior**, em 29/04/2024, às 11:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Tiago Henrique Machado, Usuário Externo**, em 29/04/2024, às 13:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 29/04/2024, às 13:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Fran Sergio Lobato, Professor(a) do Magistério Superior**, em 29/04/2024, às 17:16, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Thiago Gamboa Ritto, Usuário Externo**, em 06/05/2024, às 11:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5374911** e o código CRC **48452D23**.

Referência: Processo nº 23117.029722/2024-10

SEI nº 5374911

*À minha família, com toda minha
dedicação*

AGRADECIMENTOS

À Deus, meu eterno consolador, que me concedeu a vida, saúde, fé e perseverança diante de todos os desafios.

À minha amada esposa e companheira de vida, Isadora, por todo o amor, cumplicidade, paciência que compartilhamos ao longo dos anos e por dedicar-se incansavelmente à nós e à nossa filha, Isis Gabriele, nosso maior tesouro, inspiração e razão pela qual nos sentimos completos.

À minha família, em especial à minha mãe Maria Abadia e ao meu pai Delcione que sempre me apoiaram e se fizeram presentes nos momentos mais difíceis e são meus maiores exemplos de fé, resiliência e amor incondicional. Se hoje estou de pé é porque vocês ficaram de joelhos em constante oração.

Ao meu irmão Delcione Jr pelo amor, amizade e apoio. Aos meus sogros, Marizete e Edson, deixo também toda minha gratidão pelo acolhimento, incentivo e carinho que sempre dedicaram a mim.

Ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia pela oportunidade concedida, pela estrutura e recursos disponibilizados.

Aos colegas e amigos do laboratório que direta ou indiretamente sempre me ajudaram com meus experimentos e compartilharam seus conhecimentos comigo.

Ao meu orientador, professor Aldemir Ap. Cavallini Jr., pelo seu incansável apoio e ensinamentos ao longo dessa pesquisa. Sua participação foi essencial para o desenvolvimento e conclusão desta tese. É uma honra ter como orientador alguém que admiro não apenas como professor, mas também como um grande amigo que sempre acreditou no meu potencial e nunca se deixou levar pelas minhas dificuldades ou limitações. Fazer parte do grupo de pesquisas em Dinâmica de Rotação é um privilégio incomparável e estar cercado pelos mais brilhantes professores é uma verdadeira inspiração.

Ao professor Marcus Antônio Viana Duarte, por todas contribuições fornecidas.

Aos órgãos de fomento: Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

Por fim, à Petrobrás, através do projeto P&D *Aplicação de técnica de inteligência artificial na captura de dados de máquinas para armazenamento de dados de anormalidades em servidores (Edge Analytics)*, pelo apoio financeiro concedido durante a realização deste trabalho.

GONÇALVES, Daniel Ferreira. **Contribuição ao Uso de Inteligência Artificial para Detecção e Diagnóstico de Falhas em Máquinas Rotativas**. 2024. 136 f. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Uberlândia, Uberlândia, 2024. DOI: <https://doi.org/10.14393/ufu.te.2024.293>.

RESUMO

Sistemas rotativos são amplamente empregados na indústria moderna. A implementação de metodologias para manutenção proativa, que reduz paradas não programadas e aumenta a eficiência operacional, está em ascensão na indústria. No entanto, a disseminação de sistemas de monitoramento e diagnóstico de falhas baseados em Inteligência Artificial (IA) ainda enfrenta desafios tanto na academia quanto na indústria. Algumas falhas, como desbalanceamento, desalinhamento e trincas, apresentam sintomas similares, dificultando o diagnóstico preciso. A ausência de dados históricos rotulados e a escassez de modelos explicáveis, mais transparentes e compreensíveis aos usuários finais também inviabilizam o uso desse tipo de sistema na indústria. Diante disso, o presente trabalho fornece uma metodologia para um sistema de monitoramento e diagnóstico inteligente baseado na combinação de modelos de IA explicáveis e técnicas de análise de vibração. A metodologia proposta é uma solução de baixo custo para a indústria, haja vista que não requer sensores dedicados ou *hardwares* de alto desempenho para o diagnóstico e apresenta possibilidades de integração com serviços online. Dados oriundos de modelos numéricos de rotores sob diversas condições de operação e ensaios experimentais realizados em um sistema rotativo suportado por mancais hidrodinâmicos foram utilizados. A análise de dados experimentais forneceu informações valiosas sobre o comportamento real da máquina e possibilitou a implementação e ajuste de modelos matemáticos confiáveis e, assim, um diagnóstico mais assertivo. Técnicas para extração de características nos domínios do tempo, da frequência e tempo-frequência foram exploradas. A possibilidade de redução dos dados através da seleção das melhores características ou da redução de dimensionalidade também é discutida. Modelos de aprendizado que variam desde um conjunto de clusterizadores até métodos tradicionais, como o *k* Vizinho Mais Próximo (*k*-NN) e as Máquinas de Vetores de Suporte (SVM), foram empregados no reconhecimento das falhas. Posteriormente, ferramentas de explicabilidade foram aplicadas para melhor compreensão das previsões obtidas. As altas taxas de acerto dos modelos, combinadas com sua interpretabilidade, tornam a metodologia

proposta uma ferramenta promissora para o monitoramento e diagnóstico de falhas em sistemas rotativos em ambientes industriais.

Palavras-chave: máquinas rotativas, mancais hidrodinâmicos, monitoramento e diagnóstico de falhas, inteligência artificial explicável.

GONÇALVES, Daniel Ferreira. **Contribution to the use of artificial intelligence for detection and diagnosis of faults in rotating machinery**. 2024. 136 f. Thesis (PhD in Mechanical Engineering) - Federal University of Uberlândia, Uberlândia, 2024. DOI: <https://doi.org/10.14393/ufu.te.2024.293>.

ABSTRACT

Rotary systems are widely employed in modern industry. The implementation of methodologies for proactive maintenance, which reduces unscheduled downtime and increases operational efficiency, is on the rise in the industry. However, the spread of Artificial Intelligence (AI) based monitoring and fault diagnosis systems still faces challenges in both academia and industry. Some failures, such as imbalance, misalignment, and cracks, have similar symptoms, making it difficult to diagnose accurately. The absence of labeled historical data and the scarcity of explainable models that are more transparent and understandable to end users also make the use of this type of system unfeasible in the industry. In view of this, the present work provides a methodology for an intelligent monitoring and diagnosis system based on the combination of explainable AI models and vibration analysis techniques. The proposed methodology is a low-cost solution for the industry, since it does not require dedicated sensors or high-performance hardware for diagnosis and presents possibilities of integration with online services. Data from numerical models of rotors under various operating conditions and experimental tests performed in a rotating system supported by hydrodynamic bearings were used. The analysis of experimental data provided valuable information about the real behavior of the machine and enabled the implementation and adjustment of reliable mathematical models and, thus, a more assertive diagnosis. Techniques for trait extraction in the time, frequency, and time-frequency domains were explored. The possibility of reducing the data by selecting the best features or reducing dimensionality is also discussed. Learning models ranging from an ensemble of clusterizers to traditional methods, such as the k Nearest Neighbor (k -NN) and the Support Vector Machines (SVM), were employed in the recognition of failures. Subsequently, explainability tools were applied to better understand the predictions obtained. The high success rates of the models, combined with their interpretability, make the proposed methodology a promising tool for monitoring and diagnosing failures in rotating systems in industrial environments.

Keywords: Rotating Machines, Hydrodynamic Bearings, Fault Monitoring and Diagnosis, Explainable Artificial Intelligence.

LISTA DE FIGURAS

3.1	Graus de liberdade (<i>gdl</i>) associados ao elemento finito construído para representar o eixo	21
3.2	Representação de um ponto arbitrário B (LALANNE; FERRARIS, 1998)	24
3.3	Representação do elemento de disco (CAVALLINI Jr., 2013)	27
3.4	Configurações para acoplamento do disco ao eixo (LALANNE; FERRARIS, 1998)	29
3.5	Coeficientes de rigidez e amortecimento do mancal (CAVALLINI Jr., 2013)	30
3.6	Coordenadas relativas à massa de desbalanceamento (CAVALLINI Jr., 2013)	31
4.1	Representação esquemática de um mancal cilíndrico radial (SICCHIERI, 2019)	34
4.2	Discretização do domínio via MVF: (a) representação tridimensional; (b) malha discretizada (BARBOSA, 2018)	36
4.3	Volume de controle para o balanço de energia (ALVES, 2011)	38
5.1	Bancada de testes: 1. motor elétrico; 2. inversor de frequência; 3. visor do tacômetro; 4. acoplamento; 5. mancal de rolamento; 6. peça secundária; 7. mancal hidrodinâmico; 8. disco; 9. parafuso para alinhamento	41
5.2	Peça secundária com porca de fixação e anel de armadura	42
5.3	Discos rígidos e suas disposições	42
5.4	Carcaça do mancal com transdutores de força e rolamento auto compensador	43
5.5	Carcaça do mancal hidrodinâmico cilíndrico	43
5.6	Modelo em Elementos Finitos do rotor da bancada experimental	44
5.7	FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #3	47
5.8	FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #22	48
5.9	FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #38	48
5.10	Medição de pontos e seções no rolamento (CAVALLINI Jr. et al., 2017)	49
5.11	Coeficientes de rigidez para B_2 : (a) K_{xx} , (b) K_{xz} , (c) K_{zx} e (d) K_{zz}	51

5.12	Coeficientes de amortecimento para B_2 : (a) C_{xx} , (b) C_{xz} , (c) C_{zx} e (d) C_{zz}	52
5.13	Coeficientes de rigidez para B_3 : (a) K_{xx} , (b) K_{xz} , (c) K_{zx} e (d) K_{zz}	52
5.14	Coeficientes de amortecimento para B_3 : (a) C_{xx} , (b) C_{xz} , (c) C_{zx} e (d) C_{zz}	53
5.15	Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_1 nas direções (a) X e (b) Z	55
5.16	Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_2 nas direções (a) X e (b) Z	55
5.17	Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_1 nas direções (a) X e (b) Z	56
5.18	Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_2 nas direções (a) X e (b) Z	56
5.19	Órbitas experimentais e do modelo matemático nos planos (a) S_1 e (b) S_2	57
6.1	Representação do desalinhamento (a) angular, (b) paralelo e (c) combinado	59
6.2	Desalinhamento paralelo (XIA et al., 2019)	61
6.3	Modelo dinâmico para dois rotores desalinhados conectados por acoplamento flexível (XIA et al., 2019)	61
6.4	Elemento de eixo e parâmetros geométricos (CAVALLINI Jr., 2013)	66
6.5	Modos de carregamentos aplicados à uma trinca (ANDERSON, 2017)	67
6.6	Flexibilidades adicionais em um elemento de eixo (SILVA, 2023)	71
6.7	Flexibilidades adicionais em um elemento de eixo com 4 graus de liberdade por nó (SILVA, 2023)	71
6.8	Coordenadas rotativas para o modelo de trinca (CAVALLINI Jr., 2013)	72
6.9	Abertura e fechamento da trinca (BACHSCHMID; PENNACCHI; TANZI, 2010)	73
6.10	Deflexão estática para rotores pesados (BACHSCHMID; PENNACCHI; TANZI, 2010)	76
6.11	Rigidezes em coordenadas rotativas segundo o modelo de Mayes (SILVA, 2023)	79
6.12	Rigidezes em coordenadas fixas segundo o modelo de Mayes (SILVA, 2023)	79
6.13	Resposta temporal e DFT experimentais em S_1 na direção X em condição normal de operação e com desbalanceamento	80
6.14	Resposta temporal e DFT experimentais em S_1 na direção X em condição normal de operação e com desalinhamento	81

6.15	Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com desbalanceamento	82
6.16	Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com desalinhamento	83
6.17	Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com trinca	84
7.1	Fluxograma da metodologia proposta	86
7.2	Representação gráfica da metodologia de detecção de anormalidades por meio da clusterização	97
7.3	Critério de seleção dos k vizinhos mais próximos	99
7.4	Hiperplano de separação para SVM em uma classificação binária	100
8.1	Bancada experimental de rotor com mancal magnético	106
8.2	Sinal de vibração do rotor com mancal magnético e anomalias inseridas	107
8.3	Exaustor industrial, sensores e placa de aquisição	109
8.4	Características do exaustor industrial e placa de identificação	109
8.5	Sinal de vibração do exaustor industrial e anomalias inseridas	110
8.6	24 melhores características segundo o método de Relevância nos dados numéricos	113
8.7	20 melhores características segundo SHAP e k -NN para cada condição avaliada nos dados numéricos: (a) normal, (b) desbalanceado, (c) desalinhado, e (d) trinca	114
8.8	20 melhores características segundo SHAP e SVM para cada condição avaliada nos dados numéricos: (a) normal, (b) desbalanceado, (c) desalinhado, e (d) trinca	115
8.9	Importância SHAP em (a) k -NN e (b) SVM para os dados numéricos	118
8.10	Importância SHAP em (a) k -NN e (b) SVM para os dados experimentais	121

LISTA DE TABELAS

5.1	Parâmetros determinados pelo procedimento de otimização	47
5.2	Medidas de diâmetro interno para os mancais hidrodinâmicos	50
5.3	Propriedades comuns para os mancais hidrodinâmicos	50
5.4	Parâmetros determinados pelo procedimento de atualização do modelo	54
7.1	Principais medidas estatísticas utilizadas na extração de características	88
8.1	Características da bancada do rotor com mancal magnético	106
8.2	Hiperparâmetros ótimos dos clusterizadores para os dados do rotor com mancal magnético	108
8.3	Resultados da detecção de anormalidades para os dados do rotor com mancal magnético	108
8.4	Hiperparâmetros ótimos dos clusterizadores para os dados do exaustor industrial	110
8.5	Resultados da detecção de anormalidades para os dados do exaustor industrial .	111
8.6	Tempo computacional para os métodos de Relevância e SHAP	116
8.7	Hiperparâmetros ótimos dos classificadores para os dados numéricos	117
8.8	Resultados da classificação de falhas nos dados numéricos	117
8.9	Condições impostas ao sistema rotativo para simulação do desbalanceamento .	119
8.10	Hiperparâmetros ótimos dos clusterizadores para os dados experimentais	119
8.11	Resultados experimentais para detecção de falhas	120
8.12	Hiperparâmetros ótimos dos classificadores para os dados experimentais	120
8.13	Resultados experimentais para classificação de falhas	121

SUMÁRIO

LISTA DE FIGURAS	xiv
LISTA DE TABELAS	xv
CAPÍTULO I - INTRODUÇÃO	1
1.1 Objetivos Gerais e Específicos	5
1.2 Estudos Prévios no LMEst	6
1.3 Organização da Tese	8
CAPÍTULO II - REVISÃO BIBLIOGRÁFICA	10
2.1 Aprendizagem de Máquina	10
2.2 Sistemas Inteligentes para Monitoramento e Diagnóstico de Falhas	11
CAPÍTULO III - DINÂMICA DE ROTORES	19
3.1 Modelagem de Rotores por Elementos Finitos	19
3.2 Força de Sustentação dos Mancais	29
3.3 Massa de Desbalanceamento	31
CAPÍTULO IV - MODELO TERMOHIDRODINÂMICO PARA MANCAIS HIDRO- DINÂMICOS	33
4.1 Modelo para Mancal Hidrodinâmico Cilíndrico Radial	33
4.2 Estimação dos Coeficientes Dinâmicos	39
CAPÍTULO V - BANCADA EXPERIMENTAL DE TESTES	40
5.1 Bancada de Teste	40
5.2 Modelo em Elementos Finitos	43
5.3 Ajuste do Modelo Matemático do Rotor	45
5.4 Estimação dos Coeficientes Dinâmicos para os Mancais Hidrodinâmicos	49

5.5	Respostas ao Desbalanceamento	53
CAPÍTULO VI - MODELO MATEMÁTICO PARA FALHAS		58
6.1	Rotores Desbalanceados	58
6.2	Rotores Desalinhados	59
6.2.1	Desalinhamento em Rotores com Acoplamento Flexível	60
6.2.1.1	Forças de Reação do Desalinhamento Paralelo	60
6.2.1.2	Forças de Reação do Desalinhamento Angular	62
6.3	Eixos com Trincas Transversais	64
6.3.1	Flexibilidade Adicional Introduzida pela Trinca	66
6.4	Representação do <i>Breathing</i>	71
6.5	Equações do Movimento e Linearização para um Eixo Horizontal com Trinca Transversal	76
6.5.1	<i>Breathing Steering Functions</i> para o Modelo de Mayes	78
6.6	Análise Dinâmica de Rotores com Mancais Hidrodinâmicos com Falhas	80
CAPÍTULO VII -METODOLOGIA PROPOSTA		85
7.1	Metodologia Proposta	85
7.2	Extração de Características	86
7.3	Engenharia de Recursos: Redução de Dados	88
7.3.1	Seleção de Características	89
7.3.2	Método de Relevância	91
7.3.3	Redução de Dimensionalidade por PCA	91
7.4	Métodos de Aprendizado Não Supervisionado para Inferência	92
7.4.1	Clusterização de Dados	92
7.4.2	Clusterização Aplicada à Detecção de Anormalidades	96
7.5	Métodos de Aprendizado Supervisionado para Inferência	98
7.5.1	<i>k</i> -Nearest Neighbor (<i>k</i> -NN)	98
7.5.2	Support Vector Machine (SVM)	99
7.6	Otimização dos Hiperparâmetros e <i>Ensemble</i>	101
7.7	Indicadores de Desempenho	102
7.8	Explicabilidade: SHapley Additive exPlanation (SHAP)	104

CAPÍTULO VIII RESULTADOS NUMÉRICOS E EXPERIMENTAIS	105
8.1 Detecção de Anormalidades	105
8.1.1 <i>Benchmark</i> 1: Rotor com Mancal Magnético	106
8.1.2 <i>Benchmark</i> 2: Exaustor Industrial	109
8.2 Diagnóstico de Falhas em Rotores com Mancais Hidrodinâmicos	111
8.2.1 Dados Numéricos	111
8.2.2 Dados Experimentais	118
CAPÍTULO IX - CONCLUSÕES E PERSPECTIVAS FUTURAS	123

CAPÍTULO I

INTRODUÇÃO

Sistemas rotativos são equipamentos de grande aplicabilidade na indústria moderna (LIU et al., 2018; LEI et al., 2020), estando presentes em indústrias de manufatura, unidades geradoras, turbinas eólicas, motores elétricos e aeronáuticos, propelentes marítimos, máquinas de mineração, entre outros (LI et al., 2018; XI et al., 2018; GARCIA et al., 2018; LI; GOEBEL; WU, 2019).

Os mancais hidrodinâmicos estão presentes numa grande maioria de sistemas rotativos devido à sua eficiência, alta capacidade de carga e baixo atrito entre as partes girantes (BARBOSA, 2018; BARBOSA, 2023). Essas vantagens se devem ao fato de que o efeito do amortecimento é mais evidente nesse tipo de mancal devido à presença do filme de óleo, o que ajuda a minimizar o desgaste e prolongar a vida útil dos equipamentos. Devido à minimização do desgaste entre as partes móveis, a presença do filme de óleo contribui para a eficiência e durabilidade operacional.

A busca por produtos e serviços que satisfaçam as necessidades do mercado atual caracterizado pela melhoria da qualidade, redução de custos e aumento da produtividade impulsiona o desenvolvimento de sistemas rotativos cada vez mais leves e com grande capacidade de operação. No entanto, o seu uso contínuo em altas velocidades de rotação, temperaturas extremas e sob constantes variações de carga contribui para a perda de eficiência, ocorrência de falhas e paradas não programadas (MISBAH; LEE; KEUNG, 2023). Diante disso, a implementação de metodologias de manutenção é uma medida crucial para assegurar o funcionamento adequado dos equipamentos e reduzir os impactos negativos.

Metodologias de manutenção permitem uma gestão mais eficiente do sistema rotativo, sendo

fundamentais para prevenir falhas graves e reduzir perdas financeiras. Neste contexto, a manutenção preditiva pode ser realizada mediante a análise de vibração, uma técnica não invasiva com grande potencial de implementação e aplicabilidade, pois reflete diretamente o comportamento do ativo (CIABATTONI et al., 2017). A análise de vibração é uma ferramenta promissora na avaliação da condição de operação do rotor (LIU et al., 2022) oferecendo muitas informações que ajudam na compreensão de sua funcionalidade e monitoramento da sua saúde operacional.

Ciabattoni et al. (2017), Wei et al. (2019), Liu et al. (2022) e Brito (2022) enfatizam que a técnica de análise de vibração se destaca porque: (i) não necessita de paradas para realização das medições, (ii) facilidade no posicionamento dos sensores para aquisição dos dados, (iii) conhecimento abrangente de características que evidenciam as possíveis falhas mecânicas, (iv) tempo de aquisição viável para o monitoramento de uma maior quantidade de ativos e (v) disponibilização de informações intrínsecas dos equipamentos, condições mecânicas, elétricas e até mesmo estruturais.

A constante ascensão da Indústria 4.0 possibilita inovações tecnológicas, promovendo transformações significativas nos processos industriais. A integralização de tecnologias digitais avançadas, tais como, Inteligência Artificial (IA), Internet das Coisas (IoT), sistemas ciberfísicos (CPS), *Big Data* e Computação em Nuvem, contribuem para o surgimento de sistemas de monitoramento e diagnóstico cada vez mais autônomos. Quando comparados aos métodos tradicionais, estes sistemas inteligentes oferecem maior confiabilidade, precisão e robustez nas tomadas de decisões, além de promover, em tempo real, *insights* acerca da condição de operação do ativo (LIU et al., 2018).

Um sistema inteligente de monitoramento e diagnóstico de falhas em máquinas rotativas é um problema de reconhecimento de padrões caracterizado pela integração de técnicas de extração de características e ferramentas de IA (LIU et al., 2018). Essa combinação é uma tendência crescente na indústria devido à competitividade no contexto da economia globalizada (BRITO, 2022). Segundo Liu et al. (2016), normalmente estes sistemas possuem algumas etapas básicas: aquisição e processamento de dados, extração de características e reconhecimento da falha.

A aquisição e processamento dos sinais de vibração envolve o uso de filtros para diversas finalidades, como filtragem de ruído e separação de componentes. A extração de características representativas abrange os domínios do tempo, da frequência e tempo-frequência (LIU et al., 2018; BRITO, 2022; WU et al., 2023).

Grande maioria dos métodos de diagnóstico são sensíveis à dimensão dos dados. Uma alternativa para contornar o problema da dimensionalidade é a aplicação de métodos para seleção de características mais relevantes e discriminativas dos dados originais, destacando métodos como o de Relevância (URBANOWICZ et al., 2018) para seleção de dados mais importantes e a Análise de Componentes Principais (PCA) (JOLLIFFE; CADIMA, 2016) para a redução de dimensionalidade. Estes métodos são essenciais para lidar de forma eficaz com a complexidade e o volume de dados presentes, pois permitem uma representação mais compacta e simplificada dos dados para uma análise subsequente.

O monitoramento e diagnóstico de falhas inclui a adoção de modelos de IA (LIU et al., 2018; LEI et al., 2020) constituídos por métodos de aprendizagem de máquina (do inglês, *Machine Learning* - ML), tanto supervisionados: *Artificial Neural Networks* (ANN), *Decision Tree* (DT), *k-Nearest Neighbors* (*k*-NN), *Naive Bayes* (NB) e *Support Vector Machines* (SVM); quanto não supervisionados: *K*-means, clusterização hierárquica, *Gaussian Mixture Models* (GMM) baseada em *Expectation Maximization* (EM), *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN), dentre outros. Vale destacar ainda a ampla adoção de modelos constituídos por métodos de aprendizagem profunda (*Deep Learning* - DL), tais como, *Autoencoder* (AE), *Convolutional Neural Networks* (CNN), *Deep Belief Network* (DBN) e *Residual Neural Networks* (RNN). Na arquitetura desses métodos, a necessidade de extração de características é suprimida, uma vez que adotam um procedimento realizado de forma indireta dentro do modelo, por meio de relações não lineares.

Apesar dos modelos de DL serem capazes de aprender e extrair as características relevantes dos dados durante o processo de treinamento, dispensando a etapa explícita de extração de características, as falhas mecânicas em máquinas rotativas são bem conhecidas e a exploração de características específicas pode ser altamente benéfica. A teoria da aprendizagem estatística possui bases teóricas rigorosas que promovem a construção de modelos diagnósticos baseados em características, fornecendo resultados de fácil compreensão (LEI et al., 2020). Essa abordagem permite uma interpretação mais clara das relações entre as características dos dados e os resultados, facilitando a análise e tomada de decisão por parte dos usuários finais (ZHANG; YANG; WANG, 2019).

Diante da vasta gama de métodos de aprendizado disponíveis, o desenvolvimento de um sistema de monitoramento e diagnóstico ainda é uma tarefa desafiadora devido a diversos fatores. Primeiramente, as falhas afetam diretamente o comportamento dinâmico da máquina (SILVA,

2023) e, devido às não linearidades envolvidas, elas podem apresentar sintomas similares, culminando em classificações errôneas (ARCO-VERDE, 2008). Além disso, a implementação de métodos de aprendizado enfrenta limitações significativas devido à falta de exemplos rotulados que representem todas as condições operacionais necessárias, conforme discutido por Ciabattini et al. (2017). Por fim, a carência de modelos explicáveis, mais transparentes e compreensíveis dificulta a disseminação desses sistemas na indústria (LEI et al., 2020).

Um banco de dados universal com exemplos rotulados para todas as possíveis condições de operação em uma máquina rotativa é impraticável no mundo real. Para contornar esse problema, um dos adventos da Indústria 4.0 oferece uma solução por meio da implementação de sistemas ciberfísicos (CPS), os chamados gêmeos digitais (*Digital Twins*), que são sistemas compostos por pelo menos três componentes: um sistema físico, um modelo virtual e conexões entre ambos (TAO; QI; NEE, 2022). Devido à sua capacidade representativa, esses sistemas estão ganhando notoriedade tanto na academia quanto na indústria, sendo aplicados em diversas áreas, incluindo monitoramento de operações, simulação, otimização e manutenção preditiva (LIU; ONG; NEE, 2022).

O monitoramento e diagnóstico de falhas a partir dos gêmeos digitais é baseado na teoria da dinâmica física com ênfase no desenvolvimento de modelos matemáticos, permitindo maiores informações sobre o comportamento da máquina em condições de operação específicas (SILVA, 2023; LIU; ONG; NEE, 2022). A representação digital de um sistema rotativo físico por meio de modelos matemáticos não apenas aprimora a compreensão de seu comportamento, mas também permite a geração de dados em situações onde a obtenção de informações por meio de ensaios experimentais é impraticável. Diante disso, os gêmeos digitais possibilitam a geração de um conjunto de dados para o treinamento dos métodos de aprendizado sem a necessidade de uma grande quantidade de exemplos rotulados do mundo real.

A difusão de sistemas inteligentes para monitoramento e diagnóstico na indústria carece de metodologias mais transparentes e compreensíveis para os usuários finais. A compreensão de como o modelo tomou uma decisão específica transmite maior confiabilidade aos especialistas (BRITO, 2022). Na literatura, percebe-se uma crescente demanda para desenvolvimento e implementação de modelos de Inteligência Artificial Explicável, do inglês *EXplainable Artificial Intelligence* (XAI).

Esforços significativos têm sido dedicados à adoção de ferramentas de explicabilidade, como o método SHapley Additive exPlanation (SHAP). A unificação e adaptação desta fer-

ramenta para interpretabilidade de modelos de IA foram conduzidas no estudo de Lundberg e Lee (2017). Essa ferramenta permite atribuir a cada característica um valor de importância, chamado de valor SHAP, que reflete na sua contribuição no resultado final do modelo. Os valores SHAP oferecem informações valiosas sobre a relação entre as características e o processo de tomada de decisão de um determinado método de aprendizado (GEBREYESUS et al., 2023).

1.1 Objetivos Gerais e Específicos

A Tese de Doutorado apresenta um sistema de monitoramento e diagnóstico de falhas em sistemas rotativos com mancais hidrodinâmicos. A metodologia proposta é uma solução de baixo custo para a indústria, haja vista que não requer sensores dedicados ou *hardware* de alto desempenho para o diagnóstico e apresenta possibilidades de integração com serviços online. Falhas como o desbalanceamento, desalinhamento e trincas são exploradas, as quais frequentemente exibem sintomas similares. Modelos matemáticos são desenvolvidos e ensaios numa bancada de testes experimentais são realizados para a obtenção de dados. Métodos de aprendizado supervisionado e não supervisionado são utilizados no monitoramento e diagnóstico. Ferramentas de explicabilidade são empregadas, garantindo resultados mais transparentes e compreensíveis aos usuários.

A utilização de uma bancada testes para um sistema rotativo suportado por mancais hidrodinâmicos se revela importante para o presente estudo. Os ensaios experimentais não apenas validam o modelo matemático, mas também fornecem informações valiosas sobre o comportamento real do rotor. Esse fato contribui de maneira crucial para o desenvolvimento de modelos digitais robustos, além de fornecer informações valiosas que aprimoram a eficácia da metodologia de monitoramento e diagnóstico.

Alguns dos objetivos específicos delineados incluem: (i) instrumentação e validação de uma bancada para testes com um sistema rotativo suportado com mancais hidrodinâmicos; (ii) desenvolvimento e implementação de modelos matemáticos incluindo falhas como desbalanceamento, desalinhamento e trincas; (iii) organização de um conjunto de dados numéricos e experimentais; (iv) estudo e implementação de técnicas de extração de características a partir da análise de vibração, bem como de métodos para redução de dados; (v) propor uma metodologia para um sistema de monitoramento e diagnóstico de falhas mediante métodos de aprendizado e ferramentas de explicabilidade.

1.2 Estudos Prévios no LMEst

O Laboratório de Mecânica de Estruturas "José Eduardo Tannús Reis" (LMEst) da Faculdade de Engenharia Mecânica da Universidade Federal de Uberlândia (FEMEC-UFU) tem contribuído de forma significativa em pesquisas realizadas no campo da dinâmica de máquinas rotativas, incluindo trabalhos dedicados ao estudo e aplicação de técnicas de monitoramento da integridade estrutural que são apresentados a seguir.

Cavallini Jr. (2013) propôs duas técnicas de monitoramento da integridade estrutural com o objetivo de identificar trincas transversais em eixos. O primeiro método, baseado no comportamento não-linear da trinca, e o segundo baseado na impedância eletromecânica. Três modelos de trincas foram abordados em suas análises com base em simulações computacionais e validação experimental.

Leão (2019) apresentou o ajuste de um modelo matemático que representa o comportamento dinâmico de uma máquina rotativa real, além da aplicação numérica e experimental de um método de detecção de falhas baseado no sinal de vibração do rotor e de um método de controle ativo de trincas que reduziu os níveis dos super-harmônicos 2X e 3X excitados pela presença da trinca no espectro de frequência do rotor.

Rende (2020) desenvolveu um modelo matemático de rotor acoplado a quatro vigas (palletas) que representam as pás. Foi também realizado um estudo da estabilidade do sistema utilizando a teoria de Floquet e a transformação de coordenadas multi-pás. Em continuidade, mas já inserindo defeitos do tipo trinca transversal nestas estruturas, Nascimento (2022) analisou o comportamento dinâmico deste sistema, adicionando ao mesmo a modelagem FLEX para introduzir a trinca nas palletas.

Em sua tese, Silva (2023) compara três modelos de trinca da literatura, demonstrando duas técnicas de SHM, a saber: combinação de ressonância e cálculo da derivada de segunda ordem do modo de vibrar. A metodologia é avaliada por meio de ensaios numéricos e experimentais, mostrando que as técnicas propostas identificam e localizam trincas transversais em máquinas rotativas, contribuindo para aprimorar segurança e eficiência de sistemas rotativos durante sua operação.

Atualmente, observa-se uma notável evolução, com ênfase na modelagem robusta dos componentes que compõem os sistemas rotativos, tais como, mancais e selos. Vários trabalhos sobre controle de vibração, utilização de mancais hidrodinâmicos e magnéticos têm sido desen-

volvidos continuamente pelo LMEst, cujos objetivos incluem o ensino e a pesquisa aplicados aos estudos do comportamento estático e dinâmico de estruturas.

O trabalho de Oliveira (2019) sintetiza controladores para rotores supercríticos com mancais magnéticos. Dois controladores PID foram desenvolvidos e avaliados com base em funções de transferência e respostas ao desbalanceamento para criação e sistematização de um metamodelo *Kriging* no estudo e projeto desses rotores.

Carvalho (2022) propõe uma metodologia de balanceamento via sinais de vibração através do *Kriging*. Neste caso, o metamodelo desenvolvido é alimentado por amostras de entrada (condições de desbalanceamento) e saída (massas e posições de correção) provenientes do Método do Coeficiente de Influência (MCI). Já em 2023, no trabalho de Cabral (2023), o autor propõe uma abordagem de balanceamento sem o uso de massas de teste, utilizando redes neurais, treinada a partir de respostas de vibração de ensaios numéricos e experimentais.

Barbosa (2023) avalia os efeitos da pressão de injeção de óleo no comportamento dinâmico de um mancal segmentado hidrodinâmico axial sujeito à lubrificação híbrida por meio de um modelo termo hidrodinâmico para determinar a posição de equilíbrio em diferentes regimes de lubrificação e, posteriormente, os métodos da perturbação e da redução em frequência são empregados para calcular os coeficientes de rigidez e amortecimento equivalentes do mancal em diversas condições operacionais.

Atualmente, o desenvolvimento de metodologias baseadas em IA para monitoramento e diagnóstico de falhas em máquinas rotativa é uma demanda crescente em pesquisas conduzidas pelo LMEst. Além de trazer contribuições importantes ao diz respeito à detecção e identificação de falhas, ao direcionar os esforços para a integração da IA no domínio da dinâmica de máquinas rotativas, a presente tese não apenas amplia o escopo das investigações do LMEst, mas também se alinha perfeitamente com as tendências emergentes tanto no meio acadêmico quanto na indústria.

Neste contexto, destaca-se o advento dos rotores inteligentes, tema de grande interesse em pesquisas vinculadas o Instituto Nacional de Ciência e Tecnologia de Estruturas Inteligentes em Engenharia (INCT-EIE). Esses equipamentos combinam tecnologias de rotor com recursos avançados de IA e automação para melhorar o seu desempenho e eficiência, sendo capazes de detectar e analisar seu comportamento dinâmico, identificar falhas, promover ações de controle para garantir o seu funcionamento de acordo com padrões previamente estabelecidos e prever seu comportamento futuro.

Vale ressaltar ainda que esta Tese de Doutorado foi elaborada no âmbito do projeto de P&D *Aplicação de Técnica de Inteligência Artificial na Captura de Dados de Máquinas para Armazenamento de Dados de Anormalidades em Servidores (Edge Analytics)*, uma iniciativa desenvolvida pela Petrobrás em colaboração com o LMEst.

1.3 Organização da Tese

Além deste Capítulo introdutório, esta Tese de Doutorado conta ainda com outros 8 capítulos, além das referências bibliográficas. Todos brevemente descritos a seguir.

O Capítulo II compreende uma revisão bibliográfica acerca de trabalhos científicos recentes que investigaram sistemas de monitoramento e diagnóstico de falhas em máquinas rotativos baseados em métodos de aprendizado. Aspectos como os principais avanços, desafios e tendências são analisados e discutidos.

O Capítulo III apresenta a formulação da equação diferencial que compõe o modelo matemático do rotor, desenvolvido pelo método de elementos finitos a fim de representar adequadamente o comportamento dinâmico de sistemas rotativos. Detalha-se a formulação das matrizes elementares que, por sua vez, abrangem as matrizes de massa, rigidez, amortecimento, efeitos giroscópicos, entre outras.

O Capítulo IV descreve a formulação matemática de um modelo termohidrodinâmico para a determinação dos coeficientes dinâmicos dos mancais hidrodinâmicos presentes no sistema rotativo considerado. São apresentadas as equações diferenciais que governam o comportamento dinâmico do filme de óleo, o método de discretização dessas equações e o procedimento de solução.

O Capítulo V apresenta detalhes da bancada de testes do sistema rotativo suportado por mancais hidrodinâmicos utilizada para obtenção de dados. Além dos detalhes acerca das partes constituintes do sistema rotativo, são apresentados seu respectivo modelo matemático e ajuste.

O Capítulo VI descreve a modelagem matemática de falhas que ocorrem em sistemas rotativos, tais como o desalinhamento em rotores com acoplamentos flexíveis e trincas transversais considerando a modelagem do fenômeno *breathing* por meio do modelo de Mayes. Posteriormente, análises numéricas e experimentais referentes ao comportamento dinâmico do rotor na presença de falhas são realizadas.

O Capítulo VII apresenta a metodologia proposta, abrangendo ferramentas matemáticas e

computacionais a serem empregadas para o desenvolvimento do sistema de monitoramento e diagnóstico.

O Capítulo VIII apresenta os resultados obtidos pelo sistema de monitoramento e diagnóstico de falhas proposto por meio de conjunto de dados experimentais e numéricos.

O capítulo IX discorre sobre as conclusões e apresenta algumas sugestões para desenvolvimentos futuros.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

Nesta revisão bibliográfica são apresentados trabalhos correlatos que investigam a aplicação de sistemas de monitoramento e diagnóstico de falhas em máquinas rotativas por meio de métodos de aprendizado. Ao revisar a literatura, almeja-se entender os principais avanços, desafios e tendências atuais. Esta abordagem permite maior compreensão acerca dos principais métodos utilizados e identificando as melhores alternativas para o problema.

2.1 Aprendizagem de Máquina

O aprendizado de máquina é uma subárea de IA que se concentra na capacidade dos sistemas de aprender e se adaptar. Fundamentados em princípios matemáticos e estatísticos, os métodos de aprendizado possuem capacidade de adquirir conhecimento e gerar *insights* para tomada de decisões. Devido a essas vantagens, a utilização desses métodos em sistemas de monitoramento e diagnóstico para máquinas rotativas é uma estratégia promissora (LIU et al., 2018).

Em sua grande maioria, sistemas de diagnóstico em máquinas rotativas são organizados em etapas que envolvem desde a coleta de dados até sua integração em sistemas de produção. Durante o processamento de dados, são utilizadas técnicas de extração de dados mediante os sinais de vibração e métodos para seleção ou redução de dados. Em seguida, os métodos de aprendizado são empregados. Após o treinamento e ajuste dos seus respectivos hiperparâmetros, a desenvoltura destes métodos é avaliada segundo indicadores de desempenho.

Em seu trabalho, Alpaydin (2020) destaca a diversidade dos métodos com aprendizado supervisionado, não supervisionado, abordagens híbridas bem como técnicas especializadas, como o aprendizado por reforço, semi-supervisionado e por transferência. Nas abordagens su-

pervisionadas, os métodos são treinados com dados rotulados, onde cada entrada está associada a uma saída correspondente, ou seja, os algoritmos aprendem a relação entre os *inputs* e *outputs* a partir dos exemplos fornecidos durante o treinamento. Por outro lado, em abordagens não supervisionadas, os métodos agrupam amostras sem conhecimento prévio de suas classes ou saídas. Algoritmos de clusterização são exemplos comuns de abordagens não supervisionadas, cujo objetivo é identificar padrões ou estruturas nos dados sem a orientação de rótulos.

2.2 Sistemas Inteligentes para Monitoramento e Diagnóstico de Falhas

O uso contínuo de sistemas rotativos em condições extremas pode comprometer seu correto funcionamento devido ao surgimento de falhas que, se não suprimidas em tempo hábil, acarretam em perdas econômicas significativas e danos irreparáveis. Diante disso, a utilização de metodologias de manutenção nestes sistemas são de suma importância.

Os avanços na automação de processos industriais está transformando a forma como as empresas abordam a manutenção de seus ativos permitindo, assim, a adoção de metodologias orientadas por dados. Neste cenário, a manutenção preditiva (PdM) se destaca como uma abordagem promissora. A utilização de dados e a empregabilidade de métodos de aprendizado neste tipo de manutenção possibilita o desenvolvimento de sistemas inteligentes para monitoramento e diagnóstico de falhas (ZHANG; YANG; WANG, 2019). Atualmente, esses sistemas estão sendo amplamente explorados e difundidos tanto na indústria quanto na academia, fato que inspirou o desenvolvimento desta Tese de Doutorado.

Em Tahir et al. (2016) é abordada a detecção precoce e precisa de falhas em rotores com foco em desbalanceamento e desalinhamento que apresentam padrões de frequência semelhantes. O procedimento de desbalanceamento, que envolve adição ou remoção de peso, pode causar problemas adicionais se aplicado incorretamente para corrigir desalinhamentos. O estudo propôs o uso de vibrações radiais e axiais, analisando a sensibilidade estatística de recursos de domínio de tempo extraídos desses sinais multi-eixos. O método utilizado foi o SVM para determinar a eficácia, alcançando 100% de precisão na detecção dessas falhas, o que garantiu um diagnóstico preciso antes de ações corretivas serem tomadas.

Liu et al. (2018) apresentaram uma revisão sobre recentes pesquisas e o desenvolvimento de métodos de aprendizado no diagnóstico de falhas de máquinas rotativas, tanto do ponto de vista teórico quanto em relação à sua aplicabilidade. Os autores caracterizaram três tarefas básicas

para o diagnóstico de falhas: (i) determinar se o equipamento está normal ou não (detecção de anomalias); (ii) encontrar a falha incipiente e sua razão (classificação de falhas); e (iii) prever a tendência de desenvolvimento de falhas. Neste mesmo trabalho, são apresentados desde algoritmos de classificação, como o *k-Nearest Neighbors* (*k*-NN), *Naive Bayes* (NB) e *Support Vector Machines* (SVM), até *Artificial Neural Networks* (ANNs) e *Deep Neural Network* (DNN). Os autores também discutem as vantagens e desvantagens de cada método e apontam que as técnicas de aprendizado de máquina tendem a continuar como técnicas atrativas para o diagnóstico de falha de máquinas rotativas.

Zhang, Yang e Wang (2019) abordaram a importância da PdM baseada em métodos de aprendizado para diagnóstico de falhas e avaliação da vida útil do ativo. O PdM baseado em dados inclui os subprocessos: (i) aquisição e pré-processamento de dados, (ii) engenharia de recursos, incluindo extração e seleção de recursos; e (iii) treinamento e previsão dos modelos. Observa-se que a pesquisa PdM ainda está em estágio experimental, com a maioria dos estudos usando conjuntos de dados abertos, como o caso da *Western Reserve University (CWRU) / Intelligent Maintenance Systems (IMS)*. O artigo dá ênfase nos métodos orientados a dados para PdM, explorando, segundo diversas aplicações, a precisão dos métodos de aprendizado, tais como, *Logistic Regression* (LR), SVM, DT, *Random Forest* (RF), quanto algoritmos de deep learning, como as ANNs, DNNs e AEs, que são comumente mais atrativos. O trabalho também apresenta um resumo dos recursos comuns e discute direções potenciais.

Lei et al. (2020) apresentaram uma ampla revisão direcionada em aplicações de métodos de aprendizado para detecção de falhas. Os autores fornecem uma visão histórica, desenvolvimentos atuais e perspectivas futuras. Neste trabalho foram abordados os principais métodos de aprendizado supervisionado e não supervisionado, além dos métodos de aprendizado profundo. Os autores enfatizam a dependência de dados reais e rotulados da máquina em análise e destacam a importância recente e futura no cenário do diagnóstico inteligente de falhas dos modelos explicáveis, com interesse crescente a partir de 2017. Por fim, os autores concluem que apesar dos avanços recentes do aprendizado profundo, os métodos tradicionais de aprendizado não devem ser abandonados, uma vez que a investigação da aprendizagem estatística, frente ao Big Data industrial, pode promover a construção de sistemas de diagnósticos com parâmetros, características e resultados de fácil compreensão.

Em Rodrigues, Cairo Júnior e Rade (2022) realizou-se um estudo comparativo de métodos de aprendizado para o diagnóstico de falhas em máquinas rotativas, utilizando imagens de es-

pectros de vibração. A extração de características de diferentes tipos de falhas é realizada através do processamento de imagens espectrais de órbitas de vibração durante o arranque da máquina, abrangendo desbalanceamento, desalinhamento, trinca de eixo, fricção rotor-estator e instabilidade hidrodinâmica. Os classificadores são treinados e testados com dados simulados, sendo estes gerados por um modelo numérico desenvolvido com o método dos elementos finitos. O estudo avaliou métodos de aprendizado profundo, conjuntos e métodos tradicionais de classificação. Apesar do custo computacional considerável, os resultados indicaram que o método baseado em CNNs apresentou o melhor desempenho na capacidade de generalizar a classificação de imagens, mesmo em padrões de testes experimentais não utilizados durante o treinamento.

Lupea e Lupea (2022) abordaram o desenvolvimento de um sistema para analisar e detectar defeitos de montagem em um banco de testes rotativo. O banco de testes foi composto por um eixo delgado com um disco central, suportado simetricamente por rolamentos de esferas oscilantes e acionado em velocidade constante por uma correia dentada. Diversas falhas, como a translação do disco central ao longo do eixo, excentricidade do disco e defeitos na posição do motor-redutor ou na montagem da correia dentada, foram introduzidas. Características no domínio do tempo e da frequência, extraídas do sinal de vibração, foram utilizadas como preditores na detecção de falhas. O problema foi modelado como uma tarefa de classificação multiclasse com oito estados de saúde: um saudável e sete defeituosos. A análise de dados, utilizando algoritmos não supervisionados e supervisionados, forneceram informações relevantes sobre o conjunto de dados inicial e equilibrado, incluindo a relevância das características, correlações entre eles, dificuldades de classificação e visualização de dados. Experimentos realizados com classificadores do MATLAB e seis conjuntos de características mostraram que o SVM quadrático alcançou o melhor desempenho, com 99,18% de precisão para o conjunto completo de 41 características e 98,93% de precisão para o subconjunto dos 18 características mais relevantes, extraídos dos eixos X e Y do acelerômetro.

O estudo de Das e Das (2023) investigou o impacto de diferentes modelos de *wavelet* mãe, seleção de sensores e métodos de aprendizado para o diagnóstico inteligente de falhas em máquinas rotativas usando a transformada *wavelet* discreta (DWT). Foram analisadas as *wavelets Daubechies*, *Haar*, *Biorthogonal* (Bior), *Symlets* (Sym) e *Coiflets* (Coif) em termos de distinção entre desbalanceamento, desalinhamento horizontal/vertical e falhas específicas em rolamentos. Duas abordagens de monitoramento de falhas foram propostas: *Single-Step Fault*

Monitoring (SSF_M) e *Two-Step Fault Monitoring* (TSF_M). No SSF_M, os métodos identificaram o tipo de falha diretamente, enquanto no TSF_M eles primeiro determinam se a máquina está com defeito e, em caso afirmativo, identificam o tipo de falha. Os métodos, incluindo RF, *AdaBoost com C4.5* (AB-C4.5) e duas ANNs, foram treinadas com características extraídas pela DWT. O estudo também avaliou o impacto do tipo de sensor no diagnóstico de falhas. Os resultados indicaram que as *wavelets Bior3.1* e *Haar* tiveram melhor desempenho na distinção de tipos de falhas, enquanto o RF-Bior3.1 alcançou as melhores acurácias para SSF_M (99,80%) e TSF_M (99,98%). A correlação entre o tipo de sensor e a *wavelet* mãe selecionada também foi destacada.

Em Saha, Hoque e Badihi (2022) desenvolveu-se uma técnica de diagnóstico inteligente para identificar diversas falhas em rolamentos de esferas em máquinas rotativas. Um experimento foi realizado para gerar dados defeituosos, simulando condições como falha na pista interna, falha na pista externa e falha na gaiola, além da condição saudável. Os dados de vibração foram convertidos em espectros de frequência usando a transformada rápida de Fourier (FFT) e analisados para detecção de falhas no rolamento. Uma contribuição significativa foi a aplicação de um método de aprendizado, especificamente a SVM, para o diagnóstico de falhas. O SVM foi otimizado usando a técnica de otimização de enxame de partículas (PSO) para melhorar o desempenho do modelo. A precisão da classificação alcançada com SVM otimizado por PSO foi de 93,9%, superando a precisão obtida pelo SVM com um otimizador de validação cruzada tradicional (92%). O modelo proposto também foi comparado com outros métodos de aprendizado tradicionais, demonstrando um desempenho superior em todos os casos.

O trabalho de Singh et al. (2023) abordou a importância do monitoramento e diagnóstico de falhas em máquinas industriais na era da Indústria 4.0, destacando a complexidade e a dificuldade associadas a essas tarefas. O texto destaca a aplicação crescente de técnicas inteligentes como uma parte crucial do monitoramento de condições em máquinas mecânicas e elétricas. Uma revisão das aplicações bem-sucedidas de técnicas de diagnóstico de falhas baseadas em métodos de aprendizado é apresentada, abrangendo um período de vinte anos (2000 a 2020). A literatura revisada aborda especificamente diagnósticos baseados em métodos de aprendizado para várias máquinas, incluindo motores de indução, rolamentos, engrenagens e bombas centrífugas, oferecendo uma discussão detalhada sobre cada aplicação. O artigo conclui com observações sobre lacunas de pesquisa, novas ideias e uma síntese geral das descobertas.

No estudo de Das, Das e Birant (2023), uma abrangente revisão dos procedimentos de Di-

agnóstico e Prognóstico Inteligente de Falhas (IFDP) para máquinas rotativas foi realizada, em resposta ao advento da Indústria 4.0. O texto se utiliza de gráficos informativos para destacar os desafios associados à avaliação de modelos, aplicabilidade em cenários reais, desenvolvimento de modelos específicos de falhas e outros aspectos como a existência de falhas compostas, adaptabilidade de domínio, fontes e aquisição de dados, fusão de dados, seleção de algoritmos e otimização. Cada componente das máquinas rotativas é considerado, reconhecendo que os desafios individuais de cada peça impactam de forma única nos indicadores vitais das máquinas. O estudo revisita as abordagens IFDP em relação às estratégias de análise de falhas, fontes e tipos de dados, técnicas de fusão de dados, técnicas de aprendizado de máquina, e falhas compostas em componentes como rolamentos, engrenagens, rotor, estator, eixo, entre outros. Desafios e direções futuras são apresentados a fim de orientar pesquisas posteriores.

Em sua tese de doutorado, Brito (2022) abordou o diagnóstico de falhas em máquinas rotativas com base em IA, visando aumentar a produtividade e reduzir custos industriais. Técnicas com diferentes tipos de aprendizados foram exploradas na análise dos dados, como sinais de vibração, a fim de fornecerem diagnósticos da condição operacional do ativo. A tese propõe metodologias inovadoras para o diagnóstico de falhas, com ênfase em IA explicável e análise de vibração. Soluções foram apresentadas para explicar modelos de maneira compreensível por usuários e especialistas, além de abordar a escassez de dados históricos rotulados. Entre as propostas, destacam-se uma estrutura para a identificação automática de bandas de frequência relevantes em sinais de vibração (Fator de Relevância de Banda - BRF), uma abordagem de identificação não supervisionada de falhas e classificação não supervisionada do tipo de falha com base na análise da relevância dos parâmetros. Além disso, é desenvolvida uma abordagem de classificação baseada em transferência de aprendizado em um conjunto de dados sintético, denominada Detecção de Falhas usando Inteligência Artificial Explicável (FaultD-XAI). A eficácia dessas abordagens é demonstrada em conjuntos de dados contendo diferentes falhas mecânicas.

Grande maioria dos trabalhos referenciados acima, utilizaram-se de métodos com aprendizado supervisionado necessitando de entradas rotuladas, fato que limita a sua aplicação em situações reais, já que a obtenção de conjuntos de dados rotulados para todas as condições reais de operação de uma máquina é impraticável (LIU et al., 2018; WANG et al., 2020). Diante disso, métodos de aprendizado não supervisionado se mostram como uma opção promissora para tarefas de monitoramento em máquinas rotativas.

Rai e Upadhyay (2017) propuseram um novo método para avaliar a degradação do desempenho (PDA) em rolamentos, utilizando uma combinação de decomposição de modo empírico (EMD) e agrupamento. As características de falha são extraídas dos sinais dos rolamentos por meio do processo EMD. Esses recursos são então submetidos a um processo de agrupamento pelo método *K*-medóides para obter os centros de cluster do estado normal e do estado de falha. Uma curva de valor de confiança (CV) é derivada da dissimilaridade do objeto de dados de teste em relação ao estado normal, sendo utilizada como indicador de degradação para avaliar a saúde dos rolamentos. A abordagem proposta é aplicada a sinais de vibração coletados em testes de funcionamento até a falha de rolamentos, demonstrando sua eficácia na avaliação de PDA. A comparação com recursos de domínio de tempo comuns, como RMS e curtose, além de métodos de diagnóstico de falhas como análise de envelope (EA) e classificadores PDA existentes, revelou que o método recomendado superou essas abordagens na detecção mais precisa da degradação em estágio inicial. Além disso, a EA é sugerida como um método de acompanhamento para confirmar defeitos em estágios iniciais detectados pela abordagem proposta de PDA. O estudo destaca o potencial do agrupamento *K*-medóides como uma ferramenta eficaz para PDA de rolamentos.

Amruthnath e Gupta (2018) destacaram a crescente importância da manutenção preditiva, impulsionada por avanços em algoritmos e metodologias de aprendizado. No contexto da detecção de falhas, um elemento crítico da manutenção preditiva, a escolha do método mais adequado, robusto e preciso continua sendo um desafio para as indústrias. A detecção precoce e precisa de falhas é crucial para minimizar os custos de manutenção. Em situações em que há mínimo ou nenhum dado histórico disponível, os métodos de ML não supervisionados são uma opção viável para construção de modelos. O artigo abordou esse desafio ao aplicar diferentes algoritmos de ML não supervisionados, como PCA T2 estatística, clusterização hierárquica, *K*-means, *Fuzzy C-Means* e GMM, em dados de vibração coletados de um exaustor. O objetivo foi avaliar a precisão, desempenho e robustez desses algoritmos. Ao final, o artigo propôs uma metodologia de comparação de diferentes algoritmos e seleção do modelo mais adequado.

Em Wang, Wei e Yang (2018) foi proposto uma abordagem de diagnóstico inteligente de falhas em três estágios para o monitoramento prático de processos industriais, visando superar a complexidade das técnicas tradicionais. Uma nova técnica de processamento de recursos é introduzida para aprimorar a precisão e reduzir a carga computacional, incorporando detecção de tendência baseada em decomposição variacional e um algoritmo de peso próprio. Além

disso, é apresentada uma busca adaptativa de picos de densidade (ADPS) para a adaptação do agrupamento, demonstrando eficácia em comparação com métodos tradicionais, como com o DPS original, cluster de propagação de afinidade e K -medóides. A abordagem é aplicada a três casos específicos em diferentes indústrias, mostrando resultados bem-sucedidos no diagnóstico de falhas em rolamentos e engrenagens, destacando confiabilidade e precisão, mesmo com menos conhecimento prévio e experiência diagnóstica. A técnica também é considerada adequada para monitoramento adaptativo em condições variáveis, incluindo a aplicação em dados de teste não rotulados até a falha, sugerindo sua utilidade em aplicações industriais online.

Wang et al. (2020) aplicaram uma abordagem de análise de agrupamento baseada em K -means para diagnosticar falhas em máquinas rotativas. A pesquisa utilizou técnicas de ML de Big Data sob a condição de sistemas ciberfísicos (CPS). O estudo também se aprofundou na extração de características de falhas e na triagem de autovetores de falhas. Os dados de vibração provenientes de um compressor centrífugo em uma planta industrial, cobrindo condições de surto, fricção, desalinhamento e status normal, foram utilizados para treinar e verificar a eficácia do modelo de reconhecimento de falhas baseado em agrupamento. Os resultados indicaram taxas de precisão de reconhecimento de falhas de 94%, 100% e 80% para sobretensão, fricção e desalinhamento, respectivamente. No entanto, o estudo também aponta para a necessidade de investigações futuras sobre a eficácia da análise de cluster de dados de vibração em cenários com cinco ou mais estados operacionais. Este trabalho destaca a aplicação prática de técnicas de agrupamento para o diagnóstico de falhas em máquinas rotativas em ambientes de sistemas ciberfísicos.

Em Wu et al. (2023), uma metodologia que utiliza a decomposição de modo empírico de conjunto completo aprimorada com ruído adaptativo (CEEMDAN) para extrair características e um algoritmo de agrupamento semi supervisionado chamado Abordagem de agrupamento de busca rápida e descoberta de picos de densidade (CFSFDP) para identificar falhas foi proposta. Duas principais contribuições do método foram a extração de características altamente representativas de recursos comuns de alta dimensão e a capacidade adaptativa do classificador semi supervisionado para identificar tipos de falhas sem depender significativamente de dados rotulados por tipo. Estudos de benchmarking demonstraram a superioridade da metodologia proposta em comparação com outras abordagens de diagnóstico de falhas.

Com vista ao estado da arte disposto acima, esta Tese de Doutorado apresenta uma contribuição pertinente no desenvolvimento de metodologias para sistemas de monitoramento e diagnóstico

de falhas em máquinas rotativas suportadas por mancais hidrodinâmicos. A exploração de dados obtidos a partir de modelos matemáticos e ensaios experimentais oferece uma visão abrangente acerca do comportamento e funcionalidades desses sistemas rotativos sob diferentes condições de operação. Uma metodologia para sistema de monitoramento e diagnóstico de falhas fundamentada em métodos de aprendizado tanto supervisionados quanto não supervisionados e em ferramentas de explicabilidade corroboram para resultados mais precisos e transparentes, possibilitando ações de manutenção proativas e reduzindo o risco de paradas não programadas.

CAPÍTULO III

DINÂMICA DE ROTORES

A utilização de máquinas rotativas mais leves com capacidade de operação em altas velocidades impulsionou o desenvolvimento de métodos cada vez mais eficazes para a representação matemática do comportamento dinâmico de rotores. Nessa trajetória, destacam-se abordagens como o Método das Matrizes de Transferência, proposto por Lallement, Lecoanet e Steffen Jr (1982) considerando o sistema como sendo contínuo e, posteriormente, desenvolvimento de adequações no Método dos Elementos Finitos para abranger a dinâmica de rotação. Segundo Ishida e Yamamoto (2013) foram Nelson e McVaugh (1976) os responsáveis pela inclusão dos efeitos de inércia de rotação, momento giroscópico e força axial no método dos Elementos Finitos.

Este capítulo apresenta os conceitos associados ao modelo de elementos finitos de rotores. As equações de Lagrange e o método de elementos finitos são utilizados para obter as equações diferenciais capazes de representar adequadamente o comportamento dinâmico de uma ampla gama de sistemas rotativos. Detalha-se a formulação das matrizes elementares que compõem o modelo matemático do sistema, desenvolvido por meio do método dos Elementos Finitos. Essa formulação abrange as matrizes de massa, rigidez, amortecimento, efeitos giroscópicos, entre outras. Os desenvolvimentos que serão mostrados têm como base os livros de Imbert (1995) e Lalanne e Ferraris (1998).

3.1 Modelagem de Rotores por Elementos Finitos

Em linhas gerais e em acordo com Lalanne e Ferraris (1998), as equações que descrevem o comportamento dinâmico de um rotor são obtidas a partir das energias envolvidas (cinética e de

deformação) e do trabalho virtual das forças externas para cada componente do sistema.

Um modelo matemático para representação do comportamento dinâmico de uma máquina rotativa considera aqueles subsistemas que podem ser definidos pela sua geometria (eixo, acoplamento e discos), outros que são dependentes da velocidade de rotação e/ou estados (deslocamentos, velocidades e acelerações radiais para mancais hidrodinâmicos) e, finalmente, o efeito giroscópico. Depois de definidos e agrupados, os parâmetros incertos são identificados com base em resultados experimentais.

A Equação (3.1) apresenta a equação diferencial que descreve numericamente o comportamento dinâmico de um rotor flexível suportado por mancais hidrodinâmicos ou por rolamentos.

$$\mathbf{M}\ddot{\mathbf{q}} + [\mathbf{D} + \Omega\mathbf{D}_g]\dot{\mathbf{q}} + [\mathbf{K} + \dot{\Omega}\mathbf{K}_{st}]\mathbf{q} = \mathbf{W} + \mathbf{F}_u + \mathbf{F}_m + \mathbf{F}_d \quad (3.1)$$

onde \mathbf{M} é a matriz de massa, \mathbf{D} é a matriz de amortecimento, \mathbf{D}_g é a matriz do efeito giroscópico, \mathbf{K} é a matriz de rigidez e \mathbf{K}_{st} representa o enrijecimento do sistema devido à variação da velocidade de rotação. Todas estas matrizes são associadas às partes girantes da máquina, tais como os discos, acoplamento e eixo. O vetor de deslocamentos é representado por \mathbf{q} e a velocidade de rotação é dada por Ω . A força peso, \mathbf{W} , contempla apenas às partes girantes, \mathbf{F}_u representa as forças de desbalanceamento, \mathbf{F}_m é o vetor das forças não lineares produzidas pelos mancais a fim de suportar o eixo e \mathbf{F}_d representa a força de excitação externa se a mesma for adicionada ao sistema.

Vale ressaltar que a influência do termo \mathbf{K}_{st} não será avaliada neste trabalho. Como essa matriz de enrijecimento é devido à variação da velocidade de rotação, $\dot{\Omega}$, para velocidades constantes sua contribuição é nula.

As matrizes associadas à energia cinética (\mathbf{M} , \mathbf{D}_g e \mathbf{K}_{st}) e à de deformação (\mathbf{K}) são determinadas avaliando as energias provenientes de cada elemento separadamente e aplicando-as nas equações de Lagrange.

$$\frac{d}{dt} \left(\frac{\partial T}{\partial \dot{\mathbf{q}}_i} \right) - \frac{\partial T}{\partial \mathbf{q}_i} + \frac{\partial U}{\partial \mathbf{q}_i} = Q_i \quad (3.2)$$

onde T representa a soma das energias cinéticas, U é a energia de deformação do eixo e Q_i representa os esforços generalizados.

O eixo é modelado como uma viga de seção transversal circular e com diâmetro constante.

Este elemento finito (comprimento L) possui dois nós (1 e 2), incluindo quatro deslocamentos (u_1, u_2, w_1 e w_2) e quatro rotações ($\theta_1, \theta_2, \varphi_1$ e φ_2), conforme mostrado na Fig. 3.1.

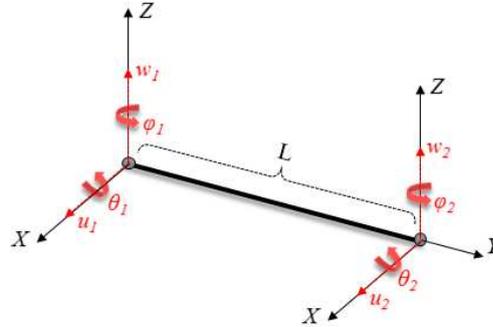


Figura 3.1: Graus de liberdade (*gdl*) associados ao elemento finito construído para representar o eixo.

Com relação aos *gdl* do elemento de eixo, o vetor de deslocamentos nodais do eixo é dado por:

$$\mathbf{q} = \left\{ u_1 \quad w_1 \quad \theta_1 \quad \varphi_1 \quad u_2 \quad w_2 \quad \theta_2 \quad \varphi_2 \right\}^t \quad (3.3)$$

Este vetor inclui os deslocamentos \mathbf{q}_u e \mathbf{q}_w , correspondendo aos movimentos nas direções X e Z , respectivamente. O elemento finito é construído a partir das seguintes relações:

$$\begin{aligned} \mathbf{u} &= \mathbf{N}_1 \mathbf{q}_u \\ \mathbf{w} &= \mathbf{N}_2 \mathbf{q}_w \end{aligned} \quad (3.4)$$

onde \mathbf{N}_1 e \mathbf{N}_2 dispostos na Eq. (3.5) são vetores formados por coeficientes de equações polinomiais de terceira ordem (hipótese considerada), conhecidos como polinômios de Hermite (IMBERT, 1995). Tais polinômios descrevem os deslocamentos nodais nos planos XY e ZY , respectivamente. Os coeficientes das funções de interpolação são determinados, resultando nas equações de deslocamento e rotação ao longo do comprimento da árvore.

As matrizes \mathbf{M} , \mathbf{D}_s , \mathbf{K} e \mathbf{K}_{st} são determinadas substituindo \mathbf{N}_1 e \mathbf{N}_2 nas equações que definem a energia cinética e a energia de deformação do eixo, com subsequente integração ao longo

do comprimento L (LALANNE; FERRARIS, 1998).

$$\begin{aligned} \mathbf{N}_1 &= \left\{ 1 - \frac{3y^2}{L^2} + \frac{2y^3}{L^3} - y + \frac{2y^2}{L} - \frac{y^3}{L^2} \frac{3y^2}{L^2} - \frac{2y^3}{L^3} \frac{y^2}{L} - \frac{y^3}{L^2} \right\} \\ \mathbf{N}_2 &= \left\{ 1 - \frac{3y^2}{L^2} + \frac{2y^3}{L^3} y - \frac{2y^2}{L} + \frac{y^3}{L^2} \frac{3y^2}{L^2} - \frac{2y^3}{L^3} - \frac{y^2}{L} + \frac{y^3}{L^2} \right\} \end{aligned} \quad (3.5)$$

A energia cinética do eixo pode então ser obtida através da Eq. (3.6).

$$T_S = \frac{\rho S}{2} \int_0^L (\dot{u}^2 + \dot{w}^2) dy + \frac{\rho I}{2} \int_0^L (\dot{\phi}^2 + \dot{\theta}^2) dy + \rho I L \Omega^2 + 2\rho I \Omega \int_0^L \phi \theta dy \quad (3.6)$$

onde, ρ é a densidade, S é a área de seção transversal do eixo e I é o momento de inércia de área.

Substituindo as Eqs. (3.4) a (3.5) na Eq. (3.6), obtém-se a energia cinética para o eixo na sua forma compacta, conforme mostra a Eq. (3.7).

$$\begin{aligned} T_S &= \frac{\rho S}{2} \int_0^L (\dot{\mathbf{q}}_u^t \mathbf{N}_1^t \mathbf{N}_1 \dot{\mathbf{q}}_u + \dot{\mathbf{q}}_w^t \mathbf{N}_2^t \mathbf{N}_2 \dot{\mathbf{q}}_w) dy + \dots \\ &\quad \dots + \frac{\rho I}{2} \int_0^L \left(\dot{\mathbf{q}}_u^t \frac{d\mathbf{N}_1^t}{dy} \frac{d\mathbf{N}_1}{dy} \dot{\mathbf{q}}_u + \dot{\mathbf{q}}_w^t \frac{d\mathbf{N}_2^t}{dy} \frac{d\mathbf{N}_2}{dy} \dot{\mathbf{q}}_w \right) dy + \dots \\ &\quad \dots + \rho I L \Omega^2 - 2\rho I \Omega \int_0^L \dot{\mathbf{q}}_u^t \frac{d\mathbf{N}_1^t}{dy} \frac{d\mathbf{N}_2}{dy} \dot{\mathbf{q}}_w dy \end{aligned} \quad (3.7)$$

Por meio da aplicação da equação de Lagrange, Eq. (3.2), na equação da energia cinética do eixo, chega-se à expressão apresentada na Eq. (3.8).

$$\frac{d}{dt} \left(\frac{\partial T_S}{\partial \dot{\mathbf{q}}} \right) - \frac{\partial T_S}{\partial \mathbf{q}} = (\mathbf{M}_S + \mathbf{M}_T) \ddot{\mathbf{q}} + \Omega \mathbf{D}_S \dot{\mathbf{q}} + \dot{\Omega} \mathbf{K}_{st} \mathbf{q} \quad (3.8)$$

onde as matrizes \mathbf{M}_S , \mathbf{M}_T , \mathbf{D}_S e \mathbf{K}_{st} são apresentadas nas Eqs. (3.9) a (3.12).

$$\mathbf{M}_S = \frac{\rho SL}{420} \begin{bmatrix} 156 & 0 & 0 & -22L & 54 & 0 & 0 & 13L \\ 0 & 156 & 22L & 0 & 0 & 54 & -13L & 0 \\ 0 & 22L & 4L^2 & 0 & 0 & 13L & -3L^2 & 0 \\ -22L & 0 & 0 & 4L^2 & -13L & 0 & 0 & -3L^2 \\ 54 & 0 & 0 & -13L & 156 & 0 & 0 & 22L \\ 0 & 54 & 13L & 0 & 0 & 156 & -22L & 0 \\ 0 & -13L & -3L^2 & 0 & 0 & -22L & 4L^2 & 0 \\ 13L & 0 & 0 & -3L^2 & 22L & 0 & 0 & 4L^2 \end{bmatrix} \quad (3.9)$$

$$\mathbf{M}_T = \frac{\rho I}{30L} \begin{bmatrix} 36 & 0 & 0 & -3L & -36 & 0 & 0 & -3L \\ 0 & 36 & 3L & 0 & 0 & -36 & 3L & 0 \\ 0 & 3L & 4L^2 & 0 & 0 & -3L & -L^2 & 0 \\ -3L & 0 & 0 & 4L^2 & 3L & 0 & 0 & -L^2 \\ -36 & 0 & 0 & -3L & 36 & 0 & 0 & 3L \\ 0 & -36 & -3L & 0 & 0 & 36 & -3L & 0 \\ 0 & 3L & -L^2 & 0 & 0 & -3L & 4L^2 & 0 \\ -3L & 0 & 0 & -L^2 & 3L & 0 & 0 & 4L^2 \end{bmatrix} \quad (3.10)$$

$$\mathbf{D}_S = \frac{\rho I}{15L} \begin{bmatrix} 0 & -36 & -3L & 0 & 0 & 36 & -3L & 0 \\ 36 & 0 & 0 & -3L & -36 & 0 & 0 & -3L \\ 3L & 0 & 0 & -4L^2 & -3L & 0 & 0 & L^2 \\ 0 & 3L & 4L^2 & 0 & 0 & -3L & -L^2 & 0 \\ 0 & 36 & 3L & 0 & 0 & -36 & 3L & 0 \\ -36 & 0 & 0 & 3L & 36 & 0 & 0 & 3L \\ 3L & 0 & 0 & L^2 & -3L & 0 & 0 & -4L^2 \\ 0 & 3L & -L^2 & 0 & 0 & -3L & 4L^2 & 0 \end{bmatrix} \quad (3.11)$$

$$\mathbf{K}_{st} = \frac{\rho I}{15L} \begin{bmatrix} 0 & -36 & -3L & 0 & 0 & 36 & -3L & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 3L & 4L^2 & 0 & 0 & -3L & -L^2 & 0 \\ 0 & 36 & 3L & 0 & 0 & -36 & 3L & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 3L & -L^2 & 0 & 0 & -3L & 4L^2 & 0 \end{bmatrix} \quad (3.12)$$

onde a matriz \mathbf{M} da Eq. (3.1) é resultado da soma das matrizes \mathbf{M}_S e \mathbf{M}_T .

A energia de deformação para o eixo simétrico é obtida com base nas tensões (σ) e deformações (ϵ) desenvolvidas. De acordo com a Fig. 3.2, pode-se definir a deformação longitudinal mostrada na Eq. (3.13) de um ponto arbitrário B no eixo.

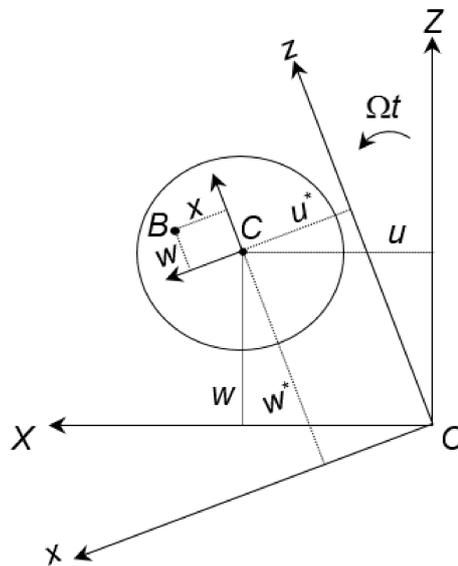


Figura 3.2: Representação de um ponto arbitrário B (LALANNE; FERRARIS, 1998).

$$\epsilon = -x \frac{\partial^2 u^*}{\partial y^2} - z \frac{\partial^2 w^*}{\partial y^2} \quad (3.13)$$

onde u e w são os deslocamentos em coordenadas fixas relacionados aos eixos X e Z , respectivamente, e u^* e w^* são os deslocamentos para as coordenadas rotativas x e z conforme apresentado

na Eq. (3.14).

$$\begin{aligned} u^* &= u \cos(\Omega t) - w \sin(\Omega t) \\ w^* &= u \sin(\Omega t) + w \cos(\Omega t) \end{aligned} \quad (3.14)$$

A energia de deformação para o eixo é calculada a partir da Eq. (3.15).

$$U = \frac{1}{2} \int_v \boldsymbol{\varepsilon}^t \boldsymbol{\sigma} dV \quad (3.15)$$

Por meio da relação entre tensão e deformação da Lei de Hooke, segundo a Eq. (3.16), pode-se reescrever a Eq. (3.22), conforme mostra a Eq. (3.17).

$$\boldsymbol{\sigma} = E \boldsymbol{\varepsilon} \quad (3.16)$$

$$U = \frac{E}{2} \int_v \boldsymbol{\varepsilon}^t \boldsymbol{\varepsilon} dV \quad (3.17)$$

Substituindo a Eq. (3.13) na Eq. (3.17), obtém-se:

$$\begin{aligned} U &= \frac{E}{2} \int_0^L \int_S \left(-x \frac{\partial^2 u^*}{\partial y^2} - z \frac{\partial^2 w^*}{\partial y^2} \right)^2 dS dy \\ &= \frac{E}{2} \int_0^L \int_S \left[x^2 \left(\frac{\partial^2 u^*}{\partial y^2} \right)^2 + z^2 \left(\frac{\partial^2 w^*}{\partial y^2} \right)^2 + 2xz \frac{\partial^2 u^*}{\partial y^2} \frac{\partial^2 w^*}{\partial y^2} \right] dS dy \end{aligned} \quad (3.18)$$

De acordo com Lalanne e Ferraris (1998), ao considerar a simetria da seção transversal do eixo com respeito as direções X e Z e as relações de momentos de inércia de área conforme apresentado pela Eq. (3.19), a Eq. (3.18) pode ser reescrita como a Eq. (3.20).

$$\begin{aligned} I_x &= \int_S z^2 dS \\ I_z &= \int_S x^2 dS \\ \int_S xz dS &= 0 \end{aligned} \quad (3.19)$$

$$U = \frac{E}{2} \int_0^L \left[I_z \left(\frac{\partial^2 u^*}{\partial y^2} \right)^2 + I_x \left(\frac{\partial^2 w^*}{\partial y^2} \right)^2 \right] dy \quad (3.20)$$

Assumindo $I_x = I_z = I$ e substituindo as Eqs. (3.4), (3.5) e (3.14) na Eq. (3.20), chega-se à expressão da energia de deformação apresentada na Eq. (3.21) em que as contribuições dos efeitos da força axial não são considerados.

$$U = \frac{EI}{2} \int_0^L \left[\mathbf{q}_u^t \frac{d^2 \mathbf{N}_1^t}{dy^2} \frac{d^2 \mathbf{N}_1}{dy^2} \mathbf{q}_u + \mathbf{q}_w^t \frac{d^2 \mathbf{N}_2^t}{dy^2} \frac{d^2 \mathbf{N}_2}{dy^2} \mathbf{q}_w \right] dy \quad (3.21)$$

Mediante a aplicação da equação de Lagrange, Eq. (3.2), na Eq. (3.21), conforme mostra a Eq. (3.22), obtém-se a matriz de rigidez apresentada pela Eq. (3.23).

$$\frac{\partial U}{\partial \mathbf{q}} = \mathbf{K} \mathbf{q} \quad (3.22)$$

$$\mathbf{K} = k_L \begin{bmatrix} 12 & 0 & 0 & -6L & -12 & 0 & 0 & -6L \\ 0 & 12 & 6L & 0 & 0 & -12 & 6L & 0 \\ 0 & 6L & (4 + \vartheta_Y)L^2 & 0 & 0 & -6L & (2 - \vartheta_Y)L^2 & 0 \\ -6L & 0 & 0 & (4 + \vartheta_Y)L^2 & 6L & 0 & 0 & (2 - \vartheta_Y)L^2 \\ -12 & 0 & 0 & 6L & 12 & 0 & 0 & 6L \\ 0 & -12 & -6L & 0 & 0 & 12 & -6L & 0 \\ 0 & 6L & (2 - \vartheta_Y)L^2 & 0 & 0 & -6L & (4 + \vartheta_Y)L^2 & 0 \\ -6L & 0 & 0 & (2 - \vartheta_Y)L^2 & 6L & 0 & 0 & (4 + \vartheta_Y)L^2 \end{bmatrix} \quad (3.23)$$

onde k_L e ϑ_Y são dados pelas Eqs. (3.24) e (3.25), respectivamente.

$$k_L = \frac{EI}{(1 + \vartheta_Y)L^3} \quad (3.24)$$

$$\vartheta_Y = \frac{12EI}{GS_r L^2} \quad (3.25)$$

sendo S_r a área reduzida da seção transversal e G é o módulo de cisalhamento, dado pela Eq.

(3.26) em função do módulo de elasticidade e do coeficiente de Poisson (ν).

$$G = \frac{E}{2(1+\nu)} \quad (3.26)$$

A matriz de rigidez, \mathbf{K} , leva em consideração o cisalhamento nas seções transversais durante a flexão, conforme o modelo de viga de Timoshenko.

Em relação ao disco, este é representado conforme a Fig. 3.3 e é assumido como sendo rígido. Portanto apenas sua energia cinética é avaliada no modelo 1D do sistema. O sistema de coordenadas fixas (R_0) continua sendo representado pelos eixos X , Y e Z e o sistema de coordenadas rotativas (R) posicionado no centro no disco, representado pelos eixos x , y e z .

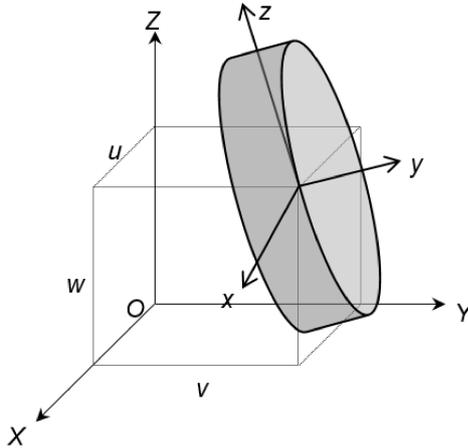


Figura 3.3: Representação do elemento de disco (CAVALLINI Jr., 2013).

Com quatro graus de liberdade (*gdl*), dois deslocamentos laterais (u e w) e duas rotações (θ e ϕ), o vetor de deslocamentos nodais é representado pela Eq. (3.27).

$$\mathbf{q}_D = \{u \quad w \quad \theta \quad \phi\}^t \quad (3.27)$$

Conforme demonstrado em Lalanne e Ferraris (1998), a energia cinética para o elemento de disco pode ser calculada segundo a Eq. (3.28).

$$T_D = \frac{1}{2}m_D(\dot{u}^2 + \dot{w}^2) + \frac{1}{2}(I_{Dx}\omega_x^2 + I_{Dy}\omega_y^2 + I_{Dz}\omega_z^2) \quad (3.28)$$

onde m_D é a massa do disco, I_{Dx} , I_{Dy} e I_{Dz} representam os momentos de inércia e ω_x , ω_y e ω_z são as velocidades angulares, Eq. (3.29), todos em relação aos eixos de coordenadas rotativas

(x , y e z).

$$\boldsymbol{\omega}_{R/R_0}^R = \begin{bmatrix} \omega_x \\ \omega_y \\ \omega_z \end{bmatrix} = \begin{bmatrix} -\dot{\phi} \cos(\theta) \sin(\phi) + \dot{\theta} \cos(\phi) \\ \dot{\phi} + \dot{\phi} \sin(\theta) \\ \dot{\phi} \cos(\theta) \cos(\phi) + \dot{\theta} \sin(\phi) \end{bmatrix} \quad (3.29)$$

A Equação (3.28) pode ainda ser simplificada como mostra a Eq. (3.30), assumindo hipóteses de que o disco seja simétrico ($I_{Dx} = I_{Dz} = I_D$) e que os ângulos θ e ϕ sejam suficientemente pequenos.

$$T_D = \frac{1}{2} m_D (\dot{u}^2 + \dot{w}^2) + \frac{1}{2} I_D (\dot{\theta}^2 + \dot{\phi}^2) + \frac{1}{2} I_{Dy} (\Omega^2 + 2\Omega\phi\theta) \quad (3.30)$$

O efeito giroscópico é representado pelo termo $I_{Dy}\Omega\phi\theta$. Aplicando as equações de Lagrange, Eq. (3.2), na energia cinética do disco, obtém-se a expressão apresentada pela Eq. (3.31).

$$\frac{d}{dt} \left(\frac{\partial T_D}{\partial \dot{\mathbf{q}}_D} \right) - \frac{\partial T_D}{\partial \mathbf{q}_D} = \mathbf{M}_D \ddot{\mathbf{q}}_D + \boldsymbol{\Omega} \mathbf{D}_D \dot{\mathbf{q}}_D + \dot{\boldsymbol{\Omega}} \mathbf{K}_{D_t} \mathbf{q}_D \quad (3.31)$$

onde as matrizes \mathbf{M}_D , \mathbf{D}_D e \mathbf{K}_{D_t} são descritas pelas Eqs. (3.32) a (3.34).

$$\mathbf{M}_D = \begin{bmatrix} m_D & 0 & 0 & 0 \\ 0 & m_D & 0 & 0 \\ 0 & 0 & I_D & 0 \\ 0 & 0 & 0 & I_D \end{bmatrix} \quad (3.32)$$

$$\mathbf{D}_D = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -I_{Dy} \\ 0 & 0 & I_{Dy} & 0 \end{bmatrix} \quad (3.33)$$

$$\mathbf{K}_{Dt} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & I_{Dy} & 0 \end{bmatrix} \quad (3.34)$$

sendo a matriz \mathbf{D}_g da Eq. (3.1) o resultado da soma das matrizes \mathbf{D}_S e \mathbf{D}_D nos *gdl* correspondentes.

De acordo com Lalanne e Ferraris (1998), o acoplamento do disco ao eixo pode se dar por três configurações distintas, conforme ilustrado na Fig. 3.4. Na primeira configuração assume-se a hipótese de que o disco não altera a rigidez do eixo e as características de inércia do disco são concentradas no nó correspondente ao elemento finito do eixo. Na segunda, utilizada neste trabalho, assume-se que o disco altera a rigidez do eixo. Dessa forma, o raio do eixo é acrescido em $h_d/2$, onde h_d corresponde à espessura do disco, e as características do disco são incluídas no nó 2. E, na terceira, para uma espessura de disco suficientemente grande, as características de inércia do mesmo são distribuídas ao longo dos três nós.

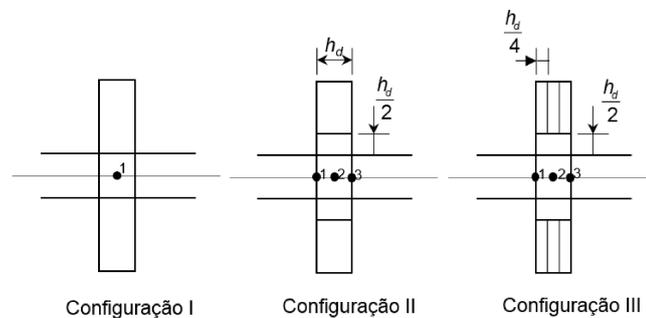


Figura 3.4: Configurações para acoplamento do disco ao eixo (LALANNE; FERRARIS, 1998).

3.2 Força de Sustentação dos Mancais

Os coeficientes de rigidez e amortecimento viscoso para um mancal de rolamento, apresentados na Fig. 3.5, são estimados por meio da solução de um problema inverso onde o resultado de simulações computacionais são aproximados de respostas de vibração experimentais do sistema em análise.

O trabalho virtual das forças produzidas pelos mancais e atuantes sobre o eixo pode ser

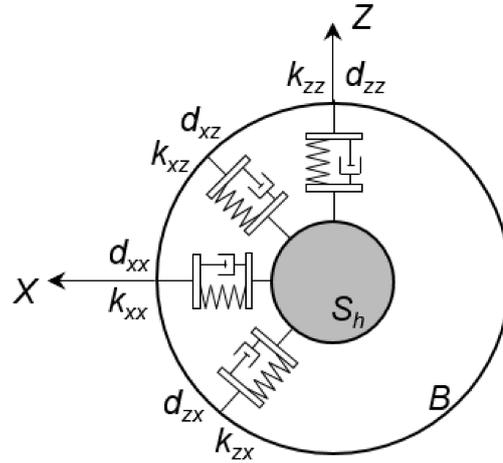


Figura 3.5: Coeficientes de rigidez e amortecimento do mancal (CAVALLINI Jr., 2013).

escrito como mostra a Eq. (3.35).

$$\delta W = -k_{xx}u\delta u - k_{xz}w\delta u - k_{zz}w\delta w - k_{zx}u\delta w - d_{xx}\dot{u}\delta u - d_{xz}\dot{w}\delta u - d_{zz}\dot{w}\delta w - d_{zx}\dot{u}\delta w \quad (3.35)$$

A Equação (3.35) pode também ser simplificada conforme a Eq. (3.36).

$$\delta W = F_{mu}\delta u + F_{mw}\delta w \quad (3.36)$$

onde F_{mu} e F_{mw} são as forças generalizadas e são expressas na forma matricial como mostra a Eq. (3.37).

$$\begin{bmatrix} F_{mu} \\ F_{mw} \end{bmatrix} = - \begin{bmatrix} k_{xx} & k_{xz} \\ k_{zx} & k_{zz} \end{bmatrix} \begin{bmatrix} u \\ w \end{bmatrix} - \begin{bmatrix} d_{xx} & d_{xz} \\ d_{zx} & d_{zz} \end{bmatrix} \begin{bmatrix} \dot{u} \\ \dot{w} \end{bmatrix} \quad (3.37)$$

A Equação (3.37) pode ser escrita de forma expandida com os graus de liberdade utilizados na formulação do elemento finito de eixo (graus de liberdade de um dos nós do elemento), conforme apresenta a Eq. (3.38).

$$\begin{bmatrix} F_{mu} \\ F_{m\theta} \\ F_{mw} \\ F_{m\phi} \end{bmatrix} = - \begin{bmatrix} k_{xx} & 0 & k_{xz} & 0 \\ 0 & 0 & 0 & 0 \\ k_{zx} & 0 & k_{zz} & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u \\ \theta \\ w \\ \phi \end{bmatrix} - \begin{bmatrix} d_{xx} & 0 & d_{xz} & 0 \\ 0 & 0 & 0 & 0 \\ d_{zx} & 0 & d_{zz} & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \dot{u} \\ \dot{\theta} \\ \dot{w} \\ \dot{\phi} \end{bmatrix} \quad (3.38)$$

3.3 Massa de Desbalanceamento

A força de desbalanceamento é definida por uma massa m_u situada a uma distância d do centro geométrico do eixo que por sua vez têm coordenadas $(u$ e $w)$ em relação ao ponto O , conforme ilustra a Fig. 3.6. A massa m_u é assumida como sendo muito menor que a massa do rotor. A energia cinética T_U da massa m_u pode então ser calculada conforme mostra a Eq. (3.39).

$$T_u = \frac{m_u}{2} (\dot{u}^2 + \dot{w}^2 + \Omega^2 d^2 + 2\Omega d \dot{u} \sin(\Omega t) - 2\Omega \dot{w} d \cos(\Omega t)) \quad (3.39)$$

onde o termo $\Omega^2 d^2$ é constante e não tem influência nas equações. Assim, a expressão da energia cinética é escrita como:

$$T_u \approx m_u \Omega d (\dot{u} \sin(\Omega t) - \dot{w} \cos(\Omega t)) \quad (3.40)$$

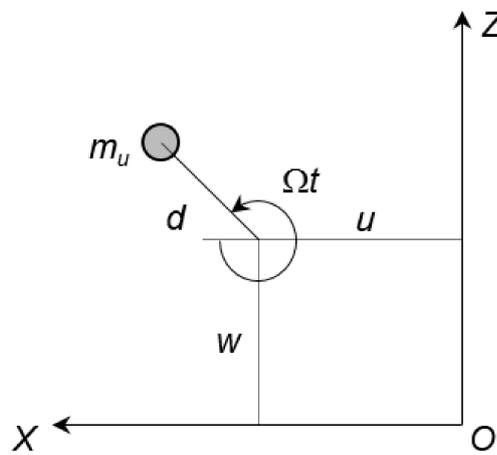


Figura 3.6: Coordenadas relativas à massa de desbalanceamento (CAVALLINI Jr., 2013).

O vetor de deslocamentos nodais para a massa de desbalanceamento é composto apenas pelos deslocamentos laterais, conforme mostra a Eq. (3.41).

$$\mathbf{q}_{\text{unb}} = \begin{Bmatrix} u & w \end{Bmatrix}^t \quad (3.41)$$

A Equação (3.42) é resultado da aplicação das equações de Lagrange sobre a energia cinética

da massa de desbalanceamento.

$$\frac{dT_u}{dt} \left(\frac{\partial T_u}{\partial \dot{\mathbf{q}}_{\text{unb}}} \right) - \frac{\partial T_u}{\partial \mathbf{q}_{\text{unb}}} = \begin{bmatrix} -m_u d \dot{\Omega} \sin(\Omega t) - m_u d \Omega^2 \cos(\Omega t) \\ -m_u d \dot{\Omega} \cos(\Omega t) + m_u d \Omega^2 \sin(\Omega t) \end{bmatrix} \quad (3.42)$$

As forças de desbalanceamento nas direções X e Z podem então ser descritas como mostra a Eq. (3.43).

$$\begin{bmatrix} F_{\text{unbx}} \\ F_{\text{unbz}} \end{bmatrix} = \begin{bmatrix} -m_u d \dot{\Omega} \sin(\Omega t) - m_u d \Omega^2 \cos(\Omega t) \\ -m_u d \dot{\Omega} \cos(\Omega t) + m_u d \Omega^2 \sin(\Omega t) \end{bmatrix} \quad (3.43)$$

CAPÍTULO IV

MODELO TERMOHIDRODINÂMICO PARA MANCAIS HIDRODINÂMICOS

Os mancais hidrodinâmicos são componentes fundamentais para um sistema rotativo. A modelagem matemática destes mancais objetiva determinar as forças de sustentação, a partir das características físicas e das condições de operação. Neste caso, os esforços são suportados por meio das forças hidrodinâmicas, as quais são determinadas a partir do campo de pressão gerado no filme de óleo. O campo de pressão hidrodinâmica, por sua vez, é obtido por meio da solução da equação de Reynolds deduzida a partir de simplificações nas equações de Navier-Stokes.

Diante do disposto acima, este capítulo descreve a formulação matemática do modelo termohidrodinâmico implementado para a determinação dos coeficientes dinâmicos dos mancais hidrodinâmicos presentes no sistema rotativo considerado. São apresentadas as equações diferenciais que governam o comportamento dinâmico do filme de óleo, o método de discretização dessas equações e o procedimento de solução. Todo o equacionamento é baseado nos trabalhos de Bregion (2012), de Barbosa (2018) e Sicchieri (2019).

4.1 Modelo para Mancal Hidrodinâmico Cilíndrico Radial

A equação clássica proposta por Reynolds não contempla todos os efeitos observados no comportamento do fluido uma vez que as propriedades do óleo e a temperatura ao longo do filme são constantes. No entanto, devido à movimentação entre as camadas de fluido e aos efeitos viscosos, parte da energia cinética é transformada em energia térmica. Conseqüentemente, a temperatura do filme lubrificante aumenta, provocando uma diminuição na viscosidade do óleo. Dowson (1962) propôs um modelo no qual as equações de Reynolds e da energia são resolvidas

conjuntamente, levando em consideração os efeitos térmicos.

A Figura 4.1 apresenta o modelo físico do mancal hidrodinâmico cilíndrico radial e as suas principais características geométricas.

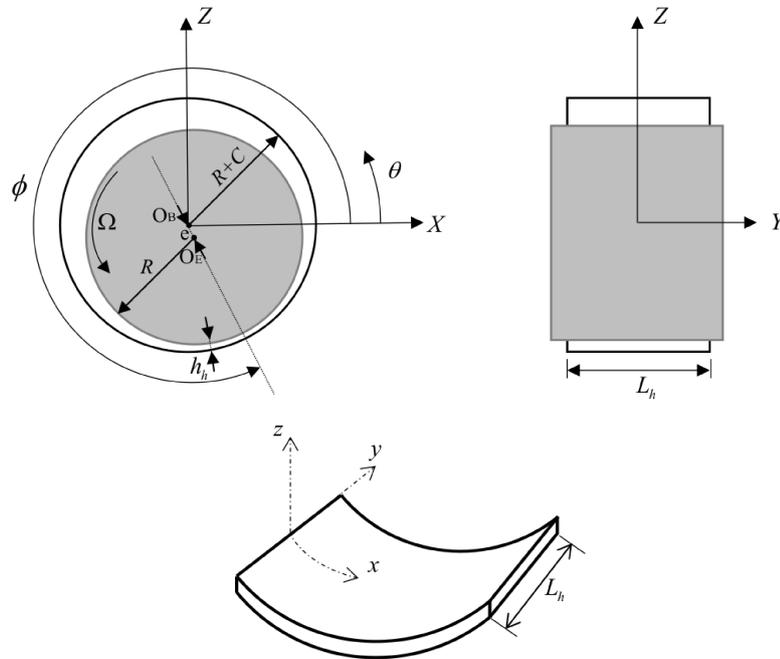


Figura 4.1: Representação esquemática de um mancal cilíndrico radial (SICCHIERI, 2019).

De acordo com a Fig. 4.1, $I(X, Y, Z)$ representa o referencial inercial localizado no centro do mancal, R é o raio do eixo, L_h o comprimento do mancal, C a folga radial, Ω a velocidade de rotação do eixo, O_E o centro do eixo, h_h a espessura do filme de óleo, e a excentricidade do eixo e ϕ a posição angular do centro do eixo considerando ainda $I_C(X, Y, Z)$ o referencial curvilíneo.

A posição do centro do eixo x_r e z_r no referencial I é dada em função de e e ϕ conforme mostrado na Eq. (4.1). Além disso, a espessura do filme de óleo h_h ao longo de todo o mancal pode ser calculada a partir da posição do centro do eixo e da posição angular θ .

$$\begin{aligned} x_r &= e \cos(\phi) , \\ z_r &= -e \sin(\phi) , \\ h_h &= C - x_r \cos(\theta) - z_r \sin(\theta) . \end{aligned} \tag{4.1}$$

A equação adimensional de Reynolds modificada para um fluido Newtoniano incompressível conforme apresentou Dowson (1962) é mostrada na Eq. (4.2) e sua solução permite determinar

o campo de pressão ao longo do filme de óleo.

$$\left(\frac{1}{2\pi}\right)^2 \frac{\partial}{\partial \bar{x}} \left(\bar{F}_2 \bar{h}_h^3 \frac{\partial \bar{p}_h}{\partial \bar{x}} \right) + \left(\frac{R}{L_h}\right)^2 \frac{\partial}{\partial \bar{y}} \left(\bar{F}_2 \bar{h}_h^3 \frac{\partial \bar{p}_h}{\partial \bar{y}} \right) = \left(\frac{1}{2\pi}\right) \frac{\partial}{\partial \bar{x}} \left[\bar{h}_h \left(1 - \frac{\bar{F}_1}{\bar{F}_0} \right) \right] + \frac{\partial \bar{h}_h}{\partial t}. \quad (4.2)$$

Observe que a pressão ao longo da direção z é considerada constante, ou seja, a pressão hidrodinâmica não varia ao longo da espessura do filme de óleo. Essa hipótese pode ser adotada devido à dimensão da folga radial ser muito pequena em relação ao comprimento e ao diâmetro do mancal (BARBOSA, 2018). As relações utilizadas na adimensionalização são apresentadas na Eq. (4.3).

$$\begin{aligned} \bar{x}_r &= \frac{x_r}{C}, & \bar{z}_r &= \frac{z_r}{C}, & \bar{x} &= \frac{x}{2\pi R}, & \bar{y} &= \frac{y}{L_h}, \\ \bar{z} &= \frac{z}{h_h}, & \bar{t} &= \Omega t, & \bar{\mu} &= \frac{\mu}{\mu_0}, & & \\ \bar{h}_h &= \frac{h_h}{C}, & \bar{p}_h &= \frac{p_h}{\mu_0 \Omega R^2} C^2, & E &= \frac{e}{C}, & & \\ \bar{F}_0 &= \int_0^1 \frac{1}{\bar{\mu}} d\bar{z}, & \bar{F}_1 &= \int_0^1 \frac{\bar{z}}{\bar{\mu}} d\bar{z}, & \bar{F}_2 &= \int_0^1 \frac{\bar{z}}{\bar{\mu}} \left(\bar{z} - \frac{\bar{F}_1}{\bar{F}_0} \right) d\bar{z}, & & \end{aligned} \quad (4.3)$$

sendo p_h a pressão hidrodinâmica, μ a viscosidade dinâmica do fluido, μ_0 a viscosidade de referência e t o tempo.

Note que a Eq. (4.2) trata-se de uma equação diferencial parcial que não pode ser resolvida analiticamente, logo, métodos numéricos de solução são utilizados para determinar o campo de pressão atuante no mancal. Primeiramente, discretizou-se a equação de Reynolds para transformá-la em uma equação algébrica, posteriormente, aplicou-se o Método dos Volumes Finitos (MVF) proposto em MALISKA (2004).

A Figura 4.2 apresenta a malha obtida por meio da discretização do domínio físico do mancal cilíndrico utilizando MVF. As direções \bar{x} , \bar{y} e \bar{z} (formas adimensionais) adotadas para o mancal cilíndrico também são apresentadas nessa figura.

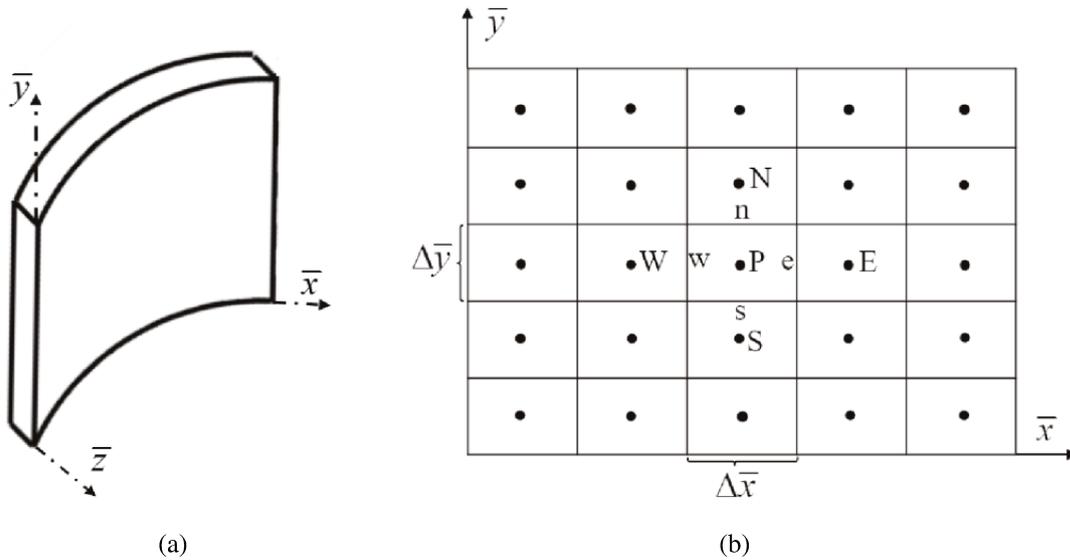


Figura 4.2: Discretização do domínio via MVF: (a) representação tridimensional; (b) malha discretizada (BARBOSA, 2018).

Com o objetivo de se obter uma solução com menor custo computacional, neste trabalho optou-se pela solução direta do sistema linear. Este método consiste em:

- Construção da matriz de coeficientes de acordo com a disposição dos volumes finitos na malha discretizada;
- Construção do vetor contendo os termos fonte da informação desejada de acordo com a disposição dos volumes;
- Obtenção do vetor contendo os valores pontuais da informação de interesse por meio do produto entre a inversa da matriz dos coeficientes e o vetor termo fonte.

Matematicamente, tem-se:

$$\Psi_p = \mathbf{C}_p^{-1} \mathbf{B}_p \quad (4.4)$$

onde Ψ_p é o vetor contendo a informação desejada, \mathbf{C}_p é a matriz de coeficientes e \mathbf{B}_p é o vetor de termo fonte.

A distribuição de temperatura T ao longo do mancal pode ser determinada utilizando a equação da energia, conforme indicado na Eq. (4.5). Esta abordagem pressupõe que a massa específica ρ , a condutividade térmica k_t e o calor específico c_p do óleo permanecem constantes com a variação de temperatura. Nesse cenário, apenas a viscosidade μ do óleo é considerada

como variável em função da temperatura. Além disso, é assumido que não há variação da temperatura do óleo ao longo da direção y do mancal.

$$\begin{aligned} \rho c_p \left(u \frac{\partial T}{\partial x} + w \frac{\partial T}{\partial z} \right) &= k_t \left(u \frac{\partial^2 T}{\partial x^2} + w \frac{\partial^2 T}{\partial z^2} \right) + \mu \Phi, \\ \Phi &= 2 \left[\left(\frac{\partial u}{\partial x} \right)^2 + \left(\frac{\partial w}{\partial z} \right)^2 \right] - \frac{2}{3} \left(\frac{\partial u}{\partial x} + \frac{\partial w}{\partial z} \right)^2 + \left(\frac{\partial u}{\partial z} + \frac{\partial w}{\partial x} \right)^2 + \left(\frac{\partial v}{\partial z} \right)^2 + \left(\frac{\partial v}{\partial x} \right)^2. \end{aligned} \quad (4.5)$$

Os parâmetros u , v e w são as velocidades do fluido ao longo das direções x , y e z do referencial curvilíneo I_C do mancal, respectivamente, podendo ser calculados pela Eq. (4.6).

$$\begin{aligned} u &= \frac{\partial p_h}{\partial x} \int_0^z \frac{z}{\mu} dz + \left(\frac{\Omega R}{F_0} - \frac{F_1}{F_0} \frac{\partial p_h}{\partial x} \right) \int_0^z \frac{dz}{\mu}, \\ v &= \frac{\partial p_h}{\partial y} \int_0^z \frac{z}{\mu} dz + \left(\frac{\partial p_h}{\partial y} \frac{F_1}{F_0} \right) \int_0^z \frac{dz}{\mu}, \\ w &= - \int_0^{h_h} \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) dz + \frac{\partial h_h}{\partial t}. \end{aligned} \quad (4.6)$$

Dada a Eq. (4.6), utiliza-se novamente o MVF associado ao método de solução direta para a obtenção do campo de temperatura já que esta equação diferencial parcial não possui solução analítica.

As condições de contorno empregadas para resolver o campo de temperatura incluem uma condição adiabática na fronteira entre o filme de óleo e a superfície do mancal, desconsiderando a transferência de calor na interface. Além disso, foi aplicada uma condição adiabática na fronteira entre o eixo e o filme de óleo. A hipótese de mancal adiabático é considerada uma abordagem conservadora, uma vez que resulta em valores calculados de temperatura mais elevados em comparação com outras hipóteses. Vale ressaltar que também foi incorporada a consideração de mistura nas regiões de injeção do óleo, contemplando a interação entre o óleo frio que entra no mancal e o óleo aquecido que circula por ele.

A Figura 4.3 ilustra a região de mistura no mancal, sendo T_2 e Q_2 a temperatura e a vazão do óleo circulante do mancal, T_{rep} e Q_{rep} são a temperatura e a vazão do óleo de entrada, respectivamente, e T_{mist} e Q_{mist} são a temperatura e a vazão resultante da mistura, respectivamente.

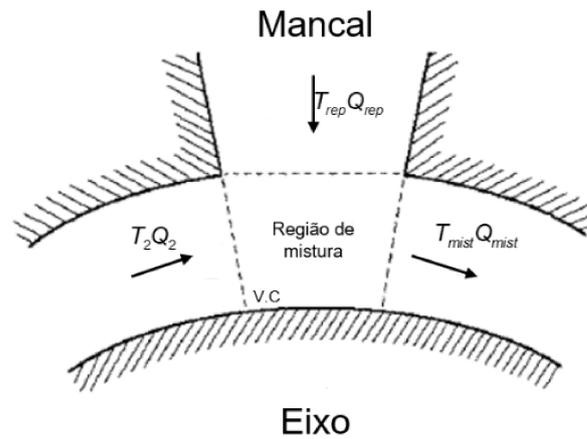


Figura 4.3: Volume de controle para o balanço de energia (ALVES, 2011).

Seguindo os procedimentos de (ALVES, 2011), obtém-se que:

$$T_{mist} = \frac{T_{rep}Q_{rep} + T_2Q_2}{Q_{mist}}, \quad (4.7)$$

$$Q_{mist} = Q_{rep} + Q_2,$$

Conhecido o campo de temperatura do óleo, o campo de viscosidade é determinado. Neste trabalho o modelo de Vogel apresentado na Eq. (4.8) foi utilizado para descrever a viscosidade em função da temperatura (SEETON, 2006).

$$\mu = a_1 \exp\left(\frac{a_2}{T + 273,15 + a_3}\right), \quad (4.8)$$

onde as constantes $a_1 = 5,506 \times 10^{-9}$, $a_2 = 5012$ e $a_3 = 0,1248$ foram determinadas a partir dos dados do óleo ISO VG 68.

Determinado o campo de viscosidade, calculam-se novamente os campos de pressão e temperatura e esse ciclo permanece até que seja verificada a convergência do campo de temperatura.

As forças de sustentação no mancal cilíndrico são obtidas a partir da integração do campo de pressão an área do mancal, conforme mostra a Eq. (4.9).

$$F_{hX} = \int_{-\frac{L_h}{2}}^{\frac{L_h}{2}} \int_0^{2\pi} p_h \cos(\theta) R d\theta dy, \quad (4.9)$$

$$F_{hZ} = \int_{-\frac{L_h}{2}}^{\frac{L_h}{2}} \int_0^{2\pi} p_h \sin(\theta) R d\theta dy.$$

4.2 Estimação dos Coeficientes Dinâmicos

Os coeficientes de rigidez e amortecimento dos mancais hidrodinâmicos são estimados aplicando variações nos deslocamentos e velocidades no eixo a partir da sua posição de equilíbrio. Como os coeficientes do filme de óleo são específicos para uma determinada posição do centro do eixo, é possível aplicar um incremento de deslocamento em uma das direções, resultando em variação do campo de pressão e modificação da força hidrodinâmica. Dessa maneira, os coeficientes podem ser obtidos pela relação entre as variações das forças hidrodinâmicas e as perturbações aplicadas, conforme Eq. (4.10).

$$\begin{aligned} \begin{Bmatrix} \Delta F_{hx} \\ \Delta F_{hz} \end{Bmatrix} &= - \begin{bmatrix} k_{xx} & k_{xz} \\ k_{zx} & k_{zz} \end{bmatrix} \begin{Bmatrix} \Delta x \\ \Delta z \end{Bmatrix} - \begin{bmatrix} c_{xx} & c_{xz} \\ c_{zx} & c_{zz} \end{bmatrix} \begin{Bmatrix} \Delta \dot{x} \\ \Delta \dot{z} \end{Bmatrix}, \\ k_{xx} &= \frac{\Delta F_x}{\Delta x}, & k_{xz} &= \frac{\Delta F_x}{\Delta z}, \\ k_{zx} &= \frac{\Delta F_z}{\Delta x}, & k_{zz} &= \frac{\Delta F_z}{\Delta z}, \\ c_{xx} &= \frac{\Delta \dot{F}_x}{\Delta \dot{x}}, & c_{xz} &= \frac{\Delta \dot{F}_x}{\Delta \dot{z}}, \\ c_{zx} &= \frac{\Delta \dot{F}_z}{\Delta \dot{x}}, & c_{zz} &= \frac{\Delta \dot{F}_z}{\Delta \dot{z}}, \end{aligned} \tag{4.10}$$

CAPÍTULO V

BANCADA EXPERIMENTAL DE TESTES

Este capítulo descreve a bancada experimental de testes construída para obtenção de dados. O sistema rotativo envolve um rotor flexível com três discos rígidos, o primeiro utilizando um rolamento auto compensador e os dois últimos utilizando mancais hidrodinâmicos. São apresentadas as diversas partes do equipamento, seguidas pela discretização em Elementos Finitos. O ajuste do modelo matemático é realizado através da análise de sinais de vibração, solucionando o problema inverso associado por meio de um método heurístico de otimização. Para validar o modelo, as respostas experimentais, obtidas a partir de forças de desbalanceamento, são confrontadas com os resultados numéricos.

5.1 Bancada de Teste

A Figura 5.1 apresenta a bancada de teste utilizada nos ensaios experimentais deste trabalho. Trata-se de um sistema rotativo horizontal da SpectraQuest, modelo MFS-RDS (*Machinery Fault & Rotor Dynamics Simulator*), fixado sobre uma mesa inercial. O sistema rotativo é composto por um eixo principal de aço 1045 com 19,01 mm de diâmetro e 950 mm de comprimento e tolerância de retificação $h7$. Além disso, a bancada conta com três discos rígidos e três mancais de suporte. O primeiro mancal é um rolamento auto compensador e os dois últimos são hidrodinâmicos cilíndricos.

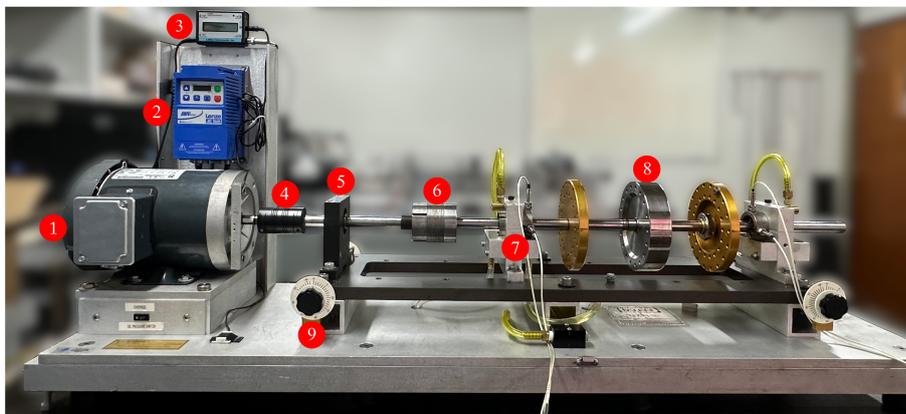


Figura 5.1: Bancada de testes: 1. motor elétrico; 2. inversor de frequência; 3. visor do tacômetro; 4. acoplamento; 5. mancal de rolamento; 6. peça secundária; 7. mancal hidrodinâmico; 8. disco; 9. parafuso para alinhamento.

Os componentes de acionamento do sistema rotativo são um motor elétrico de corrente contínua (Marathon[®] modelo 56T34F5301J Ac Motor) somado a um inversor de frequência (Lenze[®] AC tech SMVector Drive modelo ESV371N01SXB) para controle de velocidade, torque e direção.

Para conexão do motor e eixo empregou-se um acoplamento flexível com a finalidade de minimizar pequenas vibrações e ruídos, além de oferecer uma maior capacidade de absorção de desalinhamentos e impactos mecânicos. Este acoplamento é um modelo DT000175-C.750-C.625 de alumínio anodizado da marca Rocom[®].

Durante a fase de projeto da bancada, explorou-se a viabilidade de integrar atuadores eletromagnéticos. Esses dispositivos têm a capacidade de converter energia elétrica em movimento mecânico, fazendo uso de campos magnéticos para criar forças de atração que atuam sobre o eixo da máquina rotativa. Sua funcionalidade abrange o controle de vibração, regulação de carga e simulação de defeitos, tornando-os elementos de grande relevância.

A Figura 5.2 apresenta a região coberta pela peça secundária contendo o anel de armadura, localizado entre uma porca de fixação (a esquerda) e a elevação de maior diâmetro (a direita).

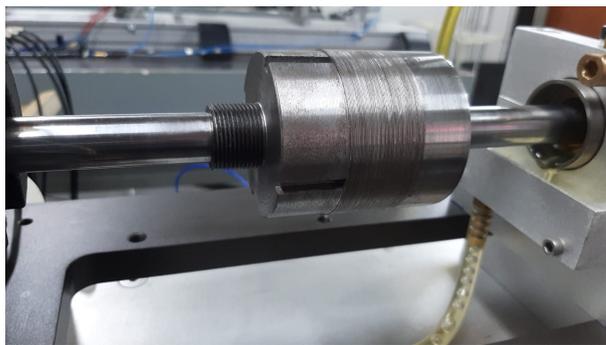


Figura 5.2: Peça secundária com porca de fixação e anel de armadura.

Conforme apresentado na Fig. 5.2, para viabilizar o uso do atuador, considerou-se a fabricação e o acoplamento por interferência de uma peça secundária ao eixo. As medidas para os diâmetros externos dessa peça são 25 mm, 27 mm e 65 mm, da esquerda para a direita. A peça receberá o anel de armadura projetado para sofrer ação das forças magnéticas oriundas do atuador eletromagnético e composto por lâminas de aço-silício com 0,5 mm de espessura, apresentando diâmetros interno e externo de 27 mm e 65 mm, respectivamente. A fixação dessas lâminas foi realizado por meio de uma porca de fixação.

A bancada foi projetada para operar com três discos rígidos distribuídos ao longo do eixo, conforme visto na Fig. 5.3. Os dois discos das extremidades são de alumínio com 150 mm de diâmetro e 16 mm de espessura (aproximadamente 0,676 kg cada) fixados no eixo por meio de abraçadeiras. Já o disco central é de aço 1045 com 150 mm de diâmetro e 35 mm de espessura (aproximadamente 3,95 kg) fixado no eixo através de uma bucha cônica (BGL[®] modelo HE 2305). Todos os discos contam com furos roscados a cada 20°, destinados ao posicionamento de massas para balanceamento e desbalanceamento da máquina.

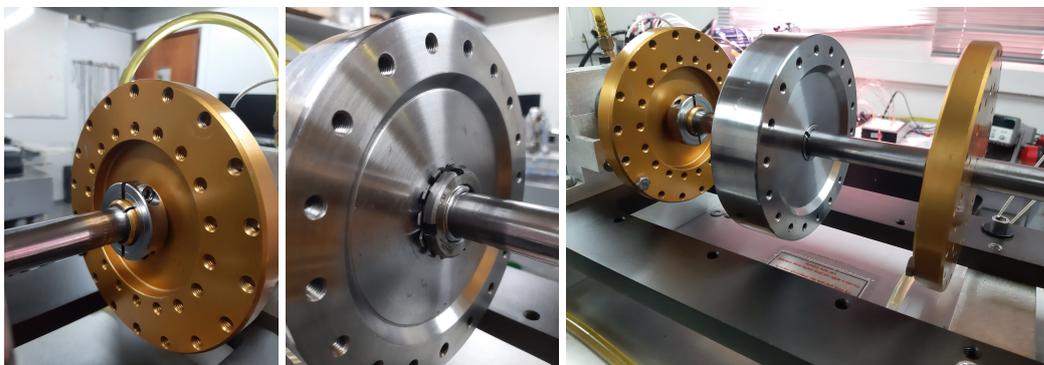


Figura 5.3: Discos rígidos e suas disposições.

A Figura 5.4 o primeiro mancal utilizado na bancada, de rolamento, é constituído por transdutores de força (SpectraQuest modelo M-FTVH) capaz de medir carregamentos dinâmicos nas direções horizontal e vertical da máquina (X e Z, respectivamente). A fixação do mancal no

eixo se deu por um rolamento auto compensador (Nachi® modelo 1205C3i) com bucha cônica (BGL® modelo KM 5).



Figura 5.4: Carcaça do mancal com transdutores de força e rolamento auto compensador.

Por outro lado, a Fig. 5.5 ilustra os segundo e terceiro mancais utilizados na bancada de teste. Ambos são hidrodinâmicos com comprimento de 12,8 mm e folga radial nominal de aproximadamente 0,0762 mm e que integram um kit de estudo fornecido pela SpectraQuest modelo MR-OWSK-3/4.

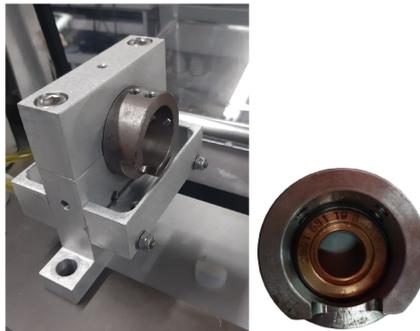


Figura 5.5: Carcaça do mancal hidrodinâmico cilíndrico.

5.2 Modelo em Elementos Finitos

A Figura 5.6 ilustra o modelo matemático desenvolvido com base no método dos Elementos Finitos para representar o comportamento dinâmico do rotor mencionado na Figura 5.1. O eixo foi discretizado em 44 elementos de eixo utilizando o modelo de Timoshenko, considerando os 12 primeiros modos de vibração do sistema. Essa abordagem é fundamental para compreender e prever o comportamento estrutural e dinâmico de sistemas complexos, como é o caso do rotor em questão.

Note na Fig. 5.1 que os componentes da peça secundária (Fig. 5.2) foram modelados como sendo discos, D_1 , D_2 e D_3 , posicionados nos nós #11, #13 e #15, respectivamente. Esse fato

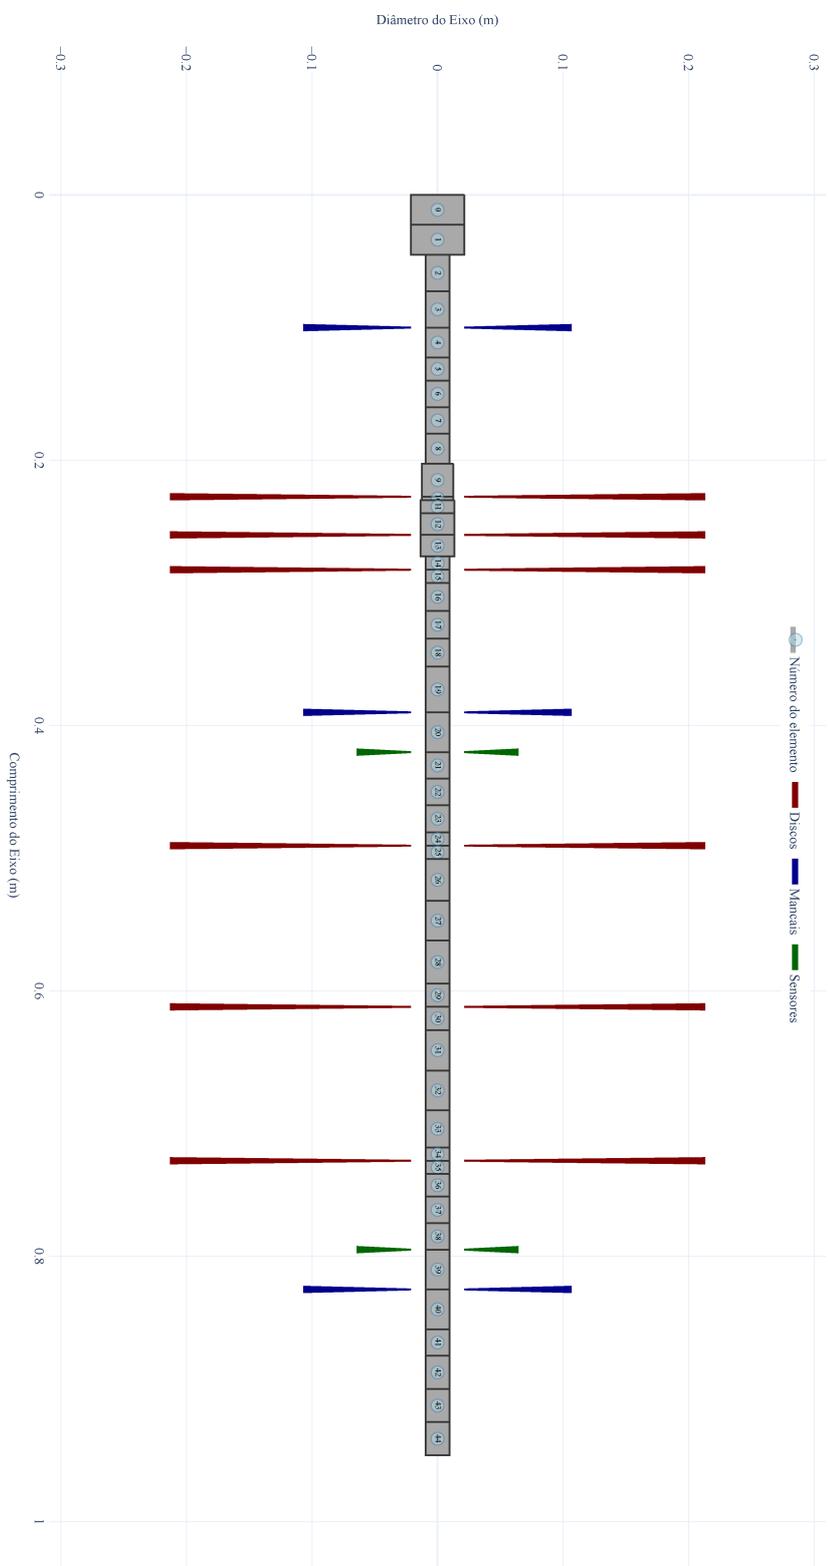


Figura 5.6: Modelo em Elementos Finitos do rotor da bancada experimental.

permitiu a integração das propriedades de inércia dos componentes da peça ao sistema rotativo, estimadas com auxílio de software específico.

Os três discos que compõem o sistema rotativo são D_4 (alumínio, 0,676 kg, nó #25), D_5 (aço 1045, 3,95 kg, nó #30) e D_6 (alumínio, 0,676 kg, nó #35). Referente aos mancais, o primeiro, B_1 , de rolamento, o segundo e terceiro, B_2 e B_3 , hidrodinâmicos, posicionados nos nós #4, #20 e #40, respectivamente. Os sensores foram estrategicamente dispostos ao longo das direções ortogonais dos nós #21 e #39.

Nas subseções abaixo serão apresentadas as etapas que envolvem o ajuste e validação do modelo matemático.

5.3 Ajuste do Modelo Matemático do Rotor

O processo de montagem da peça secundária no eixo pode resultar em alterações nas propriedades físicas dos materiais, caso não seja cuidadosamente controlado. A oscilação de temperatura pode causar variações nas dimensões da peça, levando a mudanças na densidade. A montagem com força excessiva pode introduzir tensões residuais no material, afetando o módulo de elasticidade. Além disso, essas tensões podem impactar o coeficiente de Poisson, que descreve a relação entre as deformações longitudinais e transversais de um material sob tensão.

Diante dessas considerações, em um ajuste inicial, os parâmetros como densidade (ρ), módulo de elasticidade (E), coeficiente de Poisson (ν), bem como os coeficientes relacionados ao amortecimento proporcional (α e β), foram considerados desconhecidos. O ajuste concentrou-se exclusivamente no eixo com a peça secundária na condição de extremidades livres, com o objetivo de verificar possíveis variações nas propriedades físicas.

O ajuste com os sinais experimentais ocorreu no domínio da frequência, utilizando Funções de Resposta em Frequência (FRF). Apesar da possibilidade de realização do ajuste separadamente para cada uma das direções consideradas, horizontal e vertical, optou-se por ajustar simultaneamente ambas as direções ortogonais. Isso se deve ao fato de que os coeficientes do amortecimento proporcional precisam ser iguais, independentemente da direção analisada.

As FRFs numéricas foram obtidas por meio da resolução direta das equações de movimento no domínio da frequência, eliminando a necessidade de recorrer à resposta ao impacto no domínio do tempo. Já as FRFs experimentais foram obtidas por meio de impactos aplicados ao longo da direção horizontal, separadamente, utilizando um martelo do modelo 086C01 da

PCB[®].

As medições foram realizadas com o analisador de sinais LMS SCADAS MOBILE da SIEMENS[®], abrangendo uma faixa de aquisição de 10 a 300 Hz, com uma resolução de 0,20 Hz (20 FRF medidas para o cálculo de médias). As respostas foram registradas por meio de acelerômetros (modelo 352C22 da PCB[®]) estrategicamente posicionados ao longo da mesma direção das forças de impacto de modo que os nós não coincidem com os modos de vibração da estrutura.

Para estimação dos parâmetros desconhecidos utilizou-se o método heurístico Evolução Diferencial (*Differential Evolution - DE*) (STORN; PRICE, 1997). A escolha se baseou na capacidade comprovada deste método em resolver uma ampla gama de problemas inversos complexos de maneira eficiente, evitando mínimos locais. Este algoritmo é uma evolução do Algoritmo Genético de Goldberg que incorpora conceitos de herança genética, mutação, seleção natural e cruzamento, inspirados em processos biológicos (LOBATO et al., 2008).

A Equação (5.1) apresenta a função objetivo utilizada no ajuste do modelo. Apesar da aquisição das FRFs terem sido realizadas na faixa de 10 até 300 Hz, a faixa de atuação do processo de ajuste, foi fixada nas regiões onde estão localizadas as frequências naturais de interesse (faixa de ± 3 Hz).

$$FO = \sum_{i=1}^N \frac{\|\mathbf{FRF}_{exp,i} - \mathbf{FRF}_{mod,i}\|}{\|\mathbf{FRF}_{exp,i}\|} \quad (5.1)$$

onde N é o número de FRFs utilizadas no processo, $\mathbf{FRF}_{exp,i}$ são as FRFs obtidas experimentalmente e $\mathbf{FRF}_{mod,i}$ são as FRFs determinadas pelo modelo EF da bancada com parâmetros determinados pelo otimizador (entradas e saídas nas mesmas posições das experimentais).

O processo de minimização mencionado foi repetido 10 vezes, utilizando uma população inicial de 40 indivíduos no otimizador. Os valores adotados para o controle da amplificação da diferença entre os indivíduos e a taxa de mutação foram, respectivamente, 0,8 e 0,5. Os parâmetros determinados no final do processo estão associados ao menor valor da função objetivo.

A Tabela 5.1 apresenta todos os parâmetros desconhecidos considerados, seus respectivos limites inferiores e superiores, bem como os valores encontrados no final do processo de minimização associado ao menor valor da função objetivo que foi de aproximadamente 1,07889.

Tabela 5.1: Parâmetros determinados pelo procedimento de otimização.

Parâmetros	Limite inferior	Valor ótimo	Limite superior
E [GPa]	205	214,6	217
ρ [kg/m^3]	$7,5 \times 10^3$	$7,844 \times 10^3$	$7,9 \times 10^3$
ν	0,28	0,2926	0,35
α	0	1,99836	5
β	0	$1,9 \times 10^{-4}$	$1,0 \times 10^{-5}$

Conforme observado na terceira coluna da Tab. 5.1, os valores encontrados pelo otimizador DE são coerentes se comparados aos valores nominais dispostos na literatura. A montagem da peça secundária no eixo não provocou alterações significativas nas propriedades físicas do sistema. Dessa forma, o ajuste simultâneo para ambas as direções consideradas apresenta resultados que atendem plenamente às necessidades do problema em questão.

A partir dos resultados da Tab. 5.1, as Figs. 5.7, 5.8 e 5.9 apresentam as FRFs ajustadas determinadas por combinações de excitações e respostas nos nós #3, #22 e #38, respectivamente. Para fins de comparação, as FRFs obtidas experimentalmente também são exibidas.

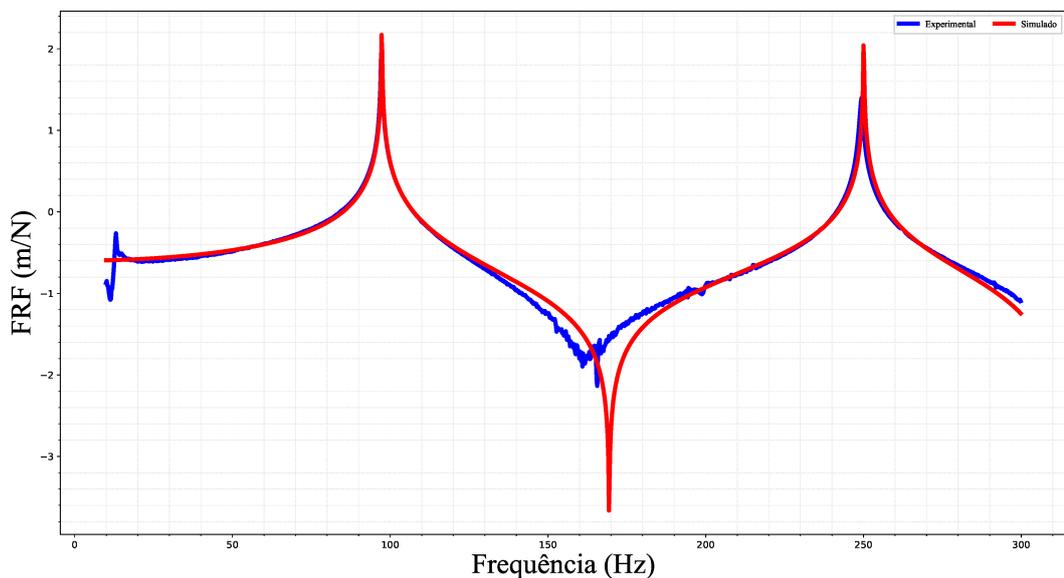


Figura 5.7: FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #3.

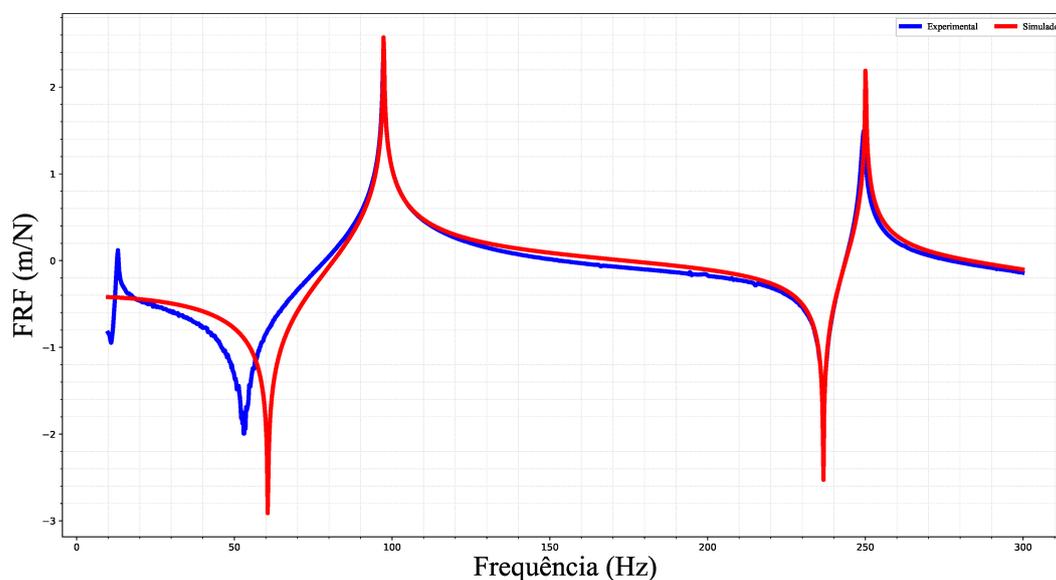


Figura 5.8: FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #22.

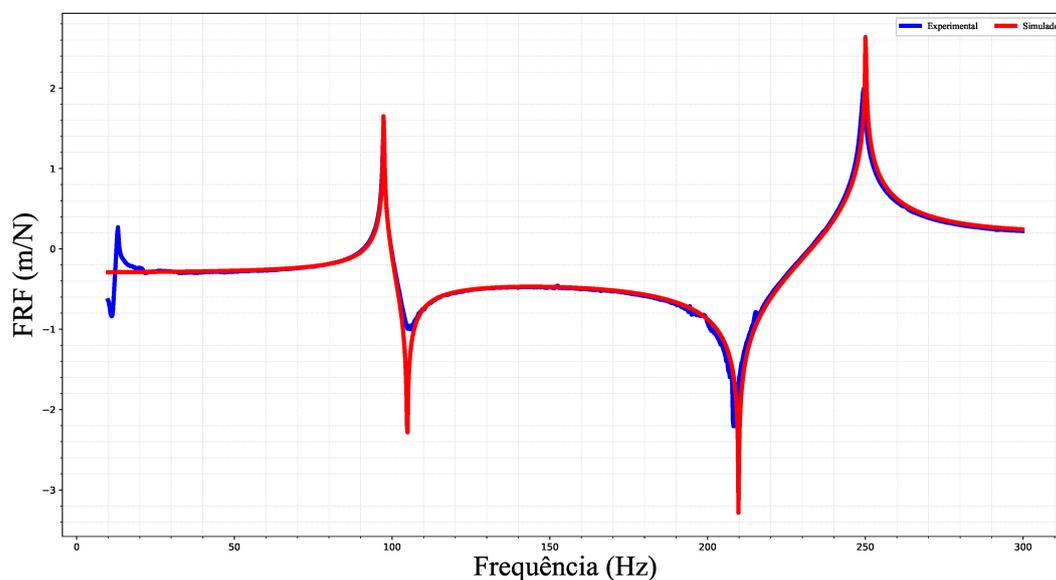


Figura 5.9: FRFs experimentais e ajustadas - excitação no nó #22 e resposta em #38.

Conforme as Figs. 5.7, 5.8 e 5.9, as duas primeiras frequências naturais experimentais para o eixo foram medidas em 97,27 Hz e 249,61 Hz, respectivamente. O modelo ajustado apresentou frequências naturais de 97,27 Hz e 250,00 Hz, resultando num erro relativo de aproximadamente 0,1562% para a segunda frequência natural. Notavelmente, as curvas geradas a partir do modelo ajustado para o eixo com a peça secundária demonstram estar notavelmente

próximas das curvas obtidas experimentalmente, evidenciando um ajuste satisfatório.

5.4 Estimação dos Coeficientes Dinâmicos para os Mancais Hidrodinâmicos

O ajuste do modelo matemático inclui a estimação dos coeficientes dinâmicos por meio do modelo termohidrodinâmico envolvendo a aplicação de variações nos deslocamentos e velocidades. A partir da posição de equilíbrio, é possível determinar os respectivos coeficientes de rigidez e amortecimento.

A estimação dos coeficientes dinâmicos para mancais hidrodinâmicos está diretamente relacionada à folga radial. Essa folga pode ser comprometida devido ao desgaste dos mancais, incluindo fatores como atrito, cargas excessivas, lubrificação inadequada, presença de impurezas no lubrificante, entre outros.

Diante dessas considerações, medições foram realizadas nas posições dos mancais mantendo um diâmetro de eixo de aproximadamente 19,01 mm, valor considerado discrepante segundo a tolerância especificada no projeto (retificado h7). Além disso, os diâmetros internos dos mancais foram estimados utilizando uma máquina de medição tridimensional da Mitutoyo[®] cuja precisão é de 0,001 mm. Essa máquina encontra-se disponível no Laboratório de Ensino em Metrologia (LEMETRO) sob a supervisão da prof. Dr. Rosenda Valdes Arencibia.

Conforme sugerido no estudo de Cavallini Jr. et al. (2017), foram efetuadas medidas de diâmetro em quatro seções distintas (A, B, C e D) no segundo e terceiro mancal da bancada experimental, denominados A_1 e A_2 , respectivamente. Essas medidas foram obtidas em quatro pontos de medição diferentes, numerados como 1, 2, 3 e 4, como indicado na Fig. 5.10.

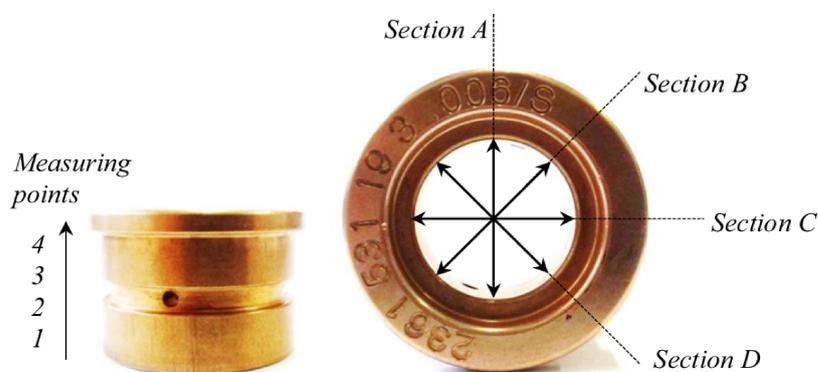


Figura 5.10: Medição de pontos e seções no rolamento (CAVALLINI Jr. et al., 2017).

A Tabela 5.2 apresenta as médias e os desvios padrões para o diâmetro de cada um dos

mancais ao longo dos pontos e seções de medições sugeridos. Estes valores revelam a não uniformidade dos mancais que se mostraram não totalmente cilíndricos. Em um cenário ideal é importante garantir que as folgas radiais sejam uniformes e estejam dentro das tolerâncias especificadas no projeto. Conseqüentemente, . No entanto, a folga radial será considerada como constante a fim de aplicação do modelo não linear proposto por Capone (1986).

Tabela 5.2: Medidas de diâmetro interno para os mancais hidrodinâmicos.

	B₂	B₃
Média [mm]	19,186	19,185
Desvio padrão [mm]	0,013	0,007

A hipótese de mancal curto é caracterizada pela relação $L_H/2R \leq 0,5$, onde L_H representa o comprimento do mancal e R é o raio. Para o caso em questão, tem-se $L_H/2R = 12,8/19,01 = 0,673$. No entanto, os resultados obtidos em Cavallini Jr. et al. (2017), juntamente com as similaridades verificadas entre as respostas obtidas através da teoria não linear de mancal curto e a teoria linear de mancal longo no trabalho de Cavallini Jr. et al. (2015), justificam a consideração do modelo não linear para mancais curtos neste trabalho.

A Tabela 5.3 apresenta as propriedades comuns aos mancais. O mancal B_2 exibe uma folga radial de $9,8 \times 10^{-5}$ m e um carregamento na direção Z de 28,7 N. Por outro lado, o mancal B_3 possui folga radial de $9,7 \times 10^{-5}$ m e carregamento de 40,75 N. O óleo lubrificante utilizado é o ISO VG 68, cujas especificações também estão descritas na tabela em questão.

Tabela 5.3: Propriedades comuns para os mancais hidrodinâmicos.

Propriedades dos mancais.	
Raio do eixo [m]	0,009505
Comprimento do mancal [m]	0,0128
Posição injeção de óleo [°]	90
Propriedades do óleo lubrificante.	
Condutividade Térmica [W/mC]	0,15
Calor específico [$J/(kg^{\circ}K)$]	1951
Densidade [kg/m^3]	874
Viscosidade a $40^{\circ}C$ [$Pa.s$]	0,0571
Viscosidade a $100^{\circ}C$ [$Pa.s$]	0,0077
Temperatura do óleo de reposição [$^{\circ}C$]	23

Uma vez definidas as propriedades dos mancais e do óleo lubrificante, os coeficientes dinâmicos associados aos mancais B_2 e B_3 são estimados pelo modelo termohidrodinâmico

considerando uma faixa de variação para a velocidade de rotação. Por conveniência, adotou-se uma interpolação cúbica para uma representação suave e contínua para aqueles valores intermediários.

As Figuras 5.11, 5.12, 5.13 e 5.14 apresentam, respectivamente, os coeficientes de rigidez e amortecimento estimados para os mancais B_2 e B_3 de acordo com o modelo termohidrodinâmico implementado com velocidade de rotação variando de 600 a 3600 rev/min.

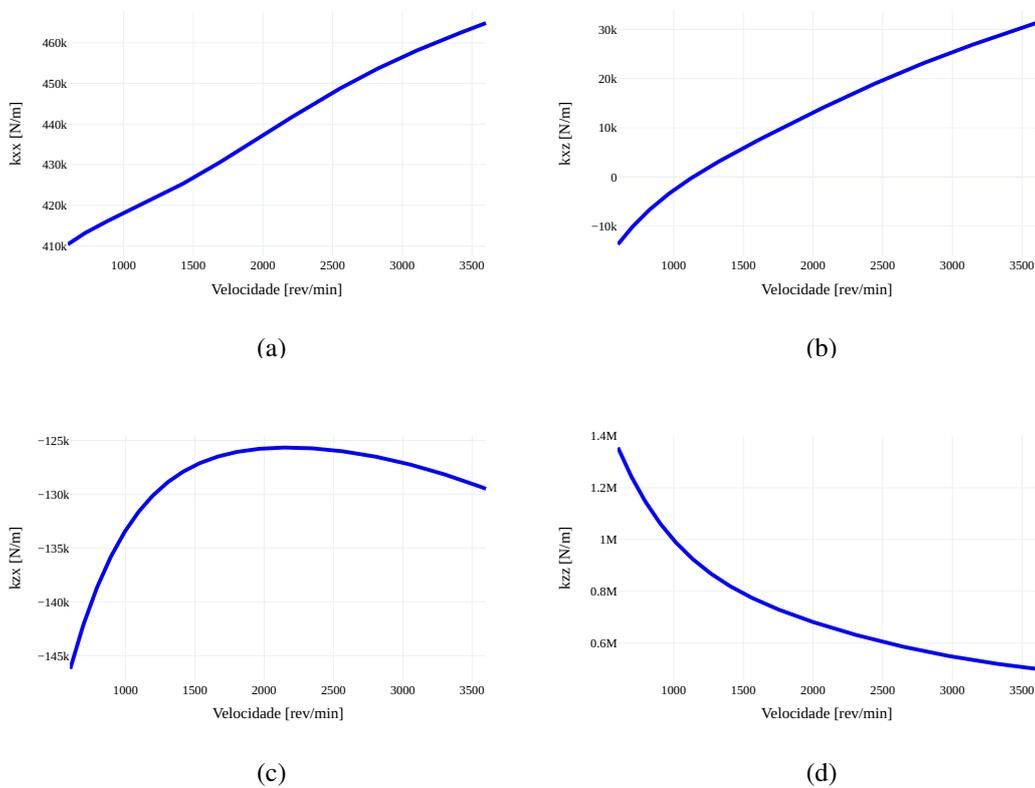
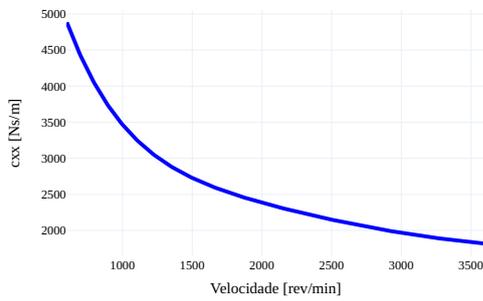
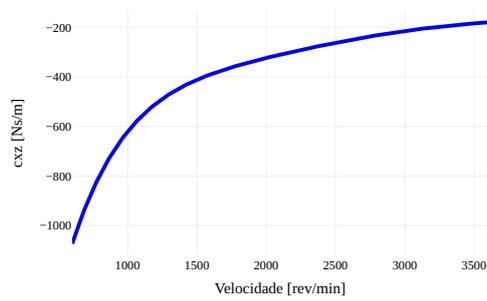


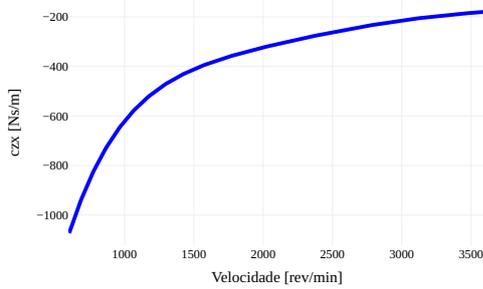
Figura 5.11: Coeficientes de rigidez para B_2 : (a) K_{xx} , (b) K_{xz} , (c) K_{zx} e (d) K_{zz} .



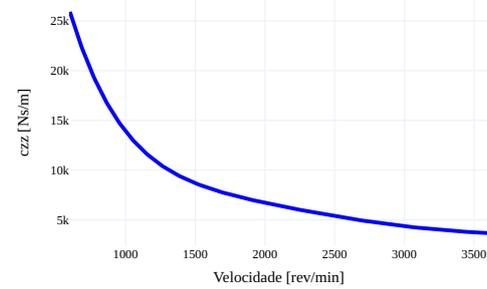
(a)



(b)

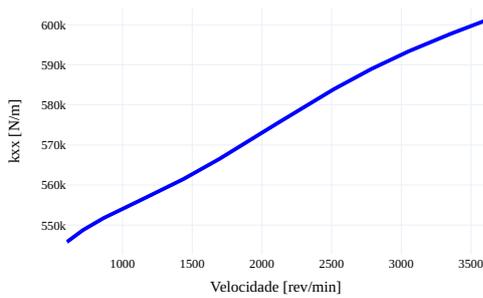


(c)

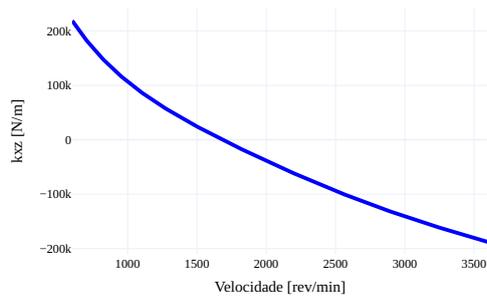


(d)

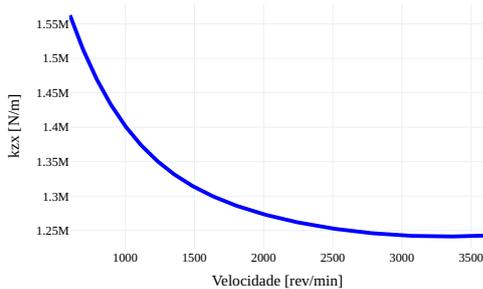
Figura 5.12: Coeficientes de amortecimento para B_2 : (a) C_{xx} , (b) C_{xz} , (c) C_{zX} e (d) C_{zz} .



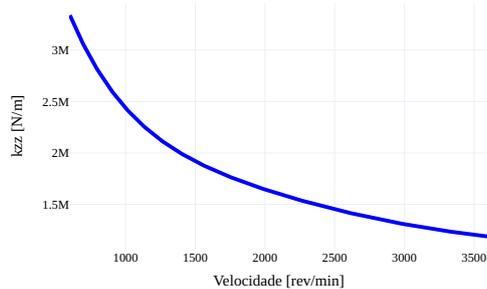
(a)



(b)



(c)



(d)

Figura 5.13: Coeficientes de rigidez para B_3 : (a) K_{xx} , (b) K_{xz} , (c) K_{zx} e (d) K_{zz} .

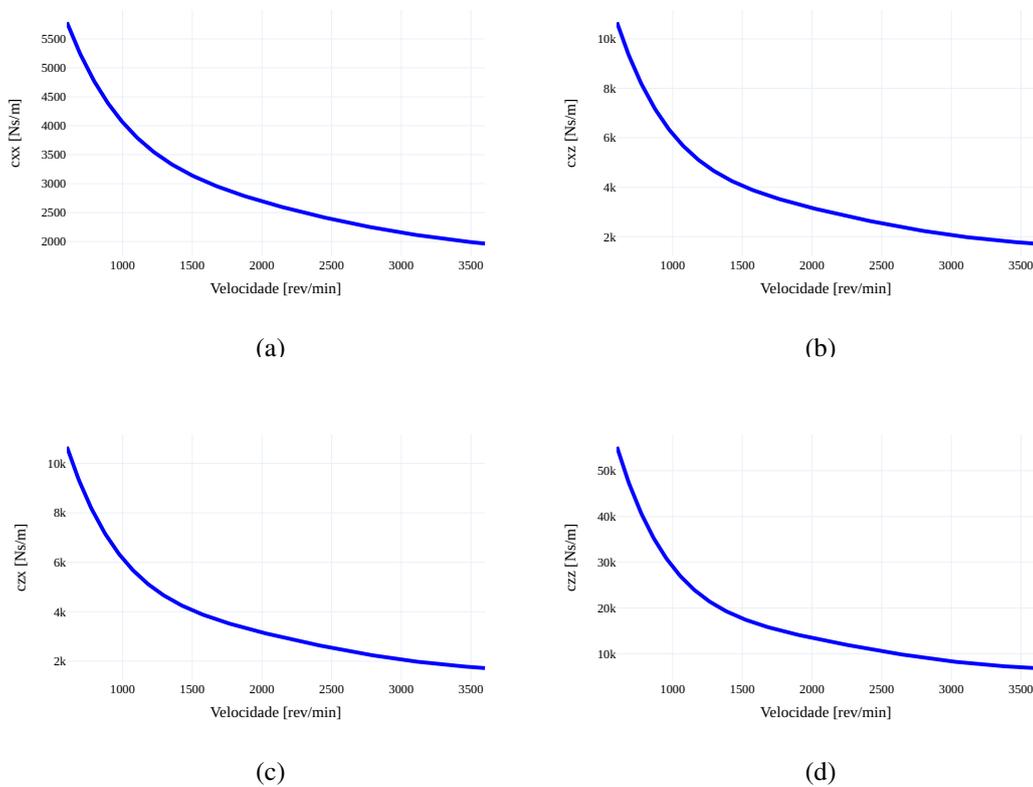


Figura 5.14: Coeficientes de amortecimento para B_3 : (a) C_{xx} , (b) C_{xz} , (c) C_{zx} e (d) C_{zz} .

Conforme observado nas Figs. 5.11, 5.12, 5.13 e 5.14, as curvas obtidas tanto para os coeficientes diretos quanto para os cruzados em ambos os mancais seguem um comportamento similar ao esperado.

5.5 Respostas ao Desbalanceamento

Esta subseção é dedicada à análise do comportamento dinâmico do modelo matemático quando comparado ao sistema real quando o efeito giroscópico está atuando. Diante disso, um procedimento de atualização de ajuste do modelo foi conduzido para quantificar a condição de desbalanceamento e, ainda, estimar os parâmetros para o mancal de rolamento.

O algoritmo DE foi empregado novamente para determinar as massas e posições angulares equivalentes que devem ser inseridas em cada disco para obter as reais condições de desbalanceamento da bancada de teste e os coeficientes de rigidez e amortecimento para o mancal de rolamento B_1 .

Os limites dos coeficientes do mancal B_1 foram estimados por meio de uma abordagem experimental adaptada de Oliveira (2015) que envolve a aplicação de cargas conhecidas na base

de um sistema do tipo basculante, onde o mancal está localizado.

Segundo esta abordagem, os dados de saída do transdutor de força, correspondentes a cada força aplicada são registrados para discernir a relação entre a força aplicada e a resposta do transdutor. Os coeficientes de rigidez são estimados pela inclinação da curva, enquanto as estimativas de amortecimento podem ser derivadas da análise do comportamento amortecedor ao longo do tempo. Por conveniência, os termos cruzados são considerados nulos.

A implementação da função objetivo, Eq. (5.2), é dada pela soma do erro relativo entre as discrepâncias de amplitude na componente 1X e entre suas respectivas posições angulares.

$$FO_{update} = \sum_{i=1}^N \frac{\| \max(\mathbf{Out}_{exp,i}) - \max(\mathbf{Out}_{mod,i}) \|}{\| \max(\mathbf{Out}_{exp,i}) \|}, \quad (5.2)$$

onde N é o número de respostas de deslocamento considerados no processo de minimização, $\mathbf{Out}_{exp,i}$ é a resposta experimental à vibração medido diretamente na bancada de teste e $\mathbf{Out}_{mod,i}$ é a resposta associada determinada pelo modelo matemático.

O processo de minimização mencionado foi repetido 10 vezes, utilizando uma população inicial de 40 indivíduos no otimizador. Os valores adotados para o controle da amplificação da diferença entre os indivíduos e a taxa de mutação foram, respectivamente, 0,8 e 0,5.

A Tabela 5.4 apresenta os parâmetros desconhecidos considerados, seus respectivos limites inferiores e superiores, bem como os valores encontrados no final do processo de minimização associado ao menor valor da função objetivo que foi de aproximadamente 0,08562.

Tabela 5.4: Parâmetros determinados pelo procedimento de atualização do modelo.

Parâmetros	Limite Inferior	Valor Ótimo	Limite Superior
Disco D_4			
Desbalanceamento [kg m]	0	$2,31 \times 10^{-4}$	$1,0 \times 10^{-3}$
Fase [°]	-180	115,79	180
Disco D_6			
Desbalanceamento [kg m]	0	$4,79 \times 10^{-4}$	$1,0 \times 10^{-3}$
Fase [°]	-180	-140,86	180
Disco D_5			
Desbalanceamento [kg m]	0	$7,15 \times 10^{-4}$	$1,0 \times 10^{-3}$
Fase [°]	-180	36,67	180
Mancal B_1			
K_{xx} N/m	$1,0 \times 10^3$	$1,92 \times 10^5$	$1,0 \times 10^6$
K_{zz} N/m	$1,0 \times 10^3$	$1,13 \times 10^5$	$1,0 \times 10^6$
C_{xx} Ns/m	$1,0 \times 10^2$	$1,88 \times 10^2$	$1,0 \times 10^3$
C_{zz} Ns/m	$1,0 \times 10^2$	$1,15 \times 10^2$	$1,0 \times 10^3$

Para avaliar a capacidade representativa do modelo matemático, confrontam-se as respostas ao desbalanceamento obtidas numericamente, utilizando os resultados da Tab. 5.4, com as respostas experimentais. Para tal fim, considerou-se o sistema operando a uma rotação nominal de 1200 rev/min e as respostas experimentais foram medidas pelo analisador Agilent® modelo 35670A com tempo total de aquisição de 1 s em passos de 0,0005 s, aproximadamente.

A Figura 5.15 apresenta um comparativo entre as respostas experimentais e numéricas para o plano de medição S_1 cujos sensores estão posicionados no nó #21 nas direções X e Z .

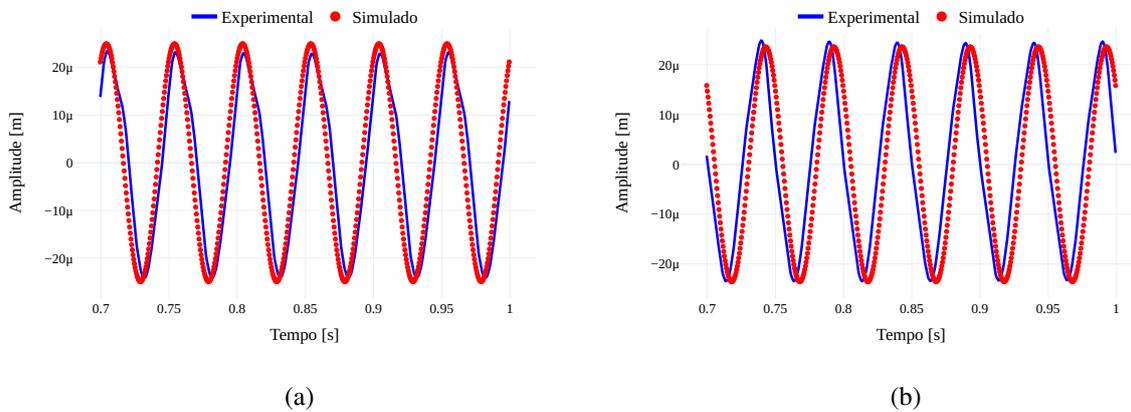


Figura 5.15: Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_1 nas direções (a) X e (b) Z .

A Figura 5.16 apresenta um comparativo entre as respostas experimentais e numéricas para o plano de medição S_2 cujos sensores estão posicionados no nó #39 nas direções X e Z .

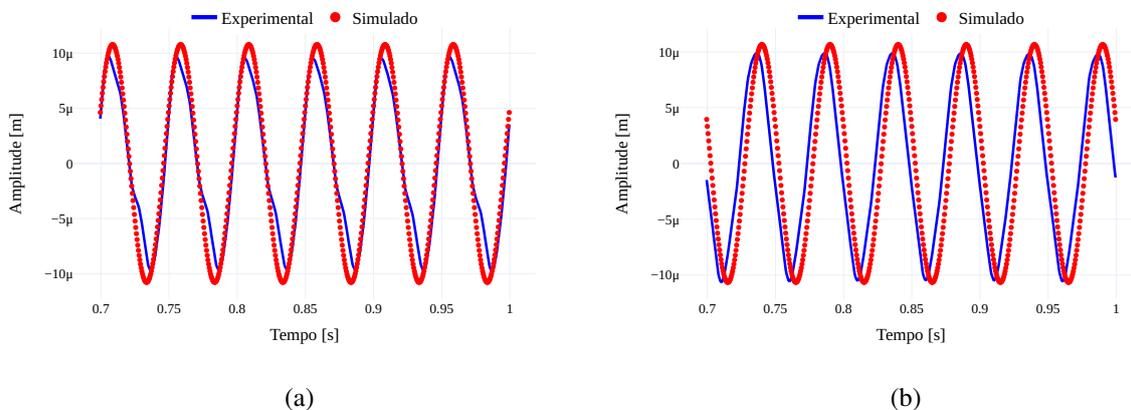


Figura 5.16: Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_2 nas direções (a) X e (b) Z .

As pequenas discrepâncias observadas nas Figs. 5.15 e 5.16 entre as respostas experimentais e do modelo matemático podem estar relacionadas a um leve desbalanceamento residual,

bem como a problemas nos mancais hidrodinâmicos, como variação da temperatura da película de óleo ao longo de suas extremidades, que não são considerados no modelo. Além disso, a cavitação (ZAPOMĚL; FERFECKI, 2011) e o desgaste natural são fenômenos que influenciam diretamente para a não uniformidade dos mancais (CAVALLINI Jr. et al., 2017) e podem contribuir negativamente para as respostas.

Note que o sistema é excitado somente pelo desbalanceamento e a frequência de maior energia será a componente 1X. Diante disso, os sinais obtidos experimentalmente podem ser reconstruídos levando em consideração apenas a contribuição desta componente. As Figs. 5.17, 5.18 e 5.19 apresentam uma nova comparação entre as respostas numéricas e experimentais, bem como as respectivas órbitas em seus planos correspondentes, considerando apenas a contribuição da componente 1X na reconstrução das respostas experimentais.

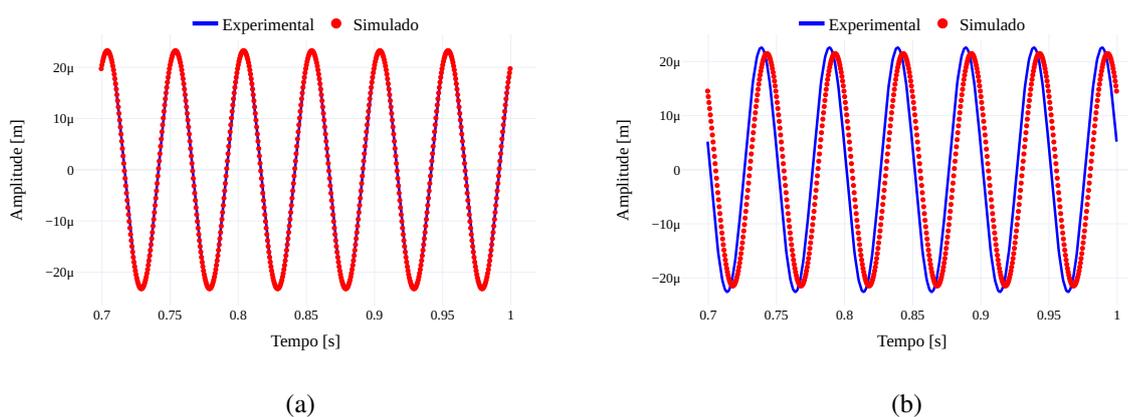


Figura 5.17: Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_1 nas direções (a) X e (b) Z .

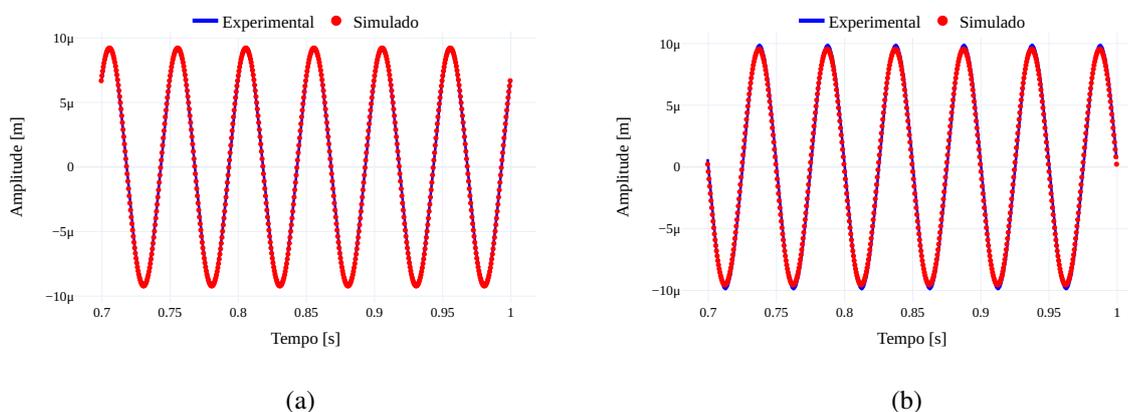


Figura 5.18: Respostas temporais experimentais e obtidas do modelo matemático do rotor para o plano S_2 nas direções (a) X e (b) Z .

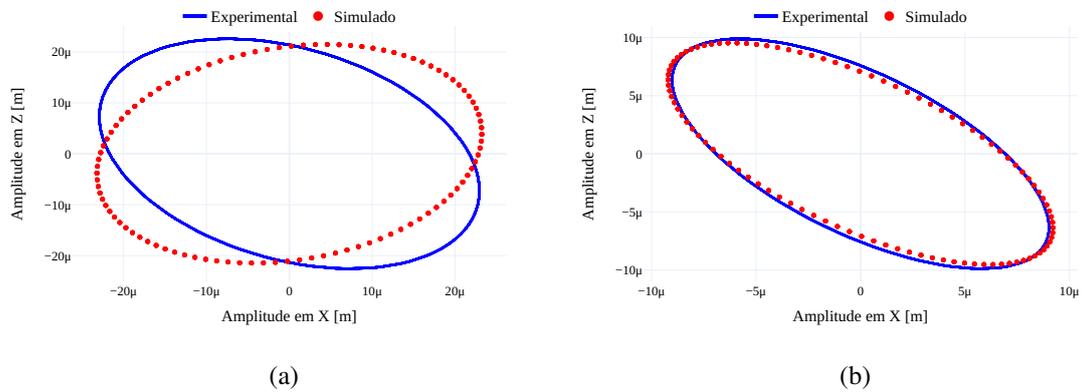


Figura 5.19: Órbitas experimentais e do modelo matemático nos planos (a) S_1 e (b) S_2 .

Conforme ilustrado nas Figs. 5.15, 5.16, 5.17, 5.18 e 5.19 as respostas do modelo matemático são semelhantes às experimentais. Percebe-se uma pequena discrepância apenas entre as respostas para o plano de medição S_1 na direção Z . Isso se deve a algum fenômeno que o processo de desbalanceamento não foi capaz de eliminar, fato pelo qual as aplicações serão restritas a uma velocidade de 1200 rev/min ou próximas a isso.

CAPÍTULO VI

MODELO MATEMÁTICO PARA FALHAS

Este capítulo discorre acerca da implementação numérico-computacional de falhas que ocorrem com maior frequência em rotores. Inicialmente, apresenta-se uma introdução sobre o desbalanceamento, em seguida, o modelo matemático conduzido por Xia et al. (2019) para desalinhamento em rotores com acoplamentos flexíveis é apresentado e, posteriormente, apresenta-se também um dos principais modelos matemáticos para a tratativa do *breathing*, fenômeno característico em eixos rotativos com trincas transversais. O modelo em questão é o de Mayes, além de amplamente utilizado na literatura, possui baixo custo computacional. Por fim, análises numéricas e experimentais referentes ao comportamento dinâmico do rotor na presença de falhas são realizadas. Vale ressaltar que o objetivo deste capítulo não pode ser vinculado à escolha do modelo mais realista, mas de apresentar um modelo com capacidade representativa para a obtenção de um conjunto de dados robusto de forma rápida e eficaz para aplicação da metodologia de diagnóstico proposta.

6.1 Rotores Desbalanceados

Segundo Zhang, Yang e Wang (2019), o desbalanceamento se dá devido a uma distribuição não uniforme de massa em torno da linha de centro do eixo de um rotor. Vibrações resultantes desta assimetria são, provavelmente, a anomalia mais comum observada em máquinas rotativas (SCHEFFER; GIRDHAR, 2004). As vibrações normalmente dominam o espectro e ocorrem na frequência de rotação da máquina $1X$.

6.2 Rotores Desalinhados

Juntamente com o desbalanceamento, o desalinhamento figura como uma das principais origens de vibração em máquinas rotativas. Isso se deve, em grande parte, à configuração habitual de acoplar dois rotores (de acionamento e acionado) para a transmissão de conjugado mecânico em linhas de produção industriais (SCHEFFER; GIRDHAR, 2004).

Conforme apontado por Piotrowski (2006), desalinhamentos podem surgir quando a linha central do motor e do eixo não está alinhada adequadamente, resultando em potenciais problemas como excesso de vibração, ruído, aumento da temperatura dos mancais e uma maior propensão a falhas prematuras tanto nos mancais quanto no eixo.

O desalinhamento pode ocorrer em direções paralelas e/ou angulares. O segundo ocorre quando as linhas de centro do eixo dos rotores se interceptam, formando um ângulo entre si, ou seja, quando as linhas são concorrentes, enquanto o primeiro ocorre quando as linhas de centro dos eixos dos rotores não se coincidem, não estão alinhados, embora possam estar paralelos entre si. A Fig. 6.1 apresenta exemplos de desalinhamento do eixo sendo eles: paralelo, angular e combinado.

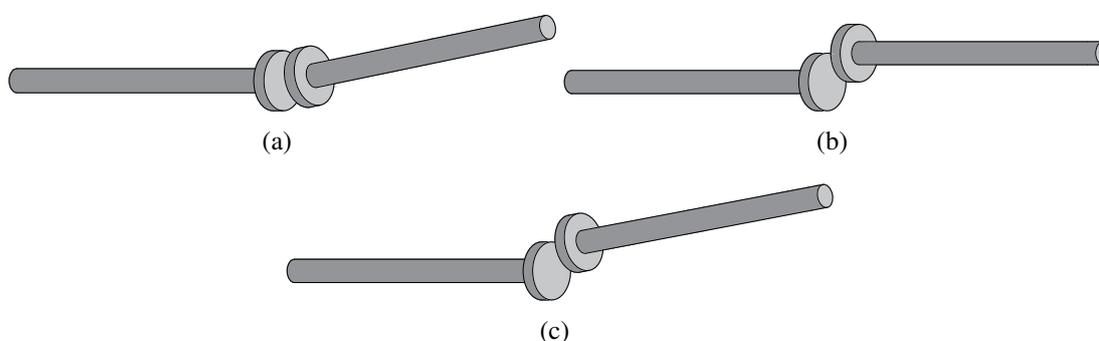


Figura 6.1: Representação do desalinhamento (a) angular, (b) paralelo e (c) combinado.

O desalinhamento angular além de resultar em predominância de vibrações axiais em torno da frequência de rotação, $1X$, também provoca o aparecimento de elevados níveis de vibração axial em seus múltiplos $2X$ e $3X$. Por outro lado, o desalinhamento paralelo ocasiona a manifestação de altos níveis vibracionais na frequência $2X$, devido à ocorrência de dois esforços mecânicos por ciclo nos rotores (REDMOND; AL-HUSSAIN, 2001; SCHEFFER; GIRDHAR, 2004; ADAMS, 2009; ZHANG; YANG; WANG, 2019).

O desalinhamento paralelo frequentemente ocorre em conjunto com o angular, resultando em vibrações significativas em torno da frequência de rotação $1X$. Contudo, quando o paralelo

prevalece, é a componente $2X$ que se evidencia proeminente no espectro de frequência. Se ambos os desalinhamentos angular e paralelo tornam-se acentuados, picos vibracionais notáveis podem surgir em múltiplos da velocidade síncrona de rotação, variando de $3X$ a $8X$ (SCHEFFER; GIRDHAR, 2004).

A modelagem dos distintos tipos de desalinhamento varia conforme a abordagem adotada por cada autor, sendo que a natureza do acoplamento, se rígido ou flexível, exerce uma influência direta sobre o modelo. Nessas situações, é sugerido que, para a análise da vibração lateral, acoplamentos do tipo elemento flexível sejam modelados na forma de uma junta articulada com rigidez rotacional. Este trabalho contempla a modelagem do desalinhamento com acoplamento flexível proposto nos trabalhos de Xia et al. (2019). Detalhes para desalinhamento com acoplamento rígido podem ser encontrados nos trabalhos de Al-Hussain e Redmond (2002).

6.2.1 Desalinhamento em Rotores com Acoplamento Flexível

Em Xia et al. (2019), os autores analisaram as respostas de vibração de dois rotores interligados (de acionamento e acionado) por um acoplamento hexagonal flexível, no qual pode ocorrer desalinhamento angular e paralelo. Os acoplamentos flexíveis têm a capacidade de aumentar a tolerância do conjunto rotativo ao desalinhamento. No entanto, sua eficácia diminui em estágios avançados de desalinhamento. Esses acoplamentos são empregados para conectar e transmitir energia de um eixo de direcionamento para um eixo acionado, com o objetivo de compensar desvios de deslocamentos lineares e angulares (SAAVEDRA; RAMIREZ, 2004).

No contexto deste modelo específico, as forças de reação induzidas pelo desalinhamento paralelo e angular na região do acoplamento são detalhadas nas subseções seguintes. As coordenadas generalizadas para o modelo são dadas pela Eq. (6.1), onde assume-se a existência de deslocamentos laterais u e w e rotações em torno do eixo axial β , os índices 1 e 2 representam os nós de atuação do acoplamento.

$$\mathbf{q} = \{u_1 \ w_1 \ \beta_1 \ u_2 \ w_2 \ \beta_2\} \quad (6.1)$$

6.2.1.1 Forças de Reação do Desalinhamento Paralelo

A Figura 6.2 apresenta uma conexão de dois eixos por meio de um acoplamento do tipo flexível, composto por 6 furos e material elástico projetado para compensar desalinhamentos

radiais, axiais e angulares. No diagrama, o eixo acionado (*driven rotor*) é destacado em preto, enquanto o eixo de acionamento (*driving rotor*) é representado em azul.

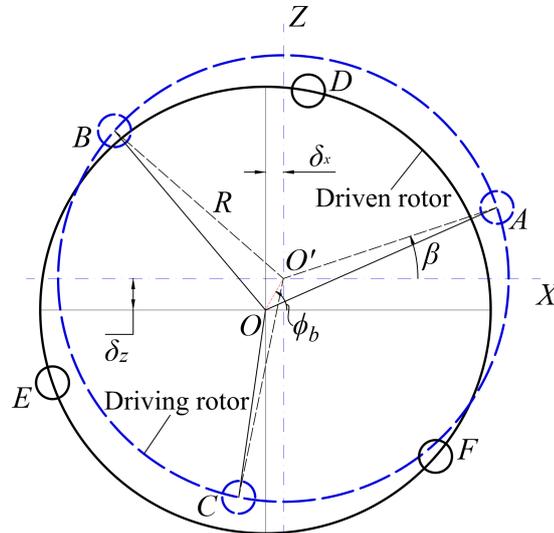


Figura 6.2: Desalinhamento paralelo (XIA et al., 2019).

Os pontos O' e O referem-se aos centros dos rotores de acionamento e acionado, respectivamente, com o raio do eixo denotado por R . Os desvios decorrentes do desalinhamento paralelo entre o rotor de acionamento e o rotor acionado ao longo das direções X e Z são representados por δ_x e δ_z . O ângulo de interseção entre o eixo Z e a linha OO' é definido como ϕ_b ($\tan \phi_b = \delta_z/\delta_x$). Adicionalmente, o ângulo β corresponde à posição angular do rotor em relação a uma marca de referência.

A Figura 6.3 apresenta um modelo dinâmico de dois rotores conectados por acoplamento flexível na presença de desalinhamento. Nota-se k_3 e c_3 que são, respectivamente, a rigidez e o amortecimento torsional no acoplamento.

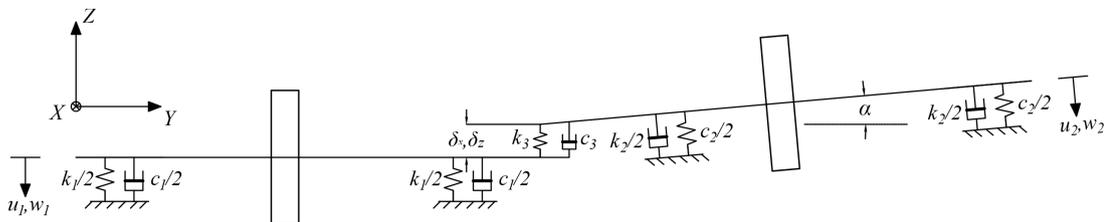


Figura 6.3: Modelo dinâmico para dois rotores desalinhados conectados por acoplamento flexível (XIA et al., 2019).

A rigidez radial do acoplamento flexível é inserida no modelo pela constante k_d , as forças de excitação causadas pelo desalinhamento paralelo nas direções X e Z são obtidas e expressas

segundo a Eq. (6.2).

$$\begin{aligned} F_{PX} &= k_d \mu_x, \\ F_{PZ} &= k_d \mu_z. \end{aligned} \quad (6.2)$$

onde,

$$\begin{aligned} \mu_x &= \mu_1 + \mu_2 \sin(\beta + 120^\circ) + \mu_3 \sin(\beta + 240^\circ), \\ \mu_z &= \mu_1 \cos(\beta) + \mu_2 \cos(\beta + 120^\circ) + \mu_3 \cos(\beta + 240^\circ). \end{aligned} \quad (6.3)$$

Sabendo que $\mu_1 = OA - O'A$, $\mu_2 = OB - O'B$ e $\mu_3 = O'C - OC$, obtém-se:

$$\begin{aligned} \mu_x &= \left(\sqrt{R^2 + \delta_x^2 + \delta_z^2 + 2R\sqrt{\delta_x^2 + \delta_z^2} \sin(\beta + \phi_b)} - R \right) \sin(\beta) + \dots \\ &\dots \left(\sqrt{R^2 + \delta_x^2 + \delta_z^2 + 2R\sqrt{\delta_x^2 + \delta_z^2} \cos\left(\frac{\pi}{6} + \beta + \phi_b\right)} - R \right) \sin\left(\beta + \frac{2\pi}{3}\right) + \dots \\ &\dots \left(R - \sqrt{R^2 + \delta_x^2 + \delta_z^2 - 2R\sqrt{\delta_x^2 + \delta_z^2} \sin\left(\frac{\pi}{3} + \beta + \phi_b\right)} \right) \sin\left(\beta + \frac{4\pi}{3}\right) \end{aligned} \quad (6.4)$$

$$\begin{aligned} \mu_z &= \left(\sqrt{R^2 + \delta_x^2 + \delta_z^2 + 2R\sqrt{\delta_x^2 + \delta_z^2} \sin(\beta + \phi_b)} - R \right) \cos(\beta) + \dots \\ &\dots \left(\sqrt{R^2 + \delta_x^2 + \delta_z^2 + 2R\sqrt{\delta_x^2 + \delta_z^2} \cos\left(\frac{\pi}{6} + \beta + \phi_b\right)} - R \right) \cos\left(\beta + \frac{2\pi}{3}\right) + \dots \\ &\dots \left(R - \sqrt{R^2 + \delta_x^2 + \delta_z^2 - 2R\sqrt{\delta_x^2 + \delta_z^2} \sin\left(\frac{\pi}{3} + \beta + \phi_b\right)} \right) \cos\left(\beta + \frac{4\pi}{3}\right) \end{aligned} \quad (6.5)$$

6.2.1.2 Forças de Reação do Desalinhamento Angular

A Figura 6.3 ilustra a posição rotativa do acoplamento flexível, utilizando o ângulo α para representar o desvio angular da linha de centro de um eixo em relação ao outro. Se assumirmos que a rigidez à flexão do acoplamento é k_s , as forças de reação decorrentes dos desalinhamentos

angulares em cada ponto A , B e C podem ser expressas por:

$$\begin{aligned} F_A &= k_s AA' , \\ F_B &= k_s BB' , \\ F_C &= k_s CC' , \end{aligned} \tag{6.6}$$

onde,

$$\begin{aligned} AA' &= R \sin(\varphi) \sqrt{2 - 2 \cos(\alpha)} , \\ BB' &= R \sin\left(\varphi + \frac{2\pi}{3}\right) \sqrt{2 - 2 \cos(\alpha)} , \\ CC' &= R \sin\left(\varphi + \frac{4\pi}{3}\right) \sqrt{2 - 2 \cos(\alpha)} . \end{aligned} \tag{6.7}$$

De acordo com as Eqs. (6.6) e (6.7), a força axial é estimada pela equação:

$$F_Y = C \sin(\beta) \cos(\alpha) + C \sin\left(\beta + \frac{2\pi}{3}\right) \cos(\alpha) + C \sin\left(\beta + \frac{4\pi}{3}\right) \cos(\alpha) = 0, \tag{6.8}$$

onde,

$$C = k_s R \sqrt{2 - 2 \cos(\alpha)}. \tag{6.9}$$

As forças de excitação causadas pelo desalinhamento angular nas direções X e Z podem ser expressas pelas Eqs. (6.10) e (6.11), respectivamente.

$$\begin{aligned} F_{AX} &= |C \sin(\beta) \sin(\alpha)| \cos(\beta + \pi) + \left| C \sin\left(\beta + \frac{2\pi}{3}\right) \sin(\alpha) \right| \cos\left(\beta + \pi + \frac{2\pi}{3}\right) + \dots \\ &\quad \dots \left| C \sin\left(\beta + \frac{4\pi}{3}\right) \sin(\alpha) \right| \cos\left(\beta + \pi + \frac{4\pi}{3}\right). \end{aligned} \tag{6.10}$$

$$\begin{aligned} F_{AZ} &= |C \sin(\beta) \sin(\alpha)| \sin(\beta + \pi) + \left| C \sin\left(\beta + \frac{2\pi}{3}\right) \sin(\alpha) \right| \sin\left(\beta + \pi + \frac{2\pi}{3}\right) + \dots \\ &\quad \dots \left| C \sin\left(\beta + \frac{4\pi}{3}\right) \sin(\alpha) \right| \sin\left(\beta + \pi + \frac{4\pi}{3}\right). \end{aligned} \tag{6.11}$$

Desta forma, o vetor de forças para o desalinhamento combinado, aplicado aos nós I e F (1 e 2) é dado por:

$$F = \begin{Bmatrix} F_{PX} + F_{AX} \\ F_{PZ} + F_{AZ} \\ TD \\ -F_{PX} - F_{AX} \\ -F_{PZ} - F_{AZ} \\ TL \end{Bmatrix}, \quad (6.12)$$

onde os termos TD e TL são os torques aplicados antes e depois do acoplamento.

6.3 Eixos com Trincas Transversais

Muszynska (2005) destaca a importância fundamental da detecção precoce de trincas em máquinas industriais para evitar falhas catastróficas e paralisações dos ativos. Nesse contexto, a previsão do comportamento das trincas torna-se particularmente eficaz quando embasada em modelos precisos que representam de maneira fiel o desenvolvimento dessas falhas. A utilização de modelos apropriados não apenas possibilita antecipar o surgimento de trincas, mas também proporciona uma compreensão mais aprofundada de sua evolução.

Segundo Bachschmid, Pennacchi e Tanzi (2010), a linha de deflexão de um eixo que contém uma trinca em sua posição central pode ser expressa como a superposição de duas partes distintas. A primeira parte corresponde à linha de deflexão de um eixo saudável, enquanto a segunda parte refere-se à deflexão adicional resultante da flexibilidade local introduzida pela presença da trinca. É importante observar que a teoria de vigas não é capaz de determinar essa deflexão adicional, uma vez que considera a trinca como um enfraquecimento instantâneo da rigidez à flexão (EI) em um comprimento nulo.

Vale ressaltar que um eixo cilíndrico com trinca, devido à sua falta de simetria e isotropia, pode induzir acoplamento entre as vibrações lateral, axial e torsional. Entretanto, para simplificar e facilitar a compreensão dos conceitos básicos da modelagem, esses efeitos podem ser inicialmente desconsiderados (SILVA, 2023). Dependendo do tipo de trinca presente, diferentes mecanismos podem ser incorporados ao modelo de elementos finitos do rotor, revelando assim diferentes efeitos na resposta estrutural.

A classificação proposta por Sabnavis et al. (2004) oferece uma visão abrangente dos diferentes tipos de trincas, considerando tanto suas características geométricas quanto os efeitos que podem ter sobre o comportamento estrutural dos eixos. Abaixo estão os principais tipos de trincas mencionados:

- Trincas transversais: são perpendiculares ao eixo, de maior incidência e graves. Reduzem a seção transversal e enfraquecem o rotor, introduzindo flexibilidade adicional devido à concentração de energia de deformação próxima à sua extremidade;
- Trincas longitudinais: são paralelas à direção longitudinal do eixo;
- Trincas oblíquas: possuem inclinação em relação ao eixo longitudinal do rotor. Influenciam no comportamento de torção de maneira semelhante ao efeito das trincas transversais no comportamento lateral do eixo;
- Trincas *breathing*: se abrem sob tensões de tração e se fecham sob tensões de compressão. Induzem não linearidades no comportamento vibratório do rotor;
- Trincas abertas ou *open*: permanecem sempre abertas e são mais fáceis de reproduzir em laboratório;
- Trincas de superfície: são localizadas na superfície do eixo. Podem ser detectadas por técnicas como líquido penetrante ou inspeção visual;
- Trincas de subsuperfície: não aparecem na superfície e exigem técnicas avançadas, como ultrassom, raio X ou partículas magnéticas, para detecção.

Para simular o comportamento da trinca, uma flexibilidade adicional do eixo é considerada no elemento finito que contém o dano. Os princípios e o desenvolvimento teórico para a matriz de flexibilidade adicional devido à trinca foram inicialmente estabelecidos por Dimarogonas, Paipetis e Chondros (1983) para vigas retangulares. Posteriormente, essa abordagem foi estendida para eixos circulares por Papadopoulos e Dimarogonas (1987).

Os termos de flexibilidade adicional, calculados com base na teoria da Mecânica da Fratura Linear Elástica, bem como os modelos representativos de trincas serão detalhados na subseção seguinte.

6.3.1 Flexibilidade Adicional Introduzida pela Trinca

Para cálculo dos coeficientes adicionais de flexibilidade devido à trinca, considere um elemento de eixo com seis graus de liberdade por nó. Este elemento tem comprimento L e diâmetro D , e apresenta uma trinca transversal de profundidade α . O sistema está sujeito a uma variedade de carregamentos, incluindo forças axiais P_1 e P_7 , forças cisalhantes P_2, P_3, P_8 , e P_9 , momentos de torção P_4 e P_{10} , e momentos fletores P_5, P_6, P_{11} e P_{12} , conforme ilustrado na Figura 6.4.

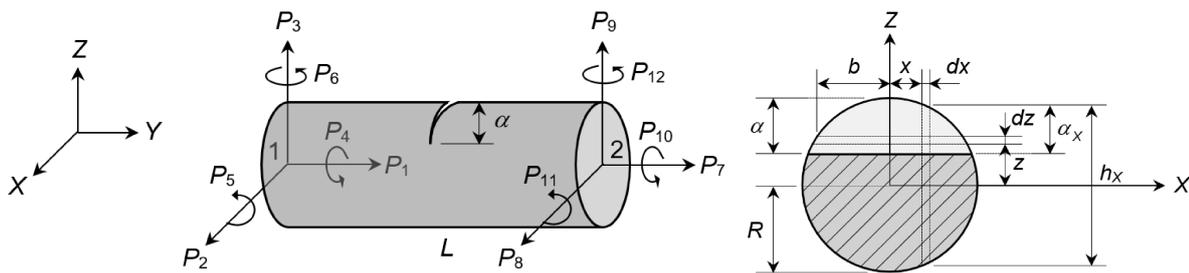


Figura 6.4: Elemento de eixo e parâmetros geométricos (CAVALLINI Jr., 2013).

Segundo Darpe, Gupta e Chawla (2004), o deslocamento ao longo da i -ésima coordenada pode ser determinado pelo segundo teorema de Castigliano conforme mostra a Eq. (6.13).

$$q_i = \frac{dU}{dP_i}, \quad (6.13)$$

onde U é a energia de deformação total dada pela Eq. (6.13).

$$U = U^0 + U^c. \quad (6.14)$$

Dado que U^0 seja a energia de deformação do elemento de eixo sem trinca e U^c a energia de deformação adicional devido à presença da trinca, a Eq. (6.14) pode ser reescrita segundo a Eq. (6.15).

$$q_i = \frac{\partial U^0}{\partial P_i} + \frac{\partial U^c}{\partial P_i}. \quad (6.15)$$

Ao considerar as forças atuantes no elemento de eixo, a energia de deformação adicional devido à trinca, representada como U^c , é expressa de acordo com os princípios da mecânica da

fratura pela Eq. (6.16).

$$U^c = \int_{A_c} J(A_c) dA_c, \quad (6.16)$$

onde $J(A_c)$ representa a função densidade de energia de deformação sobre a área do elemento correspondente à seção que contém a trinca (área não hachurada da Fig. 6.4). Essa função é expressa de acordo com a Eq. (6.17).

$$U^c = \int_{A_c} \frac{1-\nu}{E} \left[\left(\sum_{i=1}^6 K_{Ii} \right)^2 + \left(\sum_{i=1}^6 K_{IIi} \right)^2 + (1+\nu) \left(\sum_{i=1}^6 K_{IIIi} \right)^2 \right] dA_c, \quad (6.17)$$

onde K_{Ii} , K_{IIi} e K_{IIIi} são os fatores de intensificação de tensão (do inglês *Stress Intensity Factor* - SIF) para o modo *I* de tração, modo *II* de cisalhamento e modo *III* de torção, respectivamente, segundo ilustra a Fig. 6.5.

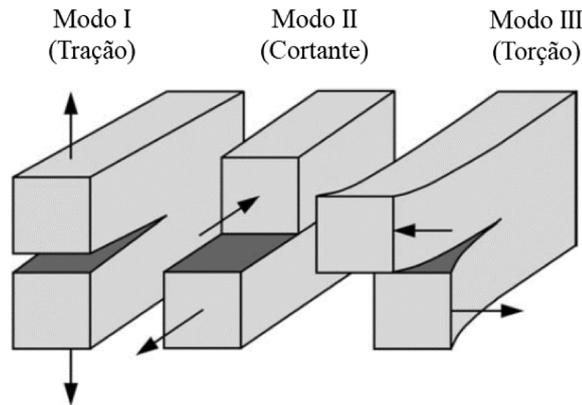


Figura 6.5: Modos de carregamentos aplicados à uma trinca (ANDERSON, 2017).

De acordo Anderson (2017) os SIFs dependem da geometria do eixo e do modo de carregamento, podendo ser escritos conforme a Eq. (6.18).

$$K_{mi} = \sigma_i \sqrt{\pi \alpha_x} F_j \left(\frac{\alpha_x}{h_x} \right), \quad (6.18)$$

em que as tensões na trinca, σ_i , são representadas pelas resultantes dos esforços aplicados pelas forças P_i ($i = 1, 2, \dots, 6$) e F_j ($j = 1, 2, II e III$) são as funções de forma que dependem da profundidade da trinca, α_x , e do diâmetro de um elemento infinitesimal de eixo, vide Fig. 6.4.

A flexibilidade adicional decorrente da presença da trinca pode ser determinada pela Eq.

(6.19).

$$c_{ij} = \frac{\partial^2 U^c}{\partial P_i \partial P_j} = \frac{\partial^2}{\partial P_i \partial P_j} \left[\int_{A_c} J(A_c) dA_c \right]. \quad (6.19)$$

O procedimento para calcular os SIFs é apresentado pela Eq. (6.20), conforme detalhado por Papadopoulos e Dimarogonas (1987).

$$\begin{aligned} K_{I1} &= \sigma_1 \sqrt{\pi \alpha_x} F_1 \left(\alpha_x / h_x \right), \quad \sigma_1 = P_1 / \pi R^2, \\ K_{I5} &= \sigma_5 \sqrt{\pi \alpha_x} F_2 \left(\alpha_x / h_x \right), \quad \sigma_5 = \left(4P_5 / \pi R^4 \right) \sqrt{(R^2 - x^2)}, \\ K_{I6} &= \sigma_6 \sqrt{\pi \alpha_x} F_1 \left(\alpha_x / h_x \right), \quad \sigma_4 = \left(4P_6 / \pi R^4 \right) x, \\ K_{I2} &= K_{I3} = K_{I4} = 0, \\ K_{II3} &= \sigma_{II3} \sqrt{\pi \alpha_x} F_{II} \left(\alpha_x / h_x \right), \quad \sigma_{II3} = k P_3 / \pi R^2, \\ K_{II4} &= \sigma_{II4} \sqrt{\pi \alpha_x} F_{II} \left(\alpha_x / h_x \right), \quad \sigma_{II4} = \left(2P_4 / \pi R^4 \right) x, \\ K_{II1} &= K_{II2} = K_{II5} = K_{II6} = 0, \\ K_{III2} &= \sigma_{III2} \sqrt{\pi \alpha_x} F_{III} \left(\alpha_x / h_x \right), \quad \sigma_{III2} = k P_2 / \pi R^2 \quad k = \frac{6(1+\nu)}{7+6\nu}, \\ K_{III4} &= \sigma_{III4} \sqrt{\pi \alpha_x} F_{III} \left(\alpha_x / h_x \right), \quad \sigma_{III4} = \left(2P_4 / \pi R^4 \right) \sqrt{(R^2 - x^2)}, \\ K_{III1} &= K_{III3} = K_{III5} = K_{III6} = 0. \end{aligned} \quad (6.20)$$

Os fatores de forma F_1 , F_2 , F_{II} e F_{III} são definidos pela Eq. (6.21).

$$\begin{aligned} F_1 \left(\frac{\alpha_x}{h_x} \right) &= \sqrt{\left(\frac{\tan(\lambda)}{\lambda} \right)} \left[\frac{0.752 + 2.02(\alpha_x/h_x) + 0.37(1 - \sin(\lambda))^3}{\cos(\lambda)} \right], \\ F_2 \left(\frac{\alpha_x}{h_x} \right) &= \sqrt{\left(\frac{\tan(\lambda)}{\lambda} \right)} \left[\frac{0.923 + 0.199(1 - \sin(\lambda))^4}{\cos(\lambda)} \right], \\ F_{II} \left(\frac{\alpha_x}{h_x} \right) &= \frac{1.122 - 0.561(\alpha_x/h_x) + 0.085(\alpha_x/h_x)^2 + 0.18(\alpha_x/h_x)^3}{\sqrt{[1 - (\alpha_x/h_x)]}}, \\ F_{III} \left(\frac{\alpha_x}{h_x} \right) &= \left(\sqrt{\left(\frac{\tan(\lambda)}{\lambda} \right)} \right), \quad \lambda = \frac{\pi \alpha_x}{2h_x}. \end{aligned} \quad (6.21)$$

Ao substituir as Eqs. (6.20) e (6.21) nas Eqs. (6.17) e (6.18) são obtidos os termos de

flexibilidade adimensionais apresentados pela Eq. (6.22).

$$\begin{aligned}
\bar{c}_{11} &= \frac{ER}{1-\nu^2} c_{11} = \frac{2}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x} F_1^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{15} &= \frac{ER^2}{1-\nu^2} c_{15} = \frac{8}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{z} \sqrt{(1-\bar{x}^2)} F_1(\bar{z}/\bar{h}_x) F_2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{16} &= \frac{ER^2}{1-\nu^2} c_{16} = \frac{4}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x} \bar{z} F_1^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{22} &= \frac{ER}{1-\nu^2} c_{22} = \frac{2}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{z} F_{III}^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{24} &= \frac{ER^2}{1-\nu^2} c_{24} = \frac{4}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \sqrt{(1-\bar{x}^2)} \bar{z} F_{III}^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{33} &= \frac{ER}{1-\nu^2} c_{33} = \frac{2}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{z} F_{II}^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{34} &= \frac{ER^2}{1-\nu^2} c_{34} = \frac{4}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x} \bar{z} F_{II}^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{44} &= \frac{ER^3}{1-\nu^2} c_{34} = \frac{8}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x}^2 \bar{z} F_{II}^2(\bar{z}/\bar{h}_x) + (1+\nu)(1-\bar{x}^2) \bar{z} F_{III}^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{55} &= \frac{ER^3}{1-\nu^2} c_{55} = \frac{32}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{z} (1-\bar{x}^2) F_2^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{56} &= \frac{ER^3}{1-\nu^2} c_{56} = \frac{32}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x} \bar{z} \sqrt{(1-\bar{x}^2)} F_1(\bar{z}/\bar{h}_x) F_2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z}, \\
\bar{c}_{66} &= \frac{ER^3}{1-\nu^2} c_{66} = \frac{16}{\pi} \int_0^{\bar{\alpha}_x} \int_{-\bar{b}}^{\bar{b}} \bar{x}^2 \bar{z} F_1^2(\bar{z}/\bar{h}_x) d\bar{x} d\bar{z},
\end{aligned} \tag{6.22}$$

onde,

$$\begin{aligned}
\bar{x} &= x/R, \\
\bar{z} &= z/R, \\
\bar{h}_x &= h_x/R, \\
\bar{b} &= b/R, \\
\bar{\alpha}_x &= \alpha_x/R.
\end{aligned} \tag{6.23}$$

Os intervalos de integração da Eq. (6.22) podem ser determinados usando a Eq. (6.24).

$$\begin{aligned}
b &= \sqrt{[R^2 - (R - \alpha)^2]}, \\
\bar{b} &= \sqrt{[1 - (1 - \bar{\alpha})^2]}, \\
\alpha_x &= \frac{h_x}{2} - (R - \alpha) = \sqrt{(R^2 - x^2)} - (R - \alpha), \\
\bar{\alpha}_x &= \frac{\bar{h}_x}{2\bar{R}} - (1 - \frac{\alpha}{R}) = \sqrt{(1 - \bar{x}^2)} - (1 - \bar{\alpha}) \\
h_x &= 2\sqrt{(R^2 - x^2)}, \\
\bar{h}_x &= 2\sqrt{(1 - \bar{x}^2)}.
\end{aligned} \tag{6.24}$$

De acordo com Papadopoulos e Dimarogonas (1987), a matriz de flexibilidade nodal para o elemento finito com trinca, Eq. (6.25), é obtida somando-se a matriz de flexibilidade nodal

adicional \mathbf{c} , apresentada na Eq. (6.26), à matriz de flexibilidade nodal \mathbf{c}_0 do elemento sem trinca.

$$\mathbf{c}_{ce} = [\mathbf{c}_0] + [\mathbf{c}] , \quad (6.25)$$

dado

$$\mathbf{c} = \begin{bmatrix} \bar{c}_{11} & 0 & 0 & 0 & \bar{c}_{15} & \bar{c}_{16} \\ & \bar{c}_{22} & 0 & \bar{c}_{24} & 0 & 0 \\ & & \bar{c}_{33} & \bar{c}_{34} & 0 & 0 \\ & & & \bar{c}_{44} & 0 & 0 \\ & & & & \bar{c}_{55} & \bar{c}_{56} \\ \text{sim.} & & & & & \bar{c}_{66} \end{bmatrix} . \quad (6.26)$$

O elemento finito utilizado neste estudo para modelar o eixo possui dois nós, cada um com quatro *gdl*s, em acordo com Silva (2023). As forças axiais P_1 e P_7 e os momentos P_4 e P_{10} , vide Fig. 6.4, são desconsiderados. O mesmo se aplica aos modos de carregamento *II* e *III*, ilustrados na Fig. 6.5, devido à sua menor expressividade em comparação ao modo de carregamento *I*. Desta forma, a flexibilidade adicional nodal incorporada no elemento do eixo devido à presença da trinca, conforme expresso pela Eq. (6.27), é caracterizada exclusivamente pelos coeficientes c_{55} , c_{56} e c_{66} .

$$\mathbf{c} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ & 0 & 0 & 0 \\ & & \bar{c}_{55} & \bar{c}_{56} \\ \text{sim.} & & & \bar{c}_{66} \end{bmatrix} . \quad (6.27)$$

Para fins de comparação, os coeficientes de flexibilidade adicionais e os resultantes para os *gdl*s são apresentados nas Figs. 6.6 e 6.7, respectivamente.

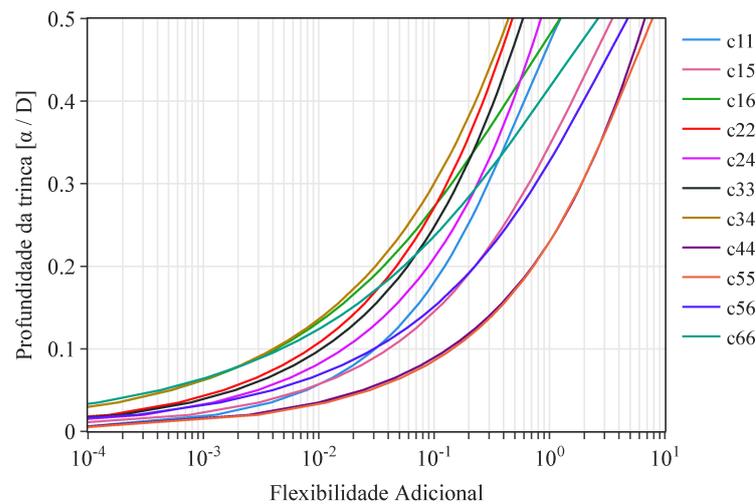


Figura 6.6: Flexibilidades adicionais em um elemento de eixo (SILVA, 2023).

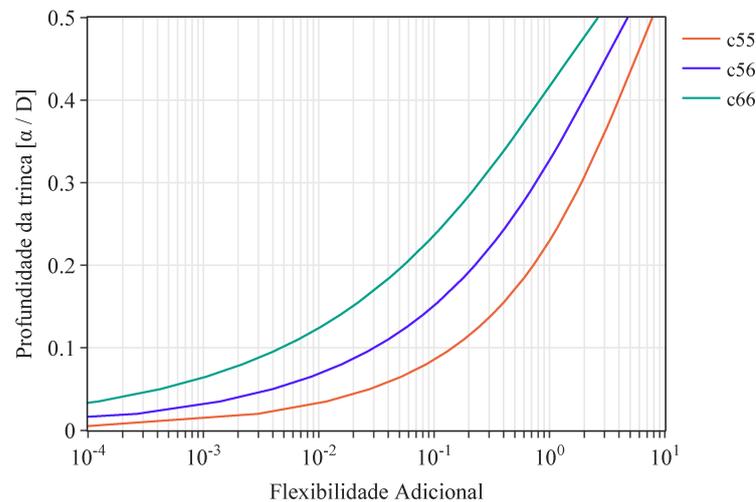


Figura 6.7: Flexibilidades adicionais em um elemento de eixo com 4 graus de liberdade por nó (SILVA, 2023).

6.4 Representação do *Breathing*

O *breathing* ocorre quando as vibrações em um rotor com trinca são predominantemente influenciadas pela deflexão estática do eixo. A maioria dos estudos sobre esse tema parte do pressuposto de que, em situações onde os carregamentos estáticos prevalecem sobre os dinâmicos (caso de eixos horizontalmente pesados com baixo nível de desbalanceamento), a trinca se abre e se fecha gradualmente a cada revolução do sistema. Dessa forma, o *breathing* assume uma condição de *Weight Dominance*.

Conforme destacado por Ferreira (2010), ao contrário do modelo de trinca que permanece constantemente aberta (trinca *open*), o *breathing* é caracterizado por aberturas e fechamentos

sucessivos da trinca, influenciados pelo carregamento cíclico imposto e pelo peso do próprio eixo. Além dos princípios da mecânica da fratura linear, esses modelos empregam funções matemáticas que descrevem essa condição dinâmica.

A literatura oferece diversas abordagens para descrever o *breathing* para trincas transversais. Entre os mais citados, destacam-se o modelo proposto por Mayes e Davies (1984) onde a inclusão da flexibilidade adicional em relação à abertura da trinca ocorre de forma gradual e, ainda, o modelo proposto por Gasch (1993), onde inclusão da flexibilidade ocorre de forma abrupta.

Em linhas gerais, a deflexão em uma determinada posição de um disco, por exemplo, com uma trinca em sua proximidade, pode ser expressa conforme a Eq. (6.28). Nessa equação, c_0 representa a flexibilidade sem trinca, Δc_ξ é a flexibilidade adicional na direção rotativa de Z , e f_ξ , f_η são as forças nas direções rotativas de Z e X , respectivamente. Frequentemente, o termo da flexibilidade adicional na direção X é negligenciado, pois tende a apresentar valores consideravelmente menores, ou seja, sua influência comparada à direção Z (onde atua a força peso) pode ser desprezível, como observado em estudos anteriores (BACHSCHMID; PENNACCHI; TANZI, 2010; GASCH, 1993).

$$\begin{Bmatrix} \xi \\ \eta \end{Bmatrix} = \begin{bmatrix} c_0 + \Delta c_\xi & 0 \\ 0 & c_0 + 0 \end{bmatrix} \begin{Bmatrix} f_\xi \\ f_\eta \end{Bmatrix}. \quad (6.28)$$

Neste contexto, as coordenadas fixas são representadas pelo referencial $O - XYZ$, enquanto as coordenadas rotativas são descritas pelo referencial $O - \xi, \eta, \zeta$, orientado de acordo com a direção da trinca e a posição angular $\theta = \omega t$, conforme ilustra a Fig. 6.8.

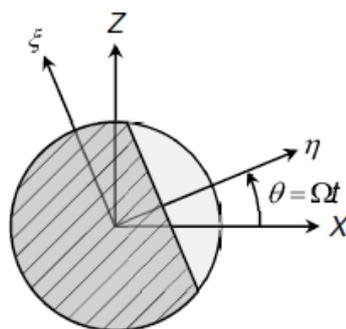


Figura 6.8: Coordenadas rotativas para o modelo de trinca (CAVALLINI Jr., 2013).

O fenômeno *breathing* pressupõe que a trinca está totalmente aberta quando o eixo η coin-

cide com o eixo negativo de Z (região de tensão) e completamente fechada quando η está alinhado com o eixo positivo de Z (região de compressão), conforme ilustrado na Figura 6.9.

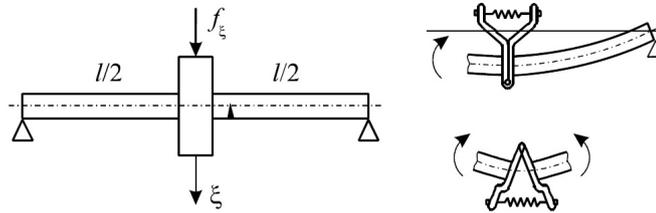


Figura 6.9: Abertura e fechamento da trinca (BACHSCHMID; PENNACCHI; TANZI, 2010).

De acordo com as hipóteses assumidas em Bachschmid, Pennacchi e Tanzi (2010), esse mecanismo é não linear, mais especificamente, bi-linear. Desta forma, a Eq. (6.28) pode ser reescrita como a Eq. (6.29).

$$\begin{Bmatrix} \xi \\ \eta \end{Bmatrix} = \left(\begin{bmatrix} c_0 & 0 \\ 0 & c_0 \end{bmatrix} + f(\Omega t) \begin{bmatrix} \Delta c_\xi & 0 \\ 0 & 0 \end{bmatrix} \right) \begin{Bmatrix} f_\xi \\ f_\eta \end{Bmatrix}, \quad (6.29)$$

onde $f(\Omega t)$ é conhecido como *steering function*, particular em cada modelo de trinca.

Agora faz-se a inversão da matriz de flexibilidade segundo a Eq. (6.30).

$$\begin{bmatrix} c_0 + f(\Omega t) \Delta c_\xi & 0 \\ 0 & 0 \end{bmatrix}^{-1} = \frac{1}{c_0 (c_0 + f(\Omega t) \Delta c_\xi)} \begin{bmatrix} c_0 & 0 \\ 0 & c_0 + f(\Omega t) \Delta c_\xi \end{bmatrix}. \quad (6.30)$$

Uma vez que a rigidez do eixo sem trinca é dada por $k_0 = 1/c_0$, obtém-se a Eq. (6.31).

$$\frac{1}{c_0 + \Delta c_\xi} = k_0 - \Delta k_\xi, \quad (6.31)$$

onde Δk_ξ é a perda de rigidez devido à abertura da trinca que pode ser estimada a partir da Eq. (6.27):

$$\mathbf{c}_{ce} = \underbrace{\begin{bmatrix} \frac{L^3(\frac{a}{4}+1)}{3EI} & 0 & 0 & -\frac{L^2}{2EI} \\ & \frac{L^3(\frac{a}{4}+1)}{3EI} & \frac{L^2}{2EI} & 0 \\ & & \frac{L}{EI} & 0 \\ \text{sim.} & & & \frac{L}{EI} \end{bmatrix}}_{\mathbf{c}_0} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ & 0 & 0 & 0 \\ & & \bar{c}_{55} & \bar{c}_{56} \\ \text{sim.} & & & \bar{c}_{66} \end{bmatrix}, \quad (6.32)$$

$$\begin{aligned}\Delta k_{\xi} &= \underbrace{\mathbf{c}_0^{-1}}_{k_0} - \underbrace{\mathbf{c}_{ce}^{-1}}_{k_{cx}} (1, 1), \\ \Delta k_{\eta} &= \underbrace{\mathbf{c}_0^{-1}}_{k_0} - \underbrace{\mathbf{c}_{ce}^{-1}}_{k_{cz}} (2, 2).\end{aligned}\tag{6.33}$$

Obtendo:

$$\begin{Bmatrix} f_{\xi} \\ f_{\eta} \end{Bmatrix} = \left(\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - f(\Omega t) \begin{bmatrix} \Delta k_{\xi} & 0 \\ 0 & 0 \end{bmatrix} \right) \begin{Bmatrix} \xi \\ \eta \end{Bmatrix},\tag{6.34}$$

ou ainda,

$$\mathbf{F}_{rot} = [\mathbf{K}_{0,rot} - f(\Omega t) \Delta \mathbf{K}_{rot}(\xi_{rot}, t)] \mathbf{q}_{rot},\tag{6.35}$$

onde \mathbf{F}_{rot} e \mathbf{q}_{rot} são os vetores das forças elásticas e os deslocamentos em coordenadas rotativas, respectivamente.

As matrizes em coordenadas fixas são obtidas por meio da multiplicação da matriz de transformação conforme mostra a Eq. (6.36):

$$\begin{Bmatrix} \xi \\ \eta \end{Bmatrix} = \begin{bmatrix} C_1 & S_1 \\ -S_1 & C_1 \end{bmatrix} \begin{Bmatrix} Z \\ X \end{Bmatrix},\tag{6.36}$$

onde $C_1 = \cos(\Omega t)$ e $S_1 = \sin(\Omega t)$.

Pode-se determinar \mathbf{q}_{rot} por meio da Eq. (6.37).

$$\mathbf{q}_{rot} = [\mathbf{T}(\Omega t)] \mathbf{q}_{inercial}.\tag{6.37}$$

De modo similar faz-se:

$$\begin{aligned}\mathbf{F}_{rot} &= [\mathbf{T}(\Omega t)] \mathbf{F}_{inercial} \\ \Rightarrow \mathbf{F}_{inercial} &= [\mathbf{T}(\Omega t)]^T \mathbf{F}_{rot} = [\mathbf{T}(\Omega t)]^T [\mathbf{K}_{0,rot} - f(\Omega t) \Delta \mathbf{K}_{rot}(\xi_{rot}, t)] [\mathbf{T}(\Omega t)] \mathbf{q}_{inercial}.\end{aligned}\tag{6.38}$$

Dada a Eq. (6.38), esta corresponde às Eqs. (6.39).

$$\begin{cases} f_Z \\ f_X \end{cases} = \left[\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - f(\Omega t) \Delta k_\xi \begin{bmatrix} C_1^2 & S_1 C_1 \\ S_1 C_1 & S_1^2 \end{bmatrix} \right] \begin{cases} Z \\ X \end{cases}, \quad (6.39)$$

$$\begin{cases} f_Z \\ f_X \end{cases} = \left[\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - \frac{1}{2} f(\Omega t) \Delta k_\xi \begin{bmatrix} 1 + C_2 & S_2 \\ S_2 & 1 - C_2 \end{bmatrix} \right] \begin{cases} Z \\ X \end{cases},$$

onde $C_2 = \cos(2\Omega t)$ e $S_2 = \sin(2\Omega t)$.

Baseando-se nos estudos de Liong e Proppe (2013) e Liong e Proppe (2012), considera-se os coeficientes de flexibilidade/rigidez na direção X (η) por meio das Eqs. (6.40) e (6.41).

$$\begin{cases} f_\xi \\ f_\eta \end{cases} = \left[\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - f(\Omega t) \begin{bmatrix} \Delta k_\xi & 0 \\ 0 & \Delta k_\eta \end{bmatrix} \right] \begin{cases} \xi \\ \eta \end{cases}, \quad (6.40)$$

$$\begin{cases} f_Z \\ f_X \end{cases} = \left[\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - f(\Omega t) \begin{bmatrix} \Delta k_\xi C_1^2 + \Delta k_\eta S_1^2 & \Delta k_2 S_1 C_1 \\ \Delta k_2 S_1 C_1 & \Delta k_\xi S_1^2 + \Delta k_\eta C_1^2 \end{bmatrix} \right] \begin{cases} Z \\ X \end{cases}, \quad (6.41)$$

$$\begin{cases} f_Z \\ f_X \end{cases} = \left[\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} - \frac{1}{2} f(\Omega t) \begin{bmatrix} \Delta k_1 + \Delta k_2 C_2 & \Delta k_2 S_2 \\ \Delta k_2 S_2 & \Delta k_1 + \Delta k_2 C_2 \end{bmatrix} \right] \begin{cases} Z \\ X \end{cases},$$

onde:

$$\begin{aligned} \Delta k_1 &= \Delta k_\xi + \Delta k_\eta, \\ \Delta k_2 &= \Delta k_\xi - \Delta k_\eta. \end{aligned} \quad (6.42)$$

A modelagem do comportamento *breathing* pode ser implementada por meio do cálculo da variação de rigidez para um eixo com trinca que, por sua vez, é expressa por uma série de cossenos truncada. A matriz de rigidez, dependente do tempo, pode ser representada conforme indicado na Eq. (6.43).

$$[\mathbf{K}] = [\mathbf{K}(\Omega, t)] = [\mathbf{K}_0] - [\Delta \mathbf{K}(\Omega, t)]. \quad (6.43)$$

6.5 Equações do Movimento e Linearização para um Eixo Horizontal com Trinca Transversal

A partir deste momento serão apresentados as equações do movimento e linearização para um eixo horizontal com trinca transversal. Para tal, assume-se um rotor na presença de trinca (conforme a Fig. 6.10), cujo comportamento é representado pela Eq. (6.43), com velocidade de rotação constante Ω , incluindo massa de desbalanceamento em um disco, coeficiente de amortecimento c e matriz de rigidez derivada da Eq. (6.43).

$$\begin{bmatrix} m & 0 \\ 0 & m \end{bmatrix} \begin{Bmatrix} \ddot{z} \\ \ddot{x} \end{Bmatrix} + \begin{bmatrix} c & 0 \\ 0 & c \end{bmatrix} \begin{Bmatrix} \dot{z} \\ \dot{x} \end{Bmatrix} + \begin{Bmatrix} fz \\ fx \end{Bmatrix} = me\Omega^2 \begin{Bmatrix} C_\delta \\ S_\delta \end{Bmatrix} + \begin{Bmatrix} mg \\ 0 \end{Bmatrix}, \quad (6.44)$$

$$[\mathbf{M}] \{\ddot{\mathbf{q}}\} + [\mathbf{C}] \{\dot{\mathbf{q}}\} + [\mathbf{K}(\Omega, t)] \{\mathbf{q}\} = \mathbf{F}_u + \mathbf{W},$$

onde $C_\delta = \cos(\Omega t + \delta)$, $S_\delta = \sin(\Omega t + \delta)$, $[\mathbf{M}]$ e $[\mathbf{C}]$ representam a matriz de massa e amortecimento (incluindo efeito giroscópico) respectivamente. $[\mathbf{F}_u]$ é o vetor das forças de desbalanceamento e \mathbf{W} é o vetor de força peso.

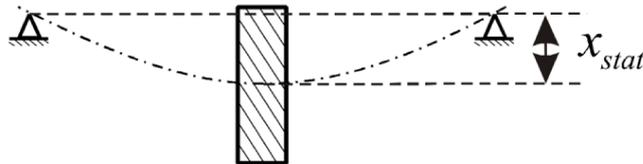


Figura 6.10: Deflexão estática para rotores pesados (BACHSCHMID; PENNACCHI; TANZI, 2010).

No processo de linearização das equações do movimento, o vetor de força peso é importante, uma vez que para um rotor horizontal pesado, sem trinca, a deflexão estática \mathbf{x}_0 é substancialmente maior em comparação com as deflexões adicionais causadas pelo comportamento dinâmico do eixo rotativo (conforme mostrado na Fig. 6.10). Para exemplo, em um rotor de uma grande turbina, a deflexão estática deve ser da ordem de 1 mm, enquanto a amplitude de vibração observada durante a operação é da ordem de 250 μm (SAWICKI et al., 2011).

A partir da soma das deflexões estática e dinâmica, obtém-se a deflexão total, conforme a

Eq. (6.45).

$$\mathbf{x}(t) = \mathbf{x}_0 + \Delta\mathbf{x}(t) = \begin{Bmatrix} mg/k_0 \\ 0 \end{Bmatrix} + \Delta\mathbf{x}(t) . \quad (6.45)$$

Fazendo o deslocamento $\Delta\mathbf{x}(t) = \Delta\mathbf{q}(t)$, a Eq. (6.44) pode ser escrita como:

$$[\mathbf{M}] \Delta\ddot{\mathbf{q}} + [\mathbf{C}] \Delta\dot{\mathbf{q}} + ([\mathbf{K}_0] - [\Delta\mathbf{K}(\Omega t)]) (\mathbf{q}_0 + \Delta\mathbf{q}) = \mathbf{F}_u + \mathbf{W} \quad (6.46)$$

Assumindo o equilíbrio estático, chega-se à Eq. (6.47).

$$\begin{bmatrix} k_0 & 0 \\ 0 & k_0 \end{bmatrix} \begin{Bmatrix} q_{stat} \\ 0 \end{Bmatrix} = \begin{Bmatrix} mg \\ 0 \end{Bmatrix} , \quad (6.47)$$

$$[\mathbf{K}_0] \mathbf{q}_0 = \mathbf{W} .$$

Substituindo a Eq. (6.47) na (6.46), tem-se que:

$$[\mathbf{M}] \Delta\ddot{\mathbf{q}} + [\mathbf{C}] \Delta\dot{\mathbf{q}} + ([\mathbf{K}_0] - [\Delta\mathbf{K}(\Omega t)]) \Delta\mathbf{q} = \mathbf{F}_u + [\Delta\mathbf{K}(\Omega t)] \mathbf{q}_0 . \quad (6.48)$$

A matriz de rigidez dependente do tempo, $[\Delta\mathbf{K}(t)]$, está presente em ambos os lados da Eq. 6.48. No esquerdo, determina-se (junto com o amortecimento) a estabilidade do sistema, enquanto que no direito essa matriz é multiplicada pela deflexão estática \mathbf{q}_0 resultando em uma força de excitação adicional dependente do tempo que é uma excitação equivalente à trinca.

Na Equação (6.49) são considerados apenas as deflexões dinâmicas. Assume-se que $\mathbf{q}_0 \gg \Delta\mathbf{q}$ uma vez que o rotor com trinca esteja em *weight dominance*, ou seja, os carregamentos estáticos prevalecem sobre os dinâmicos (eixos horizontais relativamente pesados com pequeno nível de desbalanceamento) fazendo com que a trinca abra e feche gradualmente a cada revolução. Ainda, considera-se o fato de que em um rotor de turbina de grande porte, a deflexão estática pode ser da ordem de 1 mm, enquanto na velocidade de operação, a amplitude de vibração é tipicamente de 50 μm e mesmo em uma velocidade crítica, o valor admissível da amplitude de vibração será de apenas 250 μm (SAWICKI et al., 2011).

$$[\mathbf{M}] \Delta\ddot{\mathbf{q}} + [\mathbf{C}] \Delta\dot{\mathbf{q}} + [\mathbf{K}_0] \Delta\mathbf{q} = \mathbf{F}_u - [\Delta\mathbf{K}(t)] \Delta\mathbf{q} . \quad (6.49)$$

A subseção seguinte apresenta as variações para a *Breathing steering functions* - $f(\Omega t)$ para o modelo de Mayes e Davies (1984). A implementação de outros modelos importantes além do modelo de Mayes, tais como o Gasch, *Open* e *Flex*, bem como fluxogramas para solução no domínio do tempo, são detalhadamente estudados nos trabalhos de Cavallini Jr. (2013) e Silva (2023).

O modelo de Mayes é considerado viável para ser utilizado nesta Tese de Doutorado. Este modelo apresenta custo computacional barato (fundamental para a aplicação requerida neste trabalho) e comportamento coerente com modelos mais realistas (CAVALLINI Jr., 2013), apresentando todas as características fundamentais para representatividade de trincas transversais.

Por outro lado, o modelo de Gasch é ideal para situações em que a profundidade da trinca transversal em relação ao diâmetro do elemento de eixo seja de no máximo 0,25 (CAVALLINI Jr., 2013). O modelo *Flex* evidencia uma característica mais cautelosa quanto à influência da trinca no comportamento dinâmico do rotor e possui custo computacional elevado (NASCI-MENTO, 2022).

6.5.1 *Breathing Steering Functions* para o Modelo de Mayes

Apesar de que o modelo proposto por Mayes e Davies (1984) também seja não linear, a transição entre a abertura e o fechamento da trinca ocorre de forma mais suave. A $f(\Omega t)$ é considerada sendo uma função cosseno, conforme mostra a Eq. (6.50).

$$f(\Omega t) = \frac{1}{2}(1 + C_1) . \quad (6.50)$$

De modo análogo ao desenvolvido para o modelo anterior, as matrizes dos termos contendo as rigidezes k_ξ e k_η são determinadas de acordo com a Eq. (6.51).

$$\begin{aligned} k_\xi &= \frac{k_0 + k_\xi}{2} + \frac{k_0 - k_\xi}{2} C_1 , \\ k_\eta &= \frac{k_0 + k_\eta}{2} + \frac{k_0 - k_\eta}{2} C_1 . \end{aligned} \quad (6.51)$$

Observa-se nas Figs. 6.11 e 6.12 a ocorrência de um comportamento suave de transição. Ainda, a trinca encontra-se completamente aberta em $\Omega t = 180^\circ$ e fechada em $\Omega t = 0$ ou 360° .

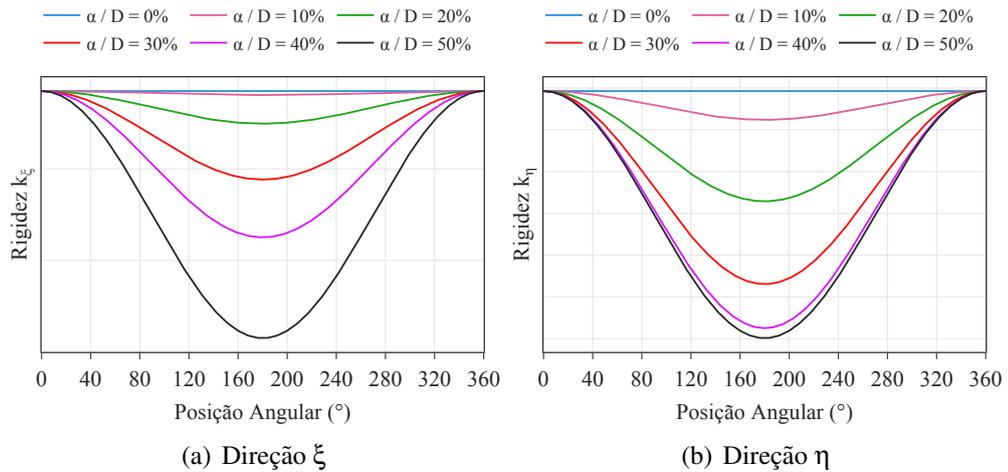


Figura 6.11: Rigidezes em coordenadas rotativas segundo o modelo de Mayes (SILVA, 2023).

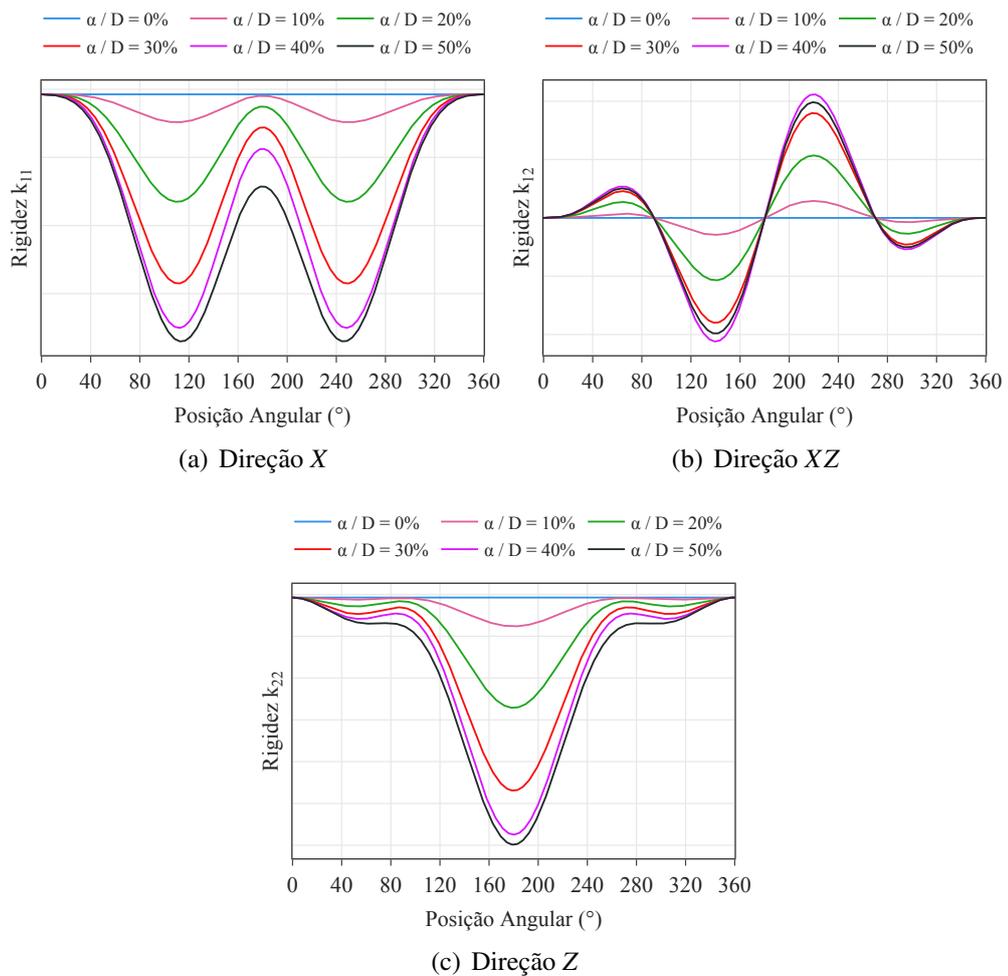


Figura 6.12: Rigidezes em coordenadas fixas segundo o modelo de Mayes (SILVA, 2023).

6.6 Análise Dinâmica de Rotores com Mancais Hidrodinâmicos com Falhas

A análise dos sinais no domínio do tempo e da frequência, obtidos a partir de ensaios experimentais na bancada de teste e dos modelos matemáticos, desempenha um papel fundamental. Essa análise proporciona uma compreensão mais aprofundada do comportamento dinâmico de sistemas rotativos em diferentes condições, como operação normal, desbalanceamento, desalinhamento ou presença de trincas. Além disso, destaca a sensibilidade do modelo matemático proposto, o que é essencial para uma compreensão e diagnóstico precisos das condições de operação da máquina.

Nos ensaios com o sistema rotativo da bancada de teste e nas simulações numéricas, a velocidade de rotação foi mantida em aproximadamente 20,5 Hz. As respostas experimentais foram medidas com um tempo total de aquisição de 1 s, devido às restrições de armazenamento do analisador utilizado, o Agilent® 35670A, enquanto no modelo numérico foi utilizado um tempo de aquisição de 10 s, ambos em passos de 0,0005 s e em regime permanente.

O desbalanceamento na bancada é dado pela adição de massas em diferentes posições angulares disponíveis ao longo dos discos. A Figura 6.13 apresenta uma comparação das respostas experimentais no domínio do tempo e de sua respectiva Transformada Discreta de Fourier (DFT) em S_1 na direção X do rotor em condição normal de operação e desbalanceado. Neste caso, uma massa de 1,5 g foi adicionada aos discos D_4 e D_6 em -60° .

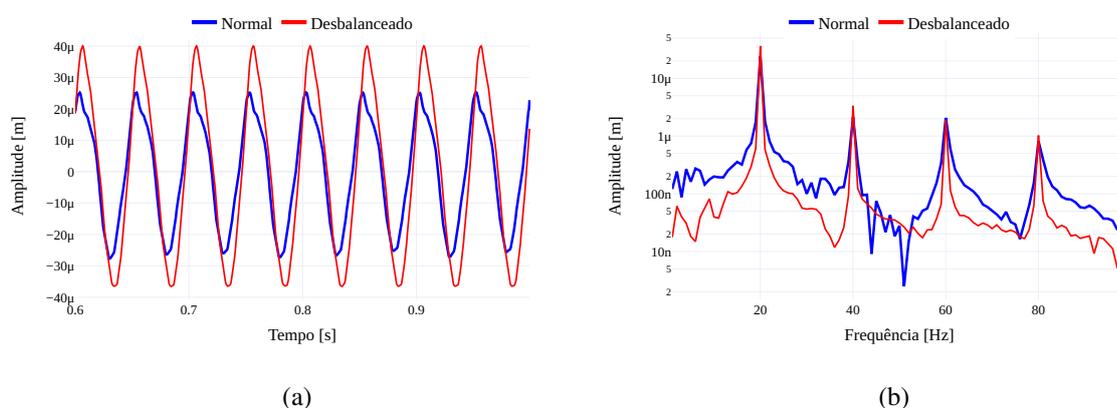


Figura 6.13: Resposta temporal e DFT experimentais em S_1 na direção X em condição normal de operação e com desbalanceamento.

O efeito do desbalanceamento é claramente evidenciado na comparação da curva obtida em condições normais de operação com aquela desbalanceada. Como era de se esperar, houve

um aumento significativo nas amplitudes de vibração do sinal temporal quando o sistema está sujeito ao desbalanceamento. Ainda, conforme visualização da DFT, é evidente a presença de múltiplos da frequência de rotação em todo o intervalo do espectro considerado.

O desalinhamento é dado por meio da fixação de chapinhas de aço com espessura variável sob os pés dianteiros ou traseiros, além da modificação dos reguladores para alinhamento axial do sistema rotativo. A Fig. 6.14 apresenta uma comparação das respostas experimentais no domínio do tempo e de sua respectiva DFT em S_1 na direção X do rotor em condição normal de operação e desalinhado. Neste caso, uma chapinha com espessura aproximada de 0,5 mm foi colocada sob os pés dianteiros da bancada somado a um desvio axial de aproximadamente 0,5 mm, caracterizando um desalinhamento angular e paralelo.

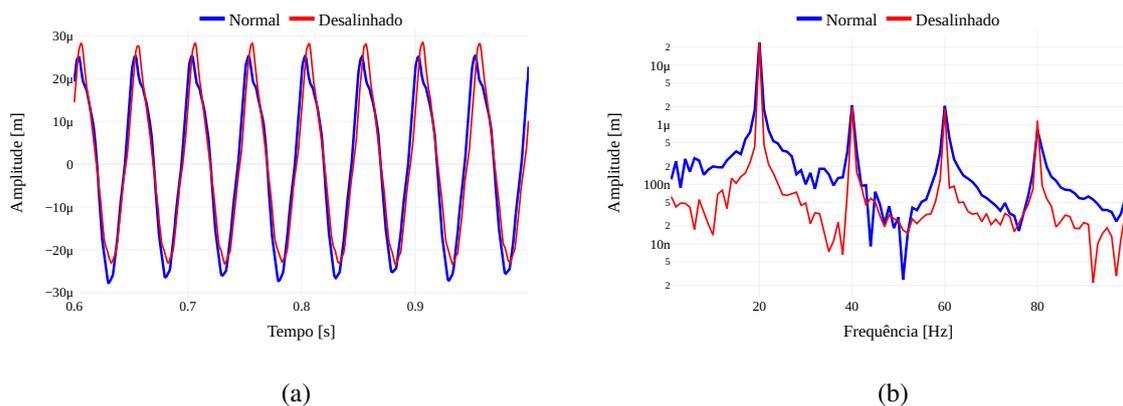


Figura 6.14: Resposta temporal e DFT experimentais em S_1 na direção X em condição normal de operação e com desalinhamento.

O desalinhamento também resulta no aumento das amplitudes do sinal temporal, embora menos acentuado do que o desbalanceamento. Nota-se, ainda, pela análise da DFT, a presença de múltiplos da frequência de rotação ao longo do espectro para ambas as condições analisadas. As amplitudes não são tão expressivas se comparadas com as do rotor sob condições normais, sugerindo um efeito menos pronunciado do desalinhamento na resposta vibratória da máquina.

Conforme observado nas Figs. 6.13 e 6.14, os efeitos do desbalanceamento e desalinhamento no sistema rotativo da bancada de testes produzem comportamento similar tanto no domínio do tempo quanto no da frequência. A sobreposição dos sintomas e os padrões de frequência prejudicam o desempenho dos métodos de diagnóstico.

Em um segundo plano, os efeitos do desbalanceamento, desalinhamento e trinca são ana-

lisados por meio de simulações numéricas utilizando o modelo matemático já ajustado. Essa análise envolve a simulação do acréscimo de massas desbalanceadoras nos discos, bem como variações nos parâmetros do modelo matemático, como a rigidez radial e de flexão do acoplamento flexível, ângulo de desalinhamento e profundidade da trinca. Esses estudos permitem uma compreensão mais profunda de como estas falhas afetam o comportamento dinâmico dos rotores.

O desbalanceamento no modelo matemático é dado através simulação do acréscimo de massas descentralizadoras nos discos. A Fig. 6.15 apresenta uma comparação das respostas numéricas no domínio do tempo e de sua respectiva DFT em S_1 na direção X do rotor em condição normal de operação e com desbalanceamento oriundo de uma massa de 1,5 g adicionada aos discos D_4 e D_6 em -60° .

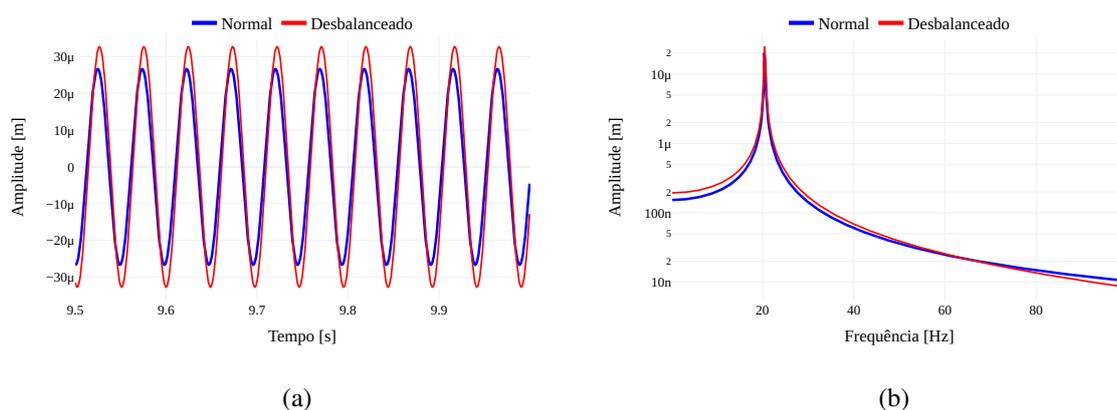


Figura 6.15: Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com desbalanceamento.

Conforme visto na Fig. 6.15, o modelo matemático apresenta sensibilidade ao desbalanceamento. Assim como nas respostas experimentais, a massa e sua respectiva posição angular influencia diretamente nas respostas, como o aumento da amplitude de vibração. A frequência de maior energia e dominante em todo o espectro é a componente $1X$ já que o sistema é excitado unicamente pelo desbalanceamento.

O desalinhamento paralelo e angular são simulados simultaneamente fixando para o modelo matemático valores da rigidez de acoplamento em 5000 N/m, radial em 400 N/m e de flexão em 380 N/m. As distâncias de desalinhamento ao redor das direções X e Z são estabelecidas em 1×10^{-3} m e ângulo para desalinhamento angular de $1,5^\circ$. A Fig. 6.16 apresenta uma

comparação das respostas numéricas no domínio do tempo e de sua DFT em S_1 na direção X do rotor em condição normal de operação e com desalinhamento.

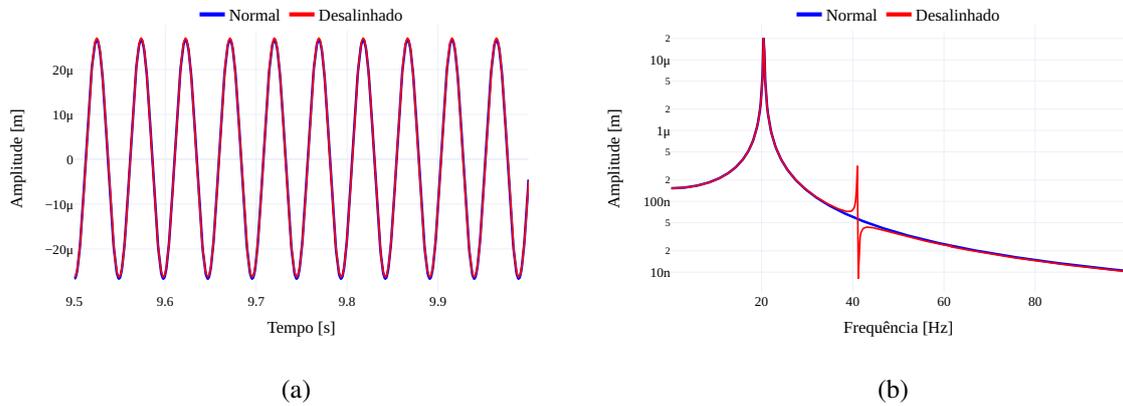


Figura 6.16: Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com desalinhamento.

Ao analisar a Fig. 6.16, fica evidente que o modelo numérico também apresenta sensibilidade ao desalinhamento. As respostas temporais do rotor em condições normais e desalinhadas mostram curvas praticamente sobrepostas, com respostas muito semelhantes para ambas as condições. No entanto, ao examinar a DFT desses sinais, observa-se um padrão característico associado ao desalinhamento: a excitação de múltiplos da velocidade de rotação, destacando-se a componente $2X$.

Uma trinca transversal no eixo do rotor segundo o modelo matemático de Mayes é simulada. A Fig. 6.17 apresenta uma comparação das respostas numéricas no domínio do tempo e de sua respectiva DFT em S_1 na direção X do rotor em condição normal de operação e uma trinca com profundidade de 25% inserida no elemento #28 do modelo de elementos finitos.

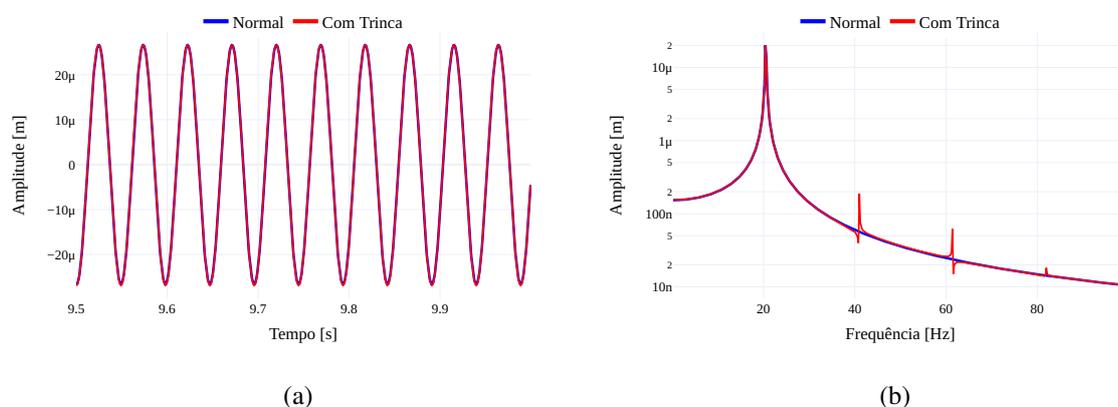


Figura 6.17: Resposta temporal e DFT numéricas em S_1 na direção X em condição normal de operação e com trinca.

Conforme visto na Fig. 6.17, similarmente ao ocorrido no desalinhamento, as respostas temporais do rotor em condições normais e com a trinca apresentam curvas sobrepostas. Os efeitos desta falha se tornam aparentes somente na análise da DFT dos sinais mediante o aparecimento de múltiplos da frequência de rotação ao longo do espectro, um sintoma característico em eixos trincados que se intensifica à medida em que a trinca se propaga (SILVA, 2023).

As análises acima possibilitaram a caracterização dos fenômenos de desbalanceamento, desalinhamento e trincas. Observa-se que o modelo matemático segue a mesma tendência do experimental, demonstrando que os efeitos das falhas observados nos ensaios experimentais também podem ser reproduzidos no modelo matemático. Por exemplo, o aumento das amplitudes de vibração e o aparecimento de múltiplos da frequência de rotação.

Percebe-se que tanto nos ensaios experimentais quanto no modelo matemático, os sintomas de falhas são muito similares. Esse fato dificulta o diagnóstico quando os métodos de detecção e identificação se baseiam apenas em informações usuais, tais como, amplitudes da frequência de rotação e de seus múltiplos. Diante desse cenário, torna-se evidente a importância desta Tese de Doutorado na aplicação de técnicas avançadas de análise de dados e utilização de modelos inteligentes e explicáveis para um maior desempenho no diagnóstico e discriminação de falhas.

CAPÍTULO VII

METODOLOGIA PROPOSTA

A metodologia para um sistema inteligente de monitoramento e diagnóstico de falhas em sistemas rotativos proposta nesta Tese de Doutorado é composta por etapas que envolvem processamento de dados, extração e seleção de características, ajuste e treinamento dos métodos de aprendizado tanto supervisionado quanto não supervisionado, avaliação de desempenho e análise das previsões através de ferramentas de explicabilidade. O presente capítulo aborda conceitos essenciais, ferramentas matemáticas e computacionais empregadas no desenvolvimento da metodologia.

7.1 Metodologia Proposta

Conforme enfatizado por Liu et al. (2018), a maioria dos sistemas inteligentes de diagnóstico de falhas são construídos a partir de uma combinação de partes individuais, como coleta de dados, extração de características, redução de dimensionalidade e reconhecimento de falhas. O diagrama de blocos da Fig. 7.1 apresenta de forma resumida a metodologia para o sistema inteligente proposto no presente trabalho. Conforme visto, cada etapa foi dividida em módulos principais segundo a sua tarefa, (i) aquisição de dados, (ii) extração de características, e (iii) engenharia de recursos, (iv) reconhecimento da falha e (v) explicabilidade.

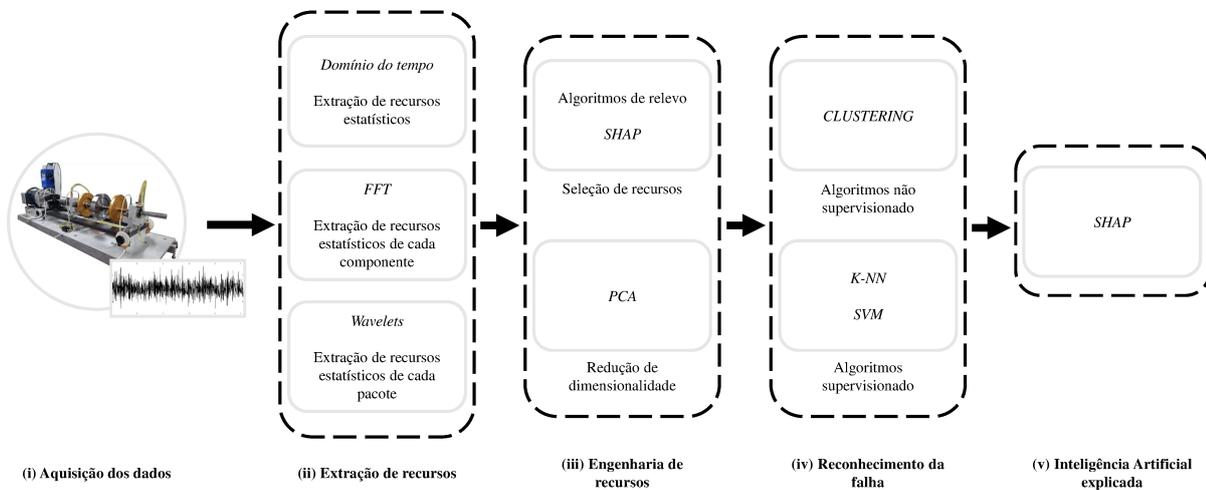


Figura 7.1: Fluxograma da metodologia proposta.

No primeiro módulo, os sinais de vibração oriundos do modelo matemático ou ensaios experimentais são coletados e processados. No segundo módulo, técnicas de extração de características são aplicadas, formando o conjunto de dados original. Posteriormente, no terceiro módulo, os dados são submetidos à engenharia de recursos para seleção das melhores características ou redução de dimensionalidade. O quarto módulo é dedicado ao reconhecimento de falhas através do ajuste, treinamento e aplicação dos métodos de aprendizado. Por fim, o quinto módulo é dedicado à Inteligência Artificial Explicável mediante a aplicação de ferramentas de explicabilidade para maior compreensão das previsões obtidas.

Vale ressaltar que, conforme visto na Fig. 7.1, a ferramenta SHAP, utilizada prioritariamente para explicabilidade, também será aplicada no módulo referente à seleção de características. Os módulos indicados nesta figura, com exceção do primeiro, serão detalhados nas subseções abaixo.

7.2 Extração de Características

A análise de vibração é uma técnica muito explorada, já que os sinais de vibração fornecem informações cruciais sobre o sistema rotativo. Segundo Brito (2022), esta técnica se torna a mais popular devido a fatores como: medições realizadas sem a necessidade de paradas; facilidade na distribuição e fixação dos sensores para aquisição dos dados; baixo esforço computacio-

nal na coleta dos sinais possibilitando o monitoramento de uma maior quantidade de ativos; e conhecimento prévio de informações mais importantes para a detecção e identificação de falha.

A extração de características de um sinal objetiva obter um conjunto de dados com medidas estatísticas que o representam, ou seja, que irão conter informações relevantes referentes ao sinal. Rodrigues, Cairo Júnior e Rade (2022) afirmam que condições anormais de máquinas rotativas são frequentemente acompanhadas por mudanças nos padrões de vibração. Desta forma, cada sinal de vibração pode ser mapeado segundo a extração de características estatísticas nos domínios do tempo, da frequência e tempo-frequência (LIU et al., 2018; BRITO, 2022; WU et al., 2023).

Os estudos de Zhang, Yang e Wang (2019), Liu et al. (2022), Saberi et al. (2022), Wu et al. (2023) apresentam uma variedade de medidas estatísticas de maior empregabilidade no monitoramento e diagnóstico de falhas em máquinas rotativas no domínio do tempo. Estas medidas e suas respectivas fórmulas matemáticas estão descritas na Tab. 7.1. Note que x_i , $i = 1, 2, \dots, N$ faz referência ao sinal de vibração e N ao seu número de pontos.

De acordo com Liu et al. (2018), Rodrigues, Cairo Júnior e Rade (2022), uma falha pode estar associada ao surgimento e propagação dos múltiplos da frequência de rotação do sistema rotativo e à alterações na convergência do espectro. Diante disso, a extração de características a partir do espectro de frequência dos sinais temporais por meio da Transformada Discreta de Fourier (DFT), se mostra uma alternativa promissora (RAZAVI-FAR; FARAJZADEH-ZANJANI; SAIF, 2017; WU et al., 2023). Com base nos estudos de Martínez-Morales, Palacios e Campos-Delgado (2010), Borges et al. (2015), Pandarakone et al. (2017), características como a energia, entropia espectral e as amplitudes da frequência de rotação, bem como de seus múltiplos até a quarta ordem, serão exploradas.

Conforme o tipo e a severidade da falha, a representação dos sinais por meio das características extraídas nos domínios do tempo e da frequência podem ser insuficientes, principalmente quando na presença de não linearidades ou ruídos. Diante disso, recorre-se ao domínio do tempo-frequência (BRITO, 2022; WU et al., 2023). Aqui, decomposições esparsas, transformadas *wavelets* e de Hilbert-Huang são técnicas amplamente adotadas (RAZAVI-FAR; FARAJZADEH-ZANJANI; SAIF, 2017). Conforme observado na Tab. 7.1, para $R13$, P_i é a probabilidade de cada sub-banda na transformada *wavelets* estar no estado i de N possíveis estados.

Tabela 7.1: Principais medidas estatísticas utilizadas na extração de características.

Descrição	Recurso	Definição
R01	Energia Absoluta	$\int x_i(t) ^2 dt$
R02	Média	$\frac{1}{N} \sum_{i=1}^N x_i$
R03	Variância	$\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$
R04	Desvio-padrão	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
R05	Root Mean Square (rms)	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
R06	Valor de Pico	$\max x_i $
R07	Valor Pico-a-Pico	$\max x_i - \min x_i $
R08	Assimetria	$\frac{1}{N} \sum_{i=1}^N \frac{(x_i - R02)^3}{R04^3}$
R09	Curtose	$\frac{1}{N} \sum_{i=1}^N \frac{(x_i - R02)^4}{R04^4}$
R10	Fator 1	$\frac{R05}{R02}$
R11	Fator 2	$\frac{R09}{R05}$
R12	Fator 3	$\frac{R08}{R09}$
R13	Entropia	$-\sum_{i=1}^N P_i \log(P_i)$

A extração de características permite a obtenção da matriz de dados. Os sinais de vibração amostrados x_i serão compostos por m características nos domínios do tempo, da frequência e tempo-frequência.

7.3 Engenharia de Recursos: Redução de Dados

O conjunto de dados original pode estar sujeito a um elevado número de características. Algoritmos de clusterização, classificação e redes neurais são sensíveis à maldição da dimensionalidade e à características irrelevantes ou redundantes (DASH; ONG, 2011), afetando a capacidade preditiva destes métodos de aprendizado (DASH; ONG, 2011; AGGARWAL et al., 2023).

No trabalho de Brito (2022) são enfatizados pontos relevantes a serem considerados em

dados com dimensão elevada. Em primeiro lugar, a maldição da dimensionalidade: o elevado número de características em relação à amostra pode acarretar *overfitting*, onde o modelo se ajusta muito bem aos dados de treinamento, mas apresenta uma alta taxa de erro no grupo de teste. Em segundo lugar, a utilização de modelos simples e explicáveis em acordo com o conceito da Navalha de Occam: quanto maior o número de características, maior será a dificuldade na explicação do modelo, tornando as aplicações reais inviáveis. E, por fim, a utilização de características que não apresentam informações significativas para o modelo resulta em um desempenho inferior ao desejado; em outras palavras, entradas de baixa qualidade produzem saídas ruins, conhecido como o conceito de *Garbage In, Garbage Out*.

Diante do exposto, o emprego de técnicas para redução de dados se apresenta como uma estratégia promissora, geralmente abordada de duas maneiras. Na primeira abordagem, realiza-se a seleção das características mais relevantes. Na segunda, utiliza-se a redução de dimensionalidade, transformando o conjunto de dados original através de combinações das variáveis de entrada, de forma que o novo conjunto contenha essencialmente as mesmas informações que o original. Conforme enfatizado por Cheng et al. (2022), Wu et al. (2023), um conjunto de dados reduzidos promove a (i) redução do espaço de armazenamento; (ii) menor tempo computacional para treinamento dos modelos; (iii) visualização e melhor compreensão dos dados e padrões subjacentes do modelo; e (v) redução de variáveis correlacionadas e recursos redundantes.

A redução de dados, apesar de ser extremamente vantajosa, não é uma tarefa trivial. Na seleção, à medida que o número de características aumenta, a complexidade de encontrar o subconjunto ideal também aumenta, e isso ocorre de forma exponencial (CHEN et al., 2021). Por outro lado, na redução de dimensionalidade, há perda de explicabilidade das características e da representatividade do problema em análise devido à transformação do espaço.

7.3.1 Seleção de Características

Conforme visto, um grande número de características nem sempre resulta em uma melhor segregação dos dados prejudicando a capacidade de aprendizado. Diante disso, a seleção das melhores características permite a obtenção de um subconjunto ótimo sem dados irrelevantes e redundantes, de modo a reduzir o erro do modelo e prevenir o *overfitting* (AGGARWAL et al., 2023). Zhang e Chen (2018), Urbanowicz et al. (2018), Aggarwal et al. (2023) categorizam os métodos de seleção em três grupos: métodos de filtro *filter*, *wrapper* e incorporados.

Os métodos de filtro são baseados nas correlações entre as características originais segundo os rótulos ou similaridades. Essas abordagens são computacionalmente mais acessíveis, especialmente em cenários de alta dimensão. Os subconjuntos são obtidos sem envolvimento de métodos de aprendizado específicos por meio da filtragem que envolvem propriedades estatísticas, ganho de informação, distâncias, dependência e consistência (URBANOWICZ et al., 2018). Pesos são atribuídos a cada um das características originais e aquelas com maior pontuação são selecionadas.

Os *wrappers* são técnicas que exigem um método de aprendizado pré-determinado. Estes métodos são iterativos cuja atribuição da pontuação de cada característica é estimada mediante o desempenho do conjunto de dados de validação por meio de algoritmos de busca, uma vez que a seleção de característica é interpretada como um problema de otimização combinatória, onde as variáveis são as características e o objetivo é a minimização da aptidão (CHEN et al., 2021). Recentemente, algoritmos meta-heurísticos têm sido amplamente aplicados aos métodos *wrapper* mostrando resultados promissores. Abordagens típicas incluem algoritmos baseados em evolução ou inspirados em inteligência de enxames (CHENG et al., 2022; AGGARWAL et al., 2023). Embora possam fornecer um subconjunto de características mais eficaz, em sua grande maioria, os métodos *wrapper* são computacionalmente caros e propensos ao *overfitting*.

Já os métodos incorporados são geralmente empregados em conjunto com os *wrappers* para redução do custo computacional, integrando a seleção de características no processo de construção do modelo durante o treinamento. São abordagens híbridas que combinam vantagens dos métodos *filter* e *wrapper*, obtendo subconjuntos ideais com base na relevância dos dados. Ao contrário dos métodos *wrapper*, estes não avaliam iterativamente subconjuntos de características, tornando suas complexidades temporais mais próximas das dos métodos *filter*. São computacionalmente eficientes, uma vez que integram a modelagem e seleção de características simultaneamente, otimizando funções objetivas com termos de adequação e penalidades para um maior número de características. Por outro lado, assim como os *wrapper*, a escolha do subconjunto ótimo depende do método de aprendizado e também estão sujeitos ao *overfitting*.

Nesta Tese de Doutorado, a seleção de características foi realizada mediante os métodos de Relevância e SHAP, este último comumente utilizado como ferramenta de explicabilidade. O método de Relevância é aplicado durante as etapas de pré-processamento dos dados, o cálculo das pontuações não exige um método de aprendizado pré-determinado. Por outro lado, o SHAP enquanto um selecionador de características (CHEN et al., 2021; GEBREYESUS et al., 2023),

atribui a cada uma delas um valor de importância que definirá as características mais importantes.

7.3.2 Método de Relevância

O método de Relevância foi proposto nos trabalhos de Kira e Rendell (1992a), Kira e Rendell (1992b). A aprendizagem é baseada em instâncias (amostras), cuja importância de cada característica é estimada através de suas instâncias vizinhas mais próximas para calcular estimativas de peso (pontuações) mediante as interações das características (AGGARWAL et al., 2023).

Em acordo com Urbanowicz et al. (2018), o método de Relevância busca identificar quão bem os valores das características distinguem entre instâncias vizinhas. As pontuações para cada uma das características, estimadas mediante processo iterativo, estão compreendidas entre -1 e 1 . Os pesos negativos são irrelevantes e os positivos devem ser atribuídos às características informativas e relevantes. As pontuações são atualizadas com base nas diferenças dos valores de características entre instâncias vizinhas de mesma e de outra classe. O peso diminui, ou aumenta, quando há diferenças de valores para instâncias vizinhas de mesma classe e de classes diferentes.

O método de Relevância original se encontra obsoleto devido sua aplicação limitada, apenas a problemas de classificação binária e com dados discretos e os pesos não são otimizados de forma eficiente, pois apenas um vizinho mais próximo é considerado para estimativa da qualidade da característica. Diante disso, aprimoramentos para este método foram propostos para lidar com dados contínuos, desbalanceados e problemas multiclasse, com destaque aos trabalhos de Dash e Ong (2011), Fu et al. (2014), Urbanowicz et al. (2018), Aggarwal et al. (2023). O presente trabalho adota uma versão do método de Relevância para dados não rotulados. O método de Relevância C proposto por Dash e Ong (2011), foi utilizado na seleção de características em tarefas de clusterização, cuja a atribuição das pontuações é baseada em medidas de similaridade entre as instâncias.

7.3.3 Redução de Dimensionalidade por PCA

Os métodos de redução de dimensionalidade projetam o conjunto de dados original em um espaço de dados com dimensão menor (RAZAVI-FAR; FARAJZADEH-ZANJANI; SAIF, 2017). Essa redução objetiva reduzir o conjunto de dados criando novas características represen-

tativas e descartando as originais, resumindo a maior parte da informação contida no conjunto original.

Uma variedade de métodos para a redução de dimensionalidade são bem consolidadas na literatura. Em Brito (2022), o autor investigou a viabilidade de métodos de redução, como a Incorporação Estocástica de Vizinhos t -distribuída (t -SNE), Mapeamento Isométrico de Características (ISOMAP), Análise de Componentes Independentes (ICA) e Auto Encoder (AE). A comparação dos resultados revelou o melhor desempenho do PCA, especialmente no contexto de detecção de anomalias em máquinas rotativas, perdendo apenas para a seleção manual de características com base no conhecimento do especialista.

O PCA é um método estatístico não paramétrico muito requisitado para simplificar a complexidade dos dados, reduzindo o conjunto de dados original a componentes principais não correlacionados, combinações lineares das variáveis originais, escolhidos segundo sua variabilidade. Esse método realiza uma transformação linear das amostras em um conjunto de novas coordenadas ortogonais em que a direção da máxima variação se concentra na primeira coordenada, a componente principal, seguida pela direção da próxima maior variação na coordenada subsequente, e assim por diante (SHLENS, 2014; JOLLIFFE; CADIMA, 2016).

7.4 Métodos de Aprendizado Não Supervisionado para Inferência

Como parte integrante da metodologia proposta neste trabalho, a detecção de anormalidades como indicador da presença de falhas e comportamentos não usuais em sistemas rotativos é realizada através de métodos de aprendizado não supervisionados, com destaque às tarefas de clusterização de dados apresentadas abaixo.

7.4.1 Clusterização de Dados

A clusterização, ou agrupamento de dados, possui um aprendizado não supervisionado que têm se destacado devido à sua aplicabilidade em diferentes áreas do conhecimento (GÉRON, 2019; ALPAYDIN, 2020). Nessa aprendizagem, o conjunto de dados é formado por amostras não rotuladas. Os dados são agrupados de acordo com um índice ou medida de similaridade pré-estabelecida.

O objetivo dos métodos de clusterização se concentra em agrupar N amostras do conjunto de dados em k grupos disjuntos, denominados clusters. Para Omran, Engelbrecht e Salman

(2007), a formulação de um problema de clusterização é a seguinte: Dado um conjunto de dados contendo N amostras, deseja-se obter um conjunto de k clusters, com $k \leq N$. Isso deve ser feito de forma que as amostras dentro de um mesmo cluster K_i apresentem maior similaridade entre si do que com as amostras de qualquer outro cluster em K . Dessa maneira, todas as condições a seguir devem ser satisfeitas:

1. $\bigcup_{i=1}^k K_i = X$;
2. $K_i \neq \emptyset$ para todo i com $1 \leq i \leq k$;
3. $K_i \cap K_j = \emptyset$ para todo $i \neq j$, com $1 \leq i \leq k$ e $1 \leq j \leq k$.

O desempenho no agrupamento dos dados está intimamente relacionada à expertise do especialista na escolha do número de clusters e da similaridade. A medida de similaridade é baseada em distância, quanto maior o valor calculado, menor o grau de semelhança entre as amostras envolvidas no cálculo e, quanto menor a distância, maior a similaridade.

Para obter a similaridade por meio das medidas de distâncias é necessário calcular o complemento da distância conforme Eq. (7.1):

$$\text{sim}(S_i, S_j) = 1 - \text{dist}(S_i, S_j), \quad (7.1)$$

onde $\text{sim}(S_i, S_j)$ representa a similaridade entre as amostras S_i e S_j e $\text{dist}(S_i, S_j)$, a distância entre elas.

Algumas medidas de distâncias são normalmente usadas para computar as similaridades dos dados. As características das amostras são consideradas como dimensões de um espaço multi-dimensional. Desse modo, a descrição de cada amostra corresponde a um ponto nesse espaço. Em sua grande maioria, os modelos utilizam a distância de Minkowsky como padrão, dada pela Eq. (7.2), que estabelece uma maneira genérica no cálculo da distância entre dois pontos no espaço multi-dimensional de tamanho p . Note que para $p = 2$ tem-se a distância euclidiana.

$$\text{dist}(S_i, S_j) = \left(\sum_{q=1}^M |x_{iq} - x_{jq}|^p \right)^{\frac{1}{p}} \quad (7.2)$$

onde $E_i = (x_{i1}, x_{i2}, \dots, x_{iM})$ e $E_j = (x_{j1}, x_{j2}, \dots, x_{jM})$, são as amostras descritas pelos respectivos valores das M características.

A clusterização é extensivamente abordada na literatura, resultando em maior aplicabilidade por meio de bibliotecas e plataformas populares, como é o caso da biblioteca *scikit-learn*, amplamente empregada para aprendizado de máquina em Python contendo uma variedade de algoritmos de clusterização englobando métodos particionais, hierárquicos, baseados em densidade e modelos de misturas.

As técnicas particionais compreendem métodos de clusterização de grande popularidade, como o k -Means, proposto por (MACQUEEN et al., 1967; LLOYD, 1982). Esses métodos geralmente visam a formação de agrupamentos ótimos nos dados, sendo mutuamente exclusivos, ou seja, cada amostra pertence a exatamente um grupo. Eles se baseiam na distância entre as amostras e os centroides, que normalmente são a média dos dados pertencentes a um mesmo grupo (BISHOP, 2006). O algoritmo começa com a escolha do número de grupos k e k pontos como centroides iniciais, selecionados por escolha ou aleatoriamente. Cada ponto é atribuído ao seu centroide mais próximo por meio de uma medida de distância. Após as atribuições, os centroides são atualizados e esse processo é repetido iterativamente até que os centroides permaneçam inalterados ou qualquer outro critério de convergência alternativo seja atendido.

O processo de agrupamento dos clusterizadores hierárquicos é fundamentado na decomposição hierárquica, resultando na formação de dendrogramas ou árvores binárias. Durante o processo iterativo de construção do dendrograma, cada nível corresponde a algum conjunto de grupos. Portanto, o número de grupos pode ser determinado pela seção do dendrograma em um nível específico. Esses clusterizadores são classificados em duas categorias de acordo com sua abordagem de decomposição: aglomerativa e divisiva.

Na abordagem aglomerativa, também conhecida como *bottom-up*, cada ponto inicialmente forma um grupo separado. A cada iteração subsequente, esses pontos são mesclados progressivamente até serem consolidados em apenas um grupo, correspondendo ao nível mais alto da hierarquia. Por outro lado, na abordagem divisiva, ou *top-down*, o processo é inverso. Inicialmente, todos os pontos pertencem ao mesmo grupo. A cada iteração subsequente, esse grupo é subdividido em grupos menores até que cada ponto esteja em um grupo distinto, representando o nível mais baixo da hierarquia.

Nos clusterizadores hierárquicos, os grupos são mapeados por ligações de similaridade (AGGARWAL; REDDY, 2014). As ligações *single* (distância mínima), *complete* (distância máxima), *average* (distância média) e *ward* (minimização da variância das distâncias) são opções de mapeamento presentes na grande maioria das bibliotecas que contemplam os cluste-

rizadores hierárquicos.

O agrupamento baseado na noção de densidade utiliza o conceito de que os grupos correspondem a subconjuntos de dados bem próximos e que, por sua vez, formam áreas densas no espaço de dados. Um mesmo grupo pode crescer enquanto a densidade de uma vizinhança não exceder algum limite. Métodos como o DBSCAN, proposto no trabalho de Ester et al. (1996), são amplamente utilizados na filtragem de ruídos e *outliers* (XU; TIAN, 2015). Essa abordagem requer apenas dois parâmetros de entrada: o raio de vizinhança (ϵ) e o número mínimo de pontos (*MinPts*). Dessa forma, a formação de um grupo se dá pela verificação da quantidade de pontos contidos no raio ϵ , que é limitada. Por outro lado, o parâmetro *MinPts* especifica o número mínimo de pontos, dado ϵ , que um ponto precisa possuir para ser considerado um ponto central.

Modelos baseados em mistura, como o GMM, associam uma probabilidade de pertencimento para cada ponto de dados a cada um dos clusters estabelecidos. Nesse contexto, os dados são gerados por uma mistura de várias distribuições gaussianas (também chamadas de componentes ou clusters). Cada componente gaussiano representa um cluster potencial. Para cada ponto de dados x_i , o modelo calcula a probabilidade de pertencimento (responsabilidade) para cada um dos componentes j segundo a Equação 7.3.

$$P(z_j|x_i) = \frac{\pi_j N(x_i|\mu_j, \Sigma_j)}{\sum_{k=1}^K \pi_k N(x_i|\mu_k, \Sigma_k)}, \quad (7.3)$$

onde $P(z_j|x_i)$ é a responsabilidade do ponto x_i para o componente j ; π_j é a proporção do componente j na mistura; $N(x_i|\mu_j, \Sigma_j)$ é a função de densidade de probabilidade gaussiana para o componente j com média μ_j e matriz covariância Σ_j . O denominador é a normalização para garantir que as responsabilidades somem para 1.

O processo de treinamento do GMM geralmente utiliza o algoritmo *Expectation-Maximization* (EM). Durante a etapa de *expectation* (E-step), são calculadas as responsabilidades dos pontos de dados para cada componente usando a função de densidade de probabilidade gaussiana. Na etapa de *maximization* (M-step), os parâmetros do modelo são ajustados para maximizar a probabilidade logarítmica dos dados, utilizando as responsabilidades calculadas.

7.4.2 Clusterização Aplicada à Detecção de Anormalidades

Em sua forma usual e clássica, métodos de clusterização são ajustados uma única vez e, posteriormente, os dados do conjunto de testes são direcionados aos grupos já definidos durante o treinamento mediante alguma medida de similaridade (ALPAYDIN, 2020). Nessas circunstâncias, sua utilização na detecção de anormalidades em aplicações industriais com atualizações constantes nos dados é uma tarefa complexa e até mesmo inviável.

Os clusterizadores, ao serem treinados inicialmente, não conseguem adaptar-se automaticamente às novas condições ou anomalias que surgem ao longo do tempo, necessitando de re-treinamentos frequentes para manter a eficácia do modelo. Se este for treinado e ajustado apenas com dados rotulados como normais, qualquer nova amostra que represente uma mudança significativa será direcionada a um dos grupos já pré-definidos durante o treinamento, mesmo que essa mudança seja substancial.

O exposto acima destaca a limitação dos clusterizadores em adaptar-se rapidamente a novas condições sem intervenção manual ou re-treinamento periódico e motiva a implementação de uma estratégia que permita a utilização de clusterizadores na detecção de anormalidades mediante a divergência na similaridade entre os grupos, detalhada abaixo. A etapa de detecção é aplicada em janelas deslizantes ao longo do tempo, simulando um sistema de diagnóstico em tempo real, onde a caracterização de anomalia numa janela de sinal atual será baseada em informações da anterior.

Inicialmente, os primeiros sinais oriundos da condição normal de operação da máquina são processados, etapa que envolve a extração de características informadas pelo usuário, normalização e redução de dimensionalidade, caso haja necessidade, técnicas de processamento digital de sinais para aumento artificial da taxa de amostragem podem ser empregadas. Os dados obtidos são dedicados ao ajuste, estabilidade e treinamento dos modelos clusterizadores.

A primeira etapa é o pré-processamento do sinal de vibração de referência. Este processo envolve a subdivisão do sinal em segmentos menores, extração de características relevantes, normalização para evitar distorções indesejadas e redução da dimensionalidade. Essa preparação é crucial para garantir que os dados estejam em um formato consistente e comparável para análises posteriores.

Na segunda etapa, aplica-se a clusterização aos dados de referência com base em sua similaridade. Durante esse processo, as distâncias máximas dentro de cada cluster são estimadas, tanto

entre as instâncias de um grupo quanto entre elas e o centroide desse grupo. Essas distâncias são armazenadas para uso subsequente.

O terceiro passo é o pré-processamento do sinal recém-chegado para comparação, que é semelhante ao primeiro passo. O sinal de comparação é preparado e processado da mesma maneira que o sinal de referência, garantindo que ambos os conjuntos de dados estejam alinhados em termos de características extraídas e normalizadas.

Na quarta etapa, as mesmas distâncias estimadas na segunda etapa são computadas para as amostras do sinal de comparação. Essas distâncias funcionam como medidas de similaridade, ajudando a determinar a correspondência entre o sinal de comparação e os padrões representados pelos clusters.

Em seguida, realiza-se a comparação das distâncias obtidas para os dados de referência e os de comparação. As distâncias entre as amostras do sinal de referência e as do sinal de comparação são avaliadas. Isso permite medir o quão bem o sinal de comparação se encaixa nos padrões estabelecidos pelo sinal de referência ou identificar divergências nas distribuições de probabilidade. Um fator percentual de divergência aceitável, fornecido pelo usuário, é utilizado para decidir se o sinal de comparação é suficientemente semelhante ao sinal de referência. Essa análise determina se o sinal de comparação está dentro dos padrões aceitáveis ou se indica alguma anomalia ou condição indesejada.

A Figura 7.2 apresenta uma ilustração da metodologia proposta. As amostras em vermelho são do sinal de referência e as azuis, do sinal de comparação. O grau de similaridade entre elas é avaliado segundo avaliação de duas características usuais, curtose e RMS.

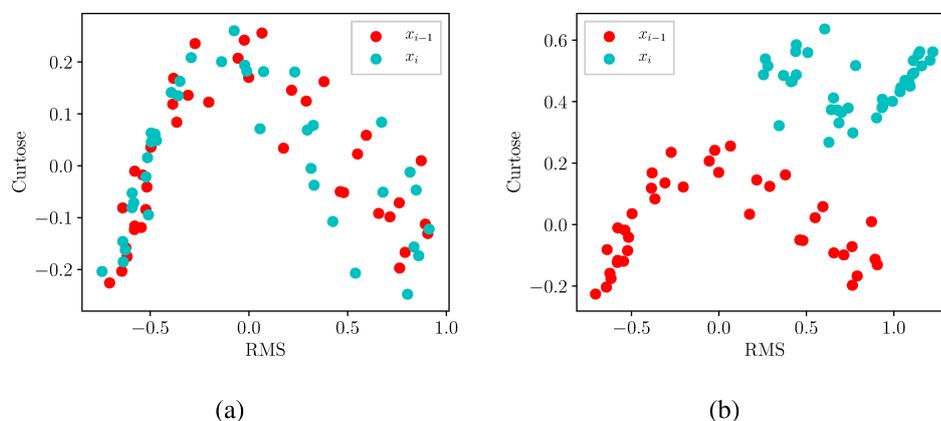


Figura 7.2: Representação gráfica da metodologia de detecção de anormalidades por meio da clusterização.

Conforme mostrado na Fig. 7.2 (a), a distribuição dos dados de referência (x_{i-1}) e os dados

de comparação (x_i) são equivalentes, indicando que as distâncias comparadas apresentam pouca divergência entre si. Portanto, o sinal de comparação será caracterizado como normal e o mesmo sinal de referência prevalece para a próxima análise. Por outro lado, conforme ilustrado na Fig. 7.2 (b), quando o novo sinal configura uma anomalia, as distribuições dos dados de referência e de comparação são bem distintas. Nessa situação, a divergência é alta, e as distâncias entre as amostras e os centroides dos clusters são maiores do que as distâncias usuais. Neste caso, o sinal de comparação será utilizado como referência na próxima análise.

7.5 Métodos de Aprendizado Supervisionado para Inferência

Devido à sua natureza, os métodos clusterizadores, utilizados para a detecção de anomalias, são insuficientes para a identificação de cada condição de falha a ser avaliada. Diante disso, dois métodos de aprendizado supervisionado clássicos foram empregados, a saber: k vizinhos mais próximos e máquinas vetoriais. Estes métodos, brevemente descritos nas subseções seguintes, são amplamente difundidos na literatura e apresentam implementação simples e custo computacional baixo, o que fundamenta a escolha.

7.5.1 k -Nearest Neighbor (k -NN)

O k -NN, proposto por (AHA; KIBLER; ALBERT, 1991), é um método determinístico e não paramétrico amplamente utilizado em tarefas de classificação e regressão. Comparado com outros algoritmos, este método mostra uma vantagem de implementação simples (LIU et al., 2018). Como o próprio nome sugere, a classificação de uma instância depende dos seus k vizinhos mais próximos. Considerando uma instância como um ponto no espaço e definindo o seu entorno, a nova instância será rotulada de acordo com a classe ou grupo mais frequente entre os demais pontos que compõem a sua vizinhança, conforme apresentado na Fig. 7.3.

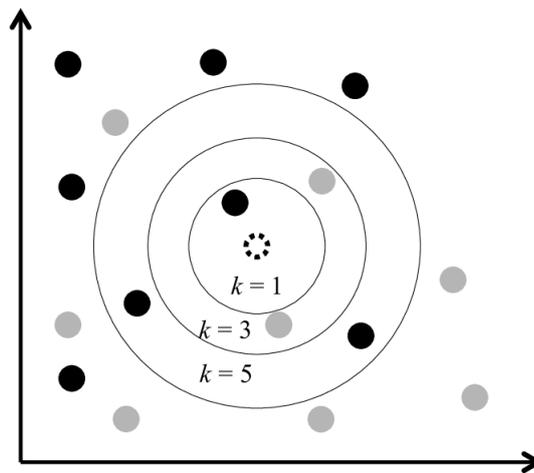


Figura 7.3: Critério de seleção dos k vizinhos mais próximos.

Percebe-se pela observação da Fig. 7.3 que a classificação do novo ponto (círculo pontilhado) dependerá da quantidade de k vizinhos mais próximos escolhidos. Se escolhermos $k = 1$ como critério de vizinhança, a classificação do novo dado será na classe preta, pois no menor círculo contínuo, a observação mais frequente pertence a esta classe. Caso $k = 3$, a classificação será cinza, uma vez que nesta vizinhança temos uma bola preta e duas cinzas. Quando $k = 5$, a classificação volta para preto, já que a frequência de bolas pretas é três e a de cinzas é dois.

7.5.2 Support Vector Machine (SVM)

As máquinas vetoriais (STITSON et al., 1996; VAPNIK, 1998) são métodos fundamentados na teoria de aprendizado estatístico que se destacam pela grande eficiência em tarefas de classificação para pequenas amostras e regressão linear. Na grande maioria dos casos, os resultados apresentados são equivalentes ou até superiores quando comparados a métodos mais avançados (LIU et al., 2018; GÉRON, 2019; DIAS, 2019).

As SVMs, em sua configuração tradicional, buscam um hiperplano ótimo que torne os dados linearmente separáveis. Ao contrário de métodos como redes neurais, as SVMs não consideram pontos distantes da linha ao gerar o plano. Na Fig. 7.4, a linha que separa os dados "X" e "O" é o hiperplano de separação, sendo este um plano em um espaço N -dimensional. É importante observar que o ponto A, devido à sua localização, não influencia na posição ideal da linha. No entanto, se o ponto C for movido para baixo, será necessário ajustar a linha para garantir que os dados permaneçam linearmente separáveis.

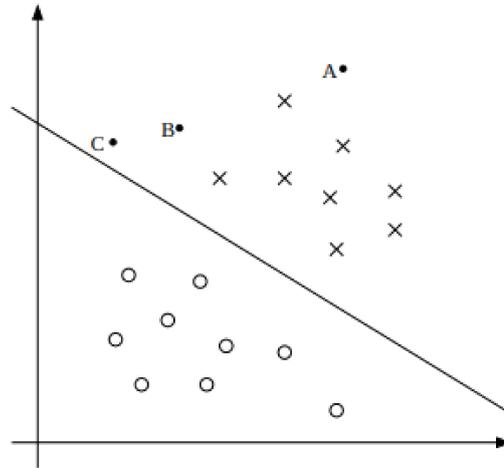


Figura 7.4: Hiperplano de separação para SVM em uma classificação binária.

A SVM busca um hiperplano ótimo que torne os dados linearmente separáveis. Ao contrário de métodos como redes neurais, ela não considera pontos distantes da linha ao gerar o plano. O hiperplano ideal de separação consiste na resolução do problema de otimização quadrático restrito, baseado no princípio da Minimização de Risco Estrutural (LIU et al., 2018), conforme Eq. (??), que permite desenvolver máquinas com maior capacidade de generalização e, ainda, superar os problemas com *overfitting* (DIAS, 2019).

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^\top \mathbf{w} + C \sum_{i=1}^n \xi_i \quad (7.4)$$

sujeito a:

$$y_i(\mathbf{w}^\top \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, n \quad (7.5)$$

onde \mathbf{w} é o vetor de pesos, b é o termo de bias, ξ_i são as variáveis de folga (slack variables) que permitem a existência de erros de classificação, e C é um parâmetro que controla a penalidade por erros de classificação. A função $\phi(\mathbf{x}_i)$ mapeia as instâncias de entrada para um espaço de características de maior dimensão, possibilitando a separação linear em casos onde os dados originais não são linearmente separáveis.

A solução do problema consiste em obter os multiplicadores de Lagrange, os quais podem ser calculados por meio do método *Sequential Quadratic Programming* (SQP) segundo às

condições de otimalidade de Karush-Kuhn-Tucker (KKT). A partir da solução deste problema de otimização obtém-se a função de decisão do classificador com margem maximizada (LIU et al., 2018).

As SVMs com margem rígida eram capazes de classificar duas classes com dados linearmente separáveis. Posteriormente, o método foi sendo aprimorado, e estratégias para classificação de dados não-linearmente separáveis passaram a ser implementadas, como a implementação de erros mínimos de classificação, chamado de SVM com margens flexíveis ou suaves cuja aplicação possibilitou o conceito de *kernel*.

Os dados utilizados para desenvolvimento das SVMs podem apresentar ruídos, rotulações incorretas e *outliers* que corroboram negativamente para capacidade de generalização do modelo. O conceito de margens suaves pode contribuir para reduzir estes efeitos por meio da suavização das margens do hiperplano inicial com margem rígida (DIAS, 2019).

A suavização permite que alguns dados permaneçam entre os limites impostos pelos vetores de suporte. Acrescenta-se o hiper-parâmetro C , denominado fator de suavização. Quanto menor o fator de suavização, maior quantidade de pontos são ignorados próximos a margem, ou seja, acontece um aumento da margem de folga. Neste caso, obtém-se um problema de otimização que deve maximizar a margem e permitir que alguns vetores estejam dentro da mesma, minimizando efeitos de alguns dados extremos no posicionamento do hiperplano (LIBONI, 2017).

Como mencionado nos estudos de Dias (2019), Liboni (2017), para lidar com problemas não linearmente separáveis, é possível mapear a representação dos dados para um novo espaço de dimensão maior. Essa transformação visa tornar o problema linearmente separável, acrescentando uma dimensão adicional, empregando funções *kernel*. Diante do exposto, essas funções desempenham papel crucial na capacidade dos SVMs lidarem com conjuntos de dados não lineares. Diversas funções *kernel* podem ser utilizadas, incluindo funções polinomiais, gaussianas, sigmoidais, entre outras.

7.6 Otimização dos Hiperparâmetros e *Ensemble*

A otimização dos hiperparâmetros é realizada através da técnica *grid seach* (busca em grade). A ideia é realizar uma busca exaustiva em uma grade de combinações de valores de hiperparâmetros pré-definidos, utilizando a validação cruzada para avaliar o desempenho do modelo em cada conjunto de hiperparâmetros evitando *overfitting* e garantindo uma avaliação

mais robusta. O *GridSearchCV*, disponibilizada na biblioteca *scikit-learn* em Python, é responsável pela automatização desse processo.

A validação cruzada (*cross validation*) é uma técnica amplamente aplicada para seleção de melhores topologias candidatas (DIAS, 2019). Seu objetivo é avaliar uma determinada configuração do modelo a partir de amostras pertencentes ao conjunto de treinamento e, posteriormente, por meio de amostras que não foram utilizadas durante o ajuste, verifica-se o melhor desempenho para mapeamento do problema.

A validação cruzada é uma técnica que divide o conjunto de dados em k partes iguais (dobras) e realiza o treinamento e a avaliação do modelo k vezes. Cada vez, uma das dobras é usada como conjunto de teste, enquanto as outras ($k-1$) dobras são usadas para treinamento reduzindo o impacto da aleatoriedade na seleção dos conjuntos de treinamento e teste.

No contexto do *GridSearchCV*, a validação cruzada é aplicada para cada combinação de hiper-parâmetros. O modelo é treinado e avaliado k vezes para cada conjunto de hiperparâmetros, e a média das pontuações de desempenho é usada para decidir quais são os melhores.

Outro aspecto crucial na aplicação de métodos de aprendizado é a sensibilidade dos mesmos aos tipos de dados, tornando impraticável a adoção de um único algoritmo universal. Assim, a utilização dos métodos de *ensemble* é uma prática valiosa para melhorar a robustez e o desempenho (GÉRON, 2019; DIAS, 2019; BRITO, 2022).

De maneira geral, o *ensemble* envolve a combinação de diferentes métodos para obter uma resposta única. Os resultados de cada modelo integrante do *ensemble* são somados, e a decisão final é alcançada por meio de votação majoritária, onde a classe ou grupo que recebeu a maioria dos votos determina a saída final.

7.7 Indicadores de Desempenho

A matriz de confusão é uma das formas mais populares na avaliação de métodos de aprendizado (BISHOP, 2006; ALPAYDIN, 2020). A forma matricial permite visualizar facilmente quantas amostras foram classificadas corretamente e erroneamente em cada classe mediante indicadores, tais como, falso positivo (FP), falso negativo (FN), verdadeiro positivo (TP) e verdadeiro negativo (TN).

Embora não seja uma métrica em si, a representação matricial pode ser usada para definir uma variedade de métricas (SARKAR; BALI; SHARMA, 2018), tais como, acurácia, precisão,

recall e *F1-score*, que constituem uma maneira melhor de se avaliar o desempenho (GÉRON, 2019).

A acurácia, cuja fórmula está apresentada na Eq. (7.6), apresenta quantas amostras foram de fato classificadas corretamente, independente da classe.

$$Acuracia = \frac{TP + TN}{TP + TN + FP + FN}, \quad (7.6)$$

A precisão, Eq. (7.7), é a razão entre a quantidade de amostras classificadas corretamente como positivos pelo modelo e o total daquelas que são de fato classificadas como positivas, dando enfoque maior aos erros de FP.

$$Precisao = \frac{TP}{TP + FP}, \quad (7.7)$$

O *Recall*, Eq. (7.8), valoriza os erros de FN, dado pela razão entre a quantidade de amostras classificadas corretamente como positivas e aquelas que são de fato positivas.

$$Recall = \frac{TP}{TP + FN}, \quad (7.8)$$

Por fim, o *F1-score*, Eq. (7.9), é a média harmônica entre a Precisão e o *Recall*.

$$F1_{Score} = 2 \left(\frac{Precisao * Recall}{Precisao + Recall} \right). \quad (7.9)$$

Na maioria dos casos, apesar de bem interpretável e de fácil uso, a Acurácia não é recomendada por atribuir o mesmo peso para ambos os erros, em alguns problemas ela pode ser elevada mas, ainda assim, o modelo pode ter uma performance inadequada devido a alguns fatores, tais como em conjunto de dados desbalanceados (BISHOP, 2006).

Em modelos de detecção de anomalias, o *Recall* e *F1-score* são bem-vindos. Em particular, este último tende a ser um resumo melhor da qualidade do modelo, já que um modelo com bom valor para essa métrica é capaz tanto de acertar suas predições quanto recuperar as amostras da classe de interesse.

7.8 Explicabilidade: SHapley Additive exPlanation (SHAP)

Para a difusão dos sistemas inteligentes de monitoramento e diagnóstico de falhas na indústria, a compreensão do processo de aprendizagem do modelo é importante em termos de confiabilidade para tomadas de decisões assertivas. Essa necessidade impulsionou a utilização da inteligência artificial explicável (XAI), destacando-se ferramentas de explicabilidade como o *SHapley Additive exPlanation* (SHAP).

A formulação matemática do SHAP, cuja projeção como ferramenta de explicabilidade são verificadas no trabalho de Lundberg e Lee (2017), tem raízes conceituais na Teoria dos Jogos Cooperativos, especificamente nos valores de Shapley, que foram desenvolvidos pelo matemático Lloyd Shapley. No contexto da XAI, essa ferramenta é aplicada para interpretação das previsões dos métodos de aprendizado, tanto em tarefas não supervisionadas quanto supervisionadas.

O SHAP atribui a cada característica um valor de importância, denominado valor SHAP, para representar a atribuição da característica a uma previsão para uma amostra específica (individual). A classificação de importância é o resultado da contribuição de cada característica para a previsão final do modelo (BRITO, 2022). Isso permite que o especialista compreenda melhor como as características individuais influenciam nas previsões de um modelo, proporcionando *insights* valiosos para a tomada de decisões e depuração.

CAPÍTULO VIII

RESULTADOS NUMÉRICOS E EXPERIMENTAIS

Neste capítulo, avalia-se o desempenho da metodologia proposta para identificação e classificação de falhas mecânicas em sistemas rotativos. Para validar a metodologia como uma ferramenta para detecção de anormalidades e reconhecimento de falhas sob diferentes perspectivas, foram utilizados dados oriundos de três sistemas rotativos. Os dois primeiros envolvem a identificação de anormalidades em um rotor com mancal magnético e em um exaustor industrial, respectivamente. O terceiro envolve tanto a identificação quanto o reconhecimento de falhas a partir de dados numéricos e experimentais do sistema rotativo com mancais hidrodinâmicos proposto e ajustado neste trabalho.

8.1 Detecção de Anormalidades

A detecção de anormalidades via métodos de clusterização é parte integrante do software desenvolvido para o projeto de pesquisa, desenvolvimento e inovação intitulado *Aplicação de Técnica de Inteligência Artificial na Captura de Dados de Máquinas para Armazenamento de Dados de Anormalidades em Servidores (Edge Analytics)*. O desenvolvimento de uma metodologia de detecção de anormalidades através da clusterização envolveu a obtenção e exploração de diferentes conjuntos de dados, chamados de *benchmarks*, dos quais dois são apresentados abaixo. Vale ressaltar que, em cumprimento às exigências do projeto para integração da metodologia ao software na indústria, o processo para detecção de anormalidades foi realizado de forma dinâmica simulando o monitoramento de uma máquina em tempo real com atualizações constantes nos sinais de vibração mediante a utilização de janelas deslizantes.

8.1.1 Benchmark 1: Rotor com Mancal Magnético

A Figura 8.1 apresenta o sistema rotativo em questão. Trata-se de um rotor com dois mancais magnéticos e um disco central comumente utilizado em estudos do LMEst que envolvem controle de vibração e ruído. As velocidades são ajustadas pelo controlador *SKF*. Os mancais, por sua vez, são controlados pela placa *Dspace*.

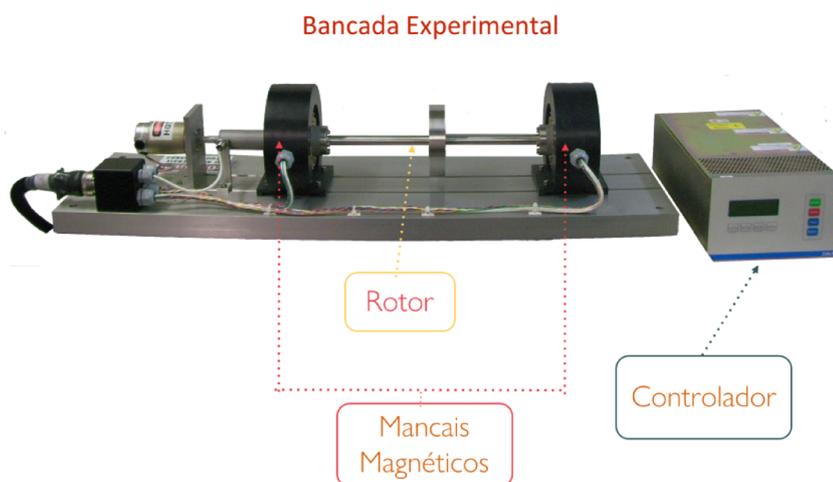


Figura 8.1: Bancada experimental de rotor com mancal magnético.

A Tabela 8.1 apresenta as principais características físicas e geométricas do sistema.

Tabela 8.1: Características da bancada do rotor com mancal magnético.

Parâmetro	Valor
Número de voltas de corrente elétrica (N_s)	276
Entreferro (g_0)	364 mm
Área projetada do pólo (A_g)	430,74 mm ²
Tensão de operação	10 V
Corrente de bias (I_b)	1 A
Rigidez de corrente (K_i)	99,15 N/A
Rigidez de posição (K_x)	214,2 N/m
Capacidade de carga estática	283 N
Comprimento do eixo	645 mm
Massa do rotor com o Disco	5,89 kg
Potência do motor	500 W
Faixa de operação	0-12000 RPM

No processo para aquisição dos dados são considerados aproximadamente 180 s, contando com 4 canais vinculados a sensores de proximidade, rotação nominal de 75 Hz e frequência de amostragem de 10000 Hz. Para avaliação foram utilizadas 185 janelas de 1 s cada, que,

posteriormente, são subdivididas em segmentos menores, contendo 256 pontos.

A Figura 8.2 apresenta o sinal de vibração do rotor com mancal magnético para um dos acelerômetros na direção X a ser avaliado. A curva em vermelho indica os instantes em que cada anomalia foi inserida no sistema. As anomalias incluem fenômenos como variações de velocidade, desalinhamento, desbalanceamento e impactos.

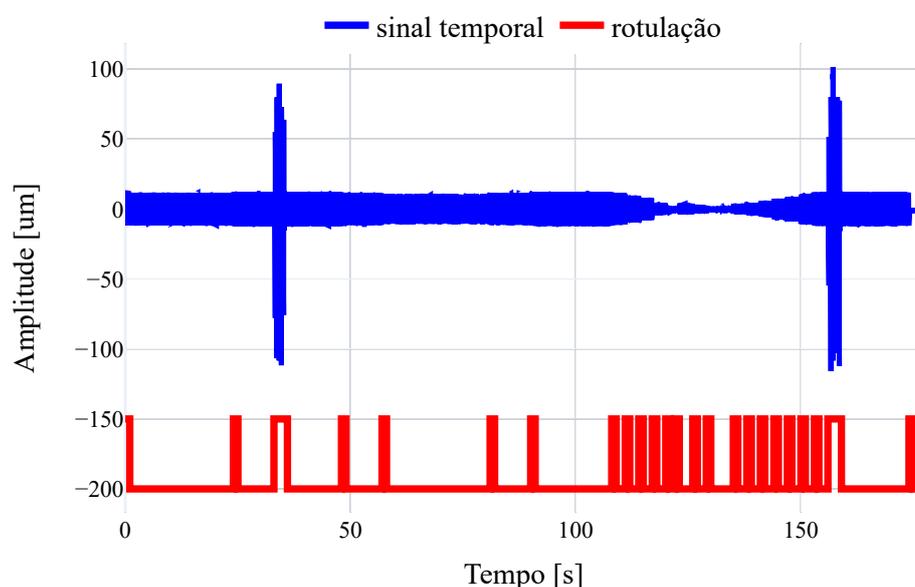


Figura 8.2: Sinal de vibração do rotor com mancal magnético e anomalias inseridas.

Como um fator relevante à implementação do software *Edge Analytics* no âmbito industrial, o custo computacional da metodologia deve ser o mínimo possível. Por conveniência, apenas algumas características como energia absoluta, curtose, assimetria, RMS e valor pico-a-pico foram utilizadas. A utilização de um grande número de características é válida para uma abordagem eficaz do problema, porém isso pode levar a um aumento significativo do custo computacional. Além disso, a alta dimensionalidade dos dados pode dificultar o uso de algoritmos de clusterização, que frequentemente não lidam bem com espaços de alta dimensão. Para mitigar esse problema, o método PCA foi aplicado na redução de dimensionalidade, neste caso, utilizando-se 3 componentes principais.

As oito primeiras janelas são destinadas ao treinamento e ajuste dos clusterizadores que irão compor o *ensemble* que, por sua vez, foi realizado mediante estratégias de busca em grade e validação cruzada considerando 5 dobras. Para conhecimento, *n-clusters* é o número de grupos

utilizados no agrupamento, *eps* é a distância máxima entre duas amostras para que uma seja considerada vizinha da outra, *min-samples* é o número mínimo de amostras em uma vizinhança necessários para a formação de um grupo, *n-components* é o número de componentes da mistura (equivalente ao número de grupos) e *covariance-type* é o tipo de parâmetros de covariância a serem usados, para o *full* cada componente tem sua própria matriz de covariância geral. A Tab. 8.2 apresenta os hiperparâmetros ótimos em questão.

Tabela 8.2: Hiperparâmetros ótimos dos clusterizadores para os dados do rotor com mancal magnético.

Método	Hiperparâmetros
Hierárquico	<i>n-clusters</i> = 4
Dbscan	<i>eps</i> = 0,5; <i>min-samples</i> = 5
Gmm	<i>n-components</i> = 4 ; <i>covariance-type</i> = full

A caracterização das amostras em normais ou anômalas é baseada no fator percentual de divergência aceitável de 0,2, ou seja, as amostras que apresentarem similaridade inferior a 80% em relação àquela de referência serão identificadas como anomalias. Os resultados para a metodologia de detecção segundo indicadores de desempenho estão apresentados na Tab. 8.3. Vale ressaltar que para assegurar resultados confiáveis e consistentes, a metodologia é aplicada repetidamente sob as mesmas condições para estimação de média e do desvio-padrão.

Tabela 8.3: Resultados da detecção de anormalidades para os dados do rotor com mancal magnético.

Método	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)
	Média (Desv.)	Média (Desv.)	Média (Desv.)	Média (Desv.)
<i>ensemble</i>	98,36 (1,3)	93,01 (5,23)	97,14 (2,67)	95,1 (3,88)

Conforme visto na Tab. 8.3, a metodologia, além de apresentar uma arquitetura relativamente simples, apresenta bom desempenho para identificação de anormalidades em sinais de vibração. Apesar de uma boa pontuação, a Acurácia não se mostra eficiente para tarefas de detecção de anomalias, os outros indicadores como a Precisão, *Recall* e *F1-score* são os mais indicados. De acordo com as pontuações alcançadas, houve a ocorrência de um maior número de falsos positivos (menor pontuação para Precisão) do que falsos negativos (maior pontuação para *Recall*).

8.1.2 Benchmark 2: Exaustor Industrial

A Figura 8.3 apresenta o exaustor utilizado, o posicionamento de quatro acelerômetros com aquisição simultânea, os mancais de rolamento do tipo UDP-UCP-205, as polias que são acionadas por correias, o eixo de 25 mm e a placa de aquisição utilizada da *National Instruments* modelo USB9162.



Figura 8.3: Exaustor industrial, sensores e placa de aquisição.

As principais características estão dispostas na Fig. 8.4.

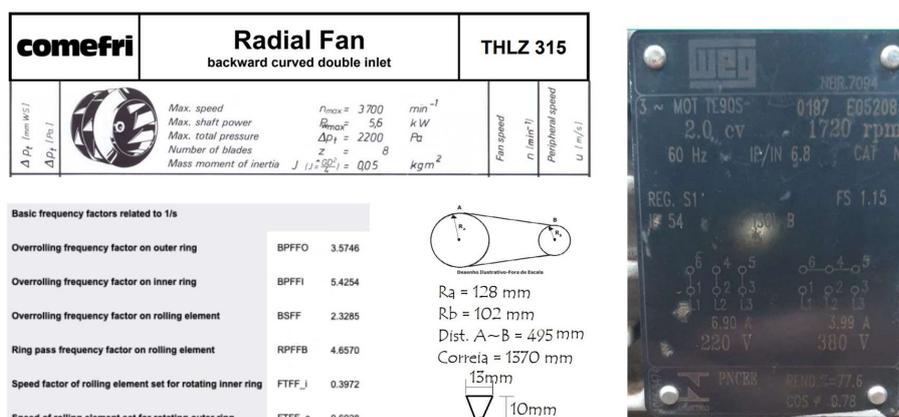


Figura 8.4: Características do exaustor industrial e placa de identificação.

Para aquisição dos dados, considerou-se uma frequência de amostragem igual a 16384 Hz, rotação nominal de 36 Hz e tempo de duração de 100 s, um total de 100 janelas de sinais com 17000 pontos, aproximadamente 1 s, dos quais os primeiros 40 s apresentam a condição normal de operação. Posteriormente, variações são impostas, tais como, *run-down*, *run-up* e impactos. A Fig. 8.5 apresenta o sinal adquirido por um dos acelerômetros e os rótulos nos instantes em que cada fenômeno foi inserido.

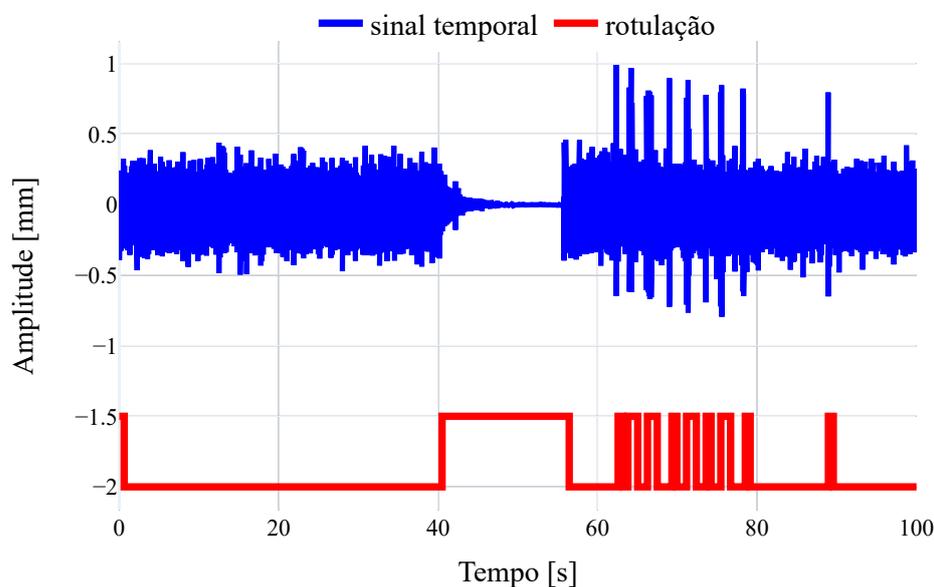


Figura 8.5: Sinal de vibração do exaustor industrial e anomalias inseridas.

Na aplicação da metodologia de detecção, as janelas são subdivididas em segmentos menores de 256 pontos, das quais 96 delas foram utilizadas no processo de detecção. As amostras obtidas dos primeiros quatro segundos de sinal são destinadas ao treinamento e ajuste dos modelos clusterizadores do *ensemble* realizado mediante estratégias de busca em grade e validação cruzada considerando 5 dobras, vide Tab. 8.4. Vale ressaltar que o processo de extração de características e redução de dimensionalidade são idênticos ao caso anterior.

Tabela 8.4: Hiperparâmetros ótimos dos clusterizadores para os dados do exaustor industrial.

Método	Hiperparâmetros
Hierárquico	$n\text{-clusters} = 4$
Dbscan	$eps = 0,5$; $min\text{-samples} = 7$
Gmm	$n\text{-components} = 4$; $covariance\text{-type} = \mathbf{full}$

Percebe-se que a metodologia se mostra robusta quanto à sua arquitetura, uma vez que maioria dos hiperparâmetros são iguais para as duas aplicações, exceto o *min-samples*, vide Tabs. 8.2 e 8.4. Ainda, manteve-se o mesmo fator percentual de divergência aceitável de 0,2. Os resultados para a metodologia de detecção de anormalidades segundo indicadores de desempenho estão apresentados na Tab. 8.5, lembrando que a metodologia é aplicada repetidamente sob as mesmas condições para estimação de média e do desvio-padrão em todas as aplicações.

Tabela 8.5: Resultados da detecção de anormalidades para os dados do exaustor industrial.

Método	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)
	Média (Desv.)	Média (Desv.)	Média (Desv.)	Média (Desv.)
<i>ensemble</i>	96,35 (2,6)	98,52 (2,04)	91,67 (6,03)	94,86 (3,75)

Com base nos resultados mostrados na Tab. 8.5, devido à natureza e as condições físicas e estruturais em que o exaustor se encontra, os sinais obtidos são mais propensos aos efeitos de vibração e ruído o que poderia prejudicar a aprendizagem e o desempenho da metodologia. No entanto, a utilização de apenas 3 componentes principais foi suficiente para garantir uma boa representação do problema, permitindo um desempenho satisfatório. Conforme esperado, os valores de falsos negativos tiveram um impacto maior nas respostas de predição. No entanto, a quantidade de falsos negativos não é expressiva o suficiente para inviabilizar futuras aplicações da metodologia de detecção.

8.2 Diagnóstico de Falhas em Rotores com Mancais Hidrodinâmicos

As subseções a seguir apresentam resultados obtidos pela metodologia proposta na detecção e classificação de falhas mecânicas no sistema rotativo proposto neste trabalho. Os conjuntos de dados são obtidos a partir do modelo matemático, por meio da tecnologia dos gêmeos digitais e de ensaios experimentais.

8.2.1 Dados Numéricos

Neste cenário, deseja-se avaliar a metodologia proposta por meio do conjunto de dados obtidos do sistema rotativo em questão sob a perspectiva dos gêmeos digitais, utilizando o modelo matemático. A análise numérica é relevante, pois possui capacidade de revelar padrões e informações que são fortes indicativos para cada um dos tipos de falha. Esses padrões podem ser identificados e interpretados de forma a auxiliar futuras aplicações, incluindo aquelas experimentais.

De acordo com a norma ISO e STANDARD (2009) destacada no estudo de Brito (2022), uma variação inferior a 3 dB nas amplitudes de respostas não indica uma mudança significativa no comportamento da máquina em termos de manutenção preditiva ou falha. Diante disso, os sinais numéricos são gerados aleatoriamente dentro dos limites aceitáveis de operação da

máquina real, conforme orientação do especialista. Essa abordagem permite a representação das falhas em diferentes níveis e melhora a robustez do classificador devido à maior variabilidade dos dados.

Para simulação do rotor em condição normal de operação, são implementadas variações de até 3 dB nos sinais de vibração. O desbalanceamento é obtido por meio da simulação da adição de diferentes massas, de 0,0015 kg a 0,01 kg, nos diferentes discos disponíveis no modelo. Para o desalinhamento combinado, desalinhamentos paralelos são considerados ao redor das direções X e Z , com distâncias compreendidas entre 1×10^{-5} m até 1×10^{-3} m e desalinhamento angular com variação de 1° a 5° . Por último, considera-se variações de profundidade para uma trinca localizada no nó 28 de 10% a 50%.

O conjunto de dados compreende 4 condições: normal, desbalanceado, desalinhado e com trinca, totalizando 512 amostras, 128 para cada condição. Uma amostra consiste de quatro sinais de vibração, provenientes dos dois planos de medição nas direções X e Z . Cada sinal de vibração é composto por características que abrangem os domínios do tempo, da frequência e tempo-frequência.

No domínio do tempo são extraídas as características de $R01$ até $R12$ apresentadas na Tab. 7.1. No domínio da frequência, além da energia absoluta ($R13$) e entropia ($R14$) do espectro, considera-se as amplitudes da componente da frequência de rotação e de seus harmônicos até a quarta ordem, representados por $A1X$, $A2X$, $A3X$ e $A4X$. Por fim, para o domínio tempo-frequência, são utilizadas sete sub-bandas *wavelets* para o cálculo de energia ($R15$). Um total de 100 características para cada amostra.

Os dados são divididos em grupos de treinamento e teste. Devido ao número de amostras disponíveis, o grupo de treinamento é composto por 70% dos dados, enquanto o grupo de teste contém 30% dos dados, ambos selecionados aleatoriamente. O conjunto de treinamento é utilizado tanto para seleção das características mais relevantes quanto para o ajuste dos hiperparâmetros de cada um dos classificadores, enquanto o conjunto de teste, subdividido em lotes menores, é utilizado para avaliar a capacidade do modelo de generalização em dados não vistos durante o treinamento.

Uma das contribuições deste trabalho é a seleção das melhores características através dos métodos de Relevância e SHAP. Aquelas de maior importância e ocorrência em ambos os métodos são selecionadas para compor o conjunto de dados ótimo. Essa estratégia tem potencial não de apenas melhorar a eficiência e interpretabilidade do modelo, mas também proporcionar uma

compreensão mais profunda dos resultados. Diante disso, o processo de seleção é essencial para aprimorar a precisão e capacidade de generalização do modelo, além de simplificar a interpretação dos resultados obtidos.

O método de Relevância avalia a importância de cada característica com base em sua capacidade de discriminação, atribuindo uma pontuação (pesos) com base no seu potencial de separação das classes. A Fig. 8.6 apresenta as 24 características, ou recursos, de maior relevância e suas respectivas pontuações segundo o método de Relevância.

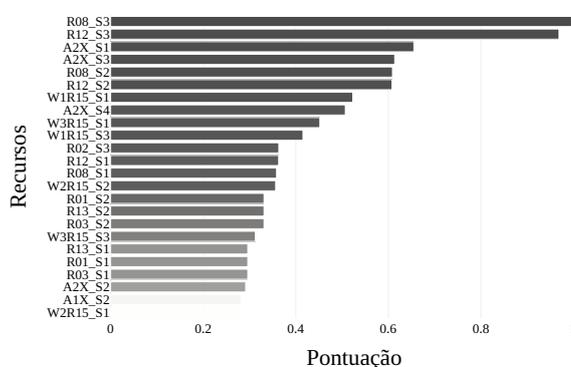
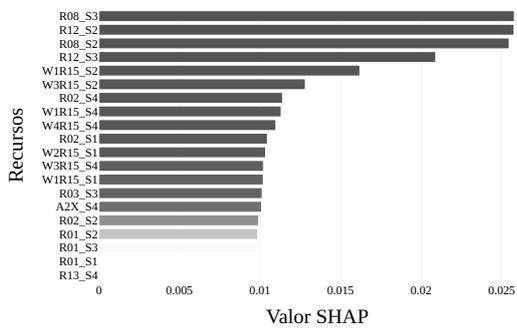


Figura 8.6: 24 melhores características segundo o método de Relevância nos dados numéricos.

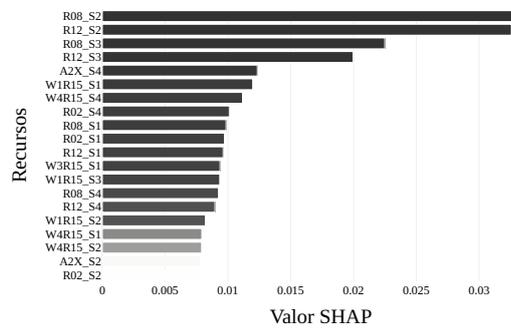
Conforme observado na Fig. 8.6, as melhores pontuações incluem 4 características principais em diferentes posições e direções de medição (os índices *S1* e *S2* são referentes ao primeiro plano de medição nas respectivas direções *X* e *Z* enquanto *S3* e *S4* são referentes ao segundo plano de medição nas respectivas direções *X* e *Z*). Destaque se dá às seguintes características: assimetria (*R08*), relação entre o valor da assimetria dividido pela curtose (*R12*), as amplitudes da componente *2X* (*A2X*) e energia absoluta para a *wavelet* de primeiro nível (*W1R15*).

Por outro lado, o método SHAP fornece uma abordagem explicável para entender como cada característica contribui na resposta obtida pelo modelo. Dessa forma, por meio de uma pontuação conhecida como valor SHAP permitirá avaliar a contribuição de cada característica e selecionar aquelas de maior relevância tanto para uma classe em específico quanto para cada classificador. São utilizados arquiteturas usuais para os modelos classificadores, ou seja, todos hiperparâmetros na configuração *default*.

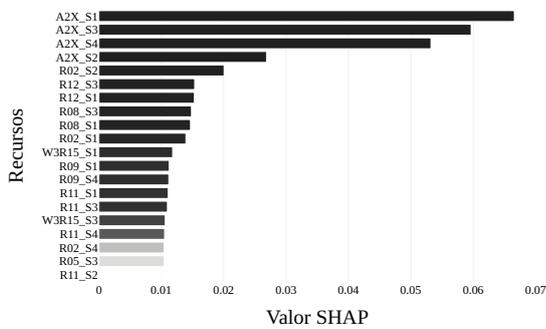
A Figura 8.7 mostra as 20 melhores características de acordo com seus respectivos valores SHAP para cada uma das falhas avaliadas. O método de aprendizado analisado foi o *k*-NN.



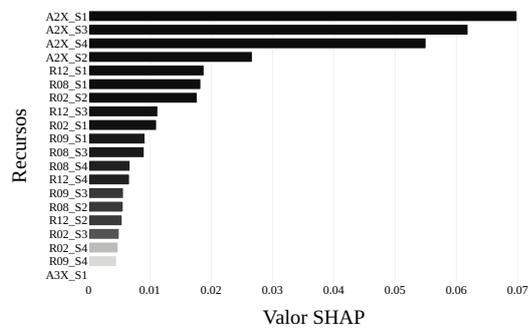
(a)



(b)



(c)



(d)

Figura 8.7: 20 melhores características segundo SHAP e k -NN para cada condição avaliada nos dados numéricos: (a) normal, (b) desbalanceado, (c) desalinhado, e (d) trinca.

A Figura 8.8 mostra as 20 melhores características de acordo com seus respectivos valores SHAP para cada falha avaliada. O método de aprendizado analisado foi uma SVM.

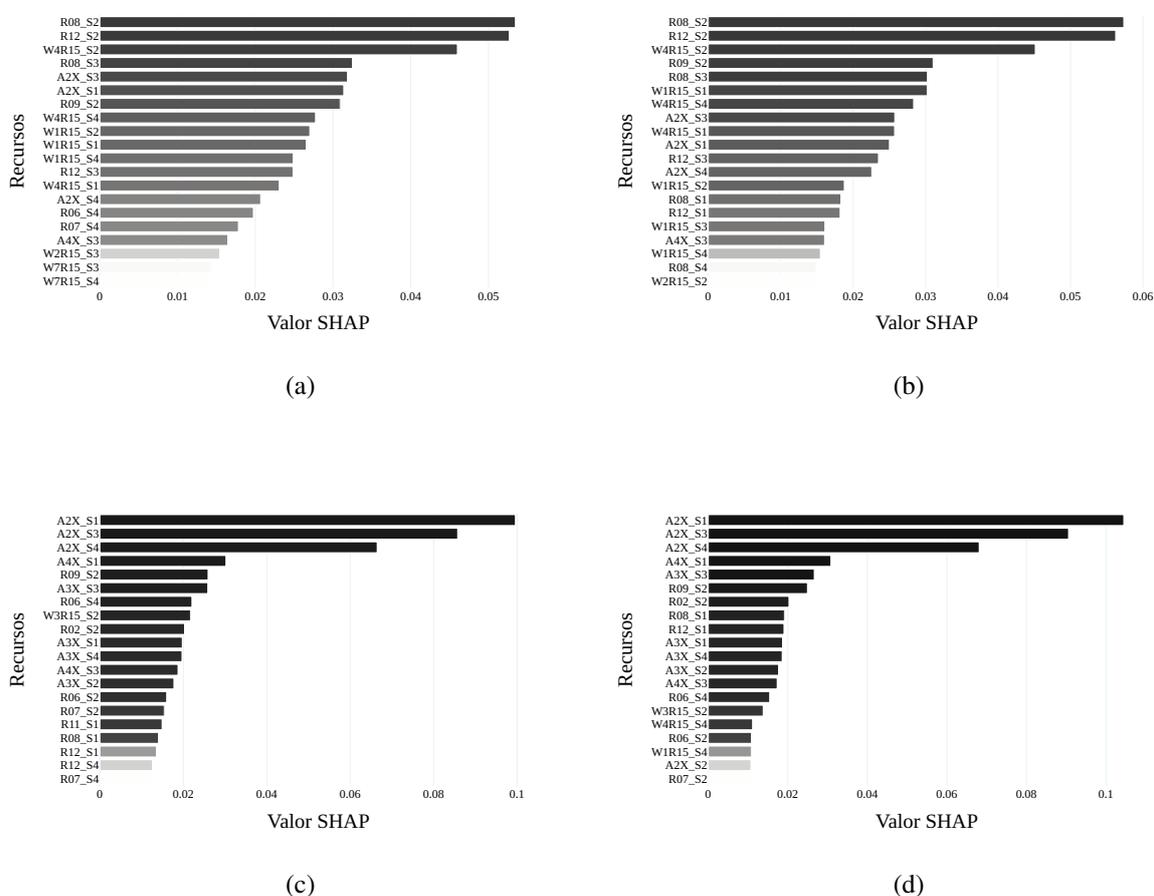


Figura 8.8: 20 melhores características segundo SHAP e SVM para cada condição avaliada nos dados numéricos: (a) normal, (b) desbalanceado, (c) desalinhado, e (d) trinca.

O comparativo das Figs. 8.6, 8.7 e 8.8 mostra que os *rankings* das características mais importantes apontadas pelos métodos de Relevância e SHAP em ambos os algoritmos de aprendizado são similares. Estes métodos podem revelar padrões nos dados que não são facilmente percebidos por um especialista, ou que, na maioria dos casos, não são óbvias à primeira vista. São informações valiosas que podem identificar quais características são mais discriminativas, evitar a utilização de dados redundantes ou irrelevantes e melhorar significativamente a precisão do diagnóstico.

Conforme ressaltado nos capítulos anteriores deste trabalho, na grande maioria dos casos, a caracterização de falhas em máquinas rotativas como desbalanceamento, desalinhamento e trinca está intimamente relacionada ao estudo e mapeamento da frequência de rotação e de seus múltiplos. Isso se deve ao fato de que muitos tipos de falhas em máquinas rotativas geram assinaturas específicas no domínio da frequência, que podem ser identificadas através de técnicas

de análise de vibração.

Diante do exposto acima, era esperado que as características baseadas nas componentes de frequência de rotação e seus múltiplos atingissem as maiores pontuações no processo de seleção. No entanto, conforme evidenciado nas Figs. 8.6, 8.7 e 8.8, essas características não atingiram pontuações excepcionais. Esse fato confirma a importância e necessidade da utilização de métodos para seleção de características nesse tipo de sistema rotativo. Uma vez que as falhas abordadas possuem comportamento similar, o desempenho no diagnóstico seria prejudicado caso fossem selecionados apenas as características usuais.

Um conjunto de dados contendo todas as características selecionadas ainda é impraticável devido à alta dimensão. Dessa forma, optou-se como uma estratégia válida, um conjunto de dados ótimo formado pelas 12 características mais frequentes nos *rankings* dos métodos de seleção, a saber: $R12_{S3}$, $R08_{S3}$, $A2X_{S1}$, $A2X_{S4}$, $R08_{S2}$, $R12_{S2}$, $A2X_{S3}$, $W1R15_{S1}$, $W1R15_{S3}$, $R12_{S1}$, $R08_{S1}$ e $W3R15_{S3}$.

Cabe ao especialista escolher o método de seleção ou a estratégia que melhor se relaciona com o problema em questão. Ressalta-se que, embora o método de Relevância seja generalista em comparação ao SHAP, que realiza uma análise mais detalhada para cada classe ou modelo de aprendizado abordado, ele não necessita de amostras rotuladas e é mais eficiente em termos de custo computacional, conforme mostrado na Tabela 8.6. Note que o método de Relevância requer apenas 2% do tempo computacional total exigido pelo SHAP.

Tabela 8.6: Tempo computacional para os métodos de Relevância e SHAP.

Método	Tempo [s]
Método de Relevância	66,49
SHAP	3942,15

O ajuste dos hiperparâmetros para cada um dos métodos de aprendizado foi realizado mediante estratégias de busca em grade e validação cruzada considerando 8 dobras. Para o método k -NN, ajustou-se apenas o hiperparâmetro número de vizinhos (n -neighbors), enquanto que, na SVM, consideraram-se os parâmetros γ da função *kernel* e o fator de suavização (C). A Tab. 8.7 apresenta os hiperparâmetros ótimos para cada uma dos classificadores.

Tabela 8.7: Hiperparâmetros ótimos dos classificadores para os dados numéricos.

Método	Hiperparâmetros
k -NN	n -neighbors = 4
SVM	$\gamma = 0,01$; $C = 100$

Os resultados para a metodologia de identificação de falhas segundo indicadores de desempenho estão apresentadas na Tab. 8.8. Vale ressaltar que para assegurar resultados confiáveis e consistentes, o grupo de testes é dividido em 10 subconjuntos menores e a metodologia é aplicada repetidamente sob as mesmas condições para estimação de média e do desvio-padrão. O tempo médio gasto em cada análise também é estimado.

Tabela 8.8: Resultados da classificação de falhas nos dados numéricos.

	Acurácia (%) Média (Desv.)	Precisão (%) Média (Desv.)	Recall (%) Média (Desv.)	F1-score (%) Média (Desv.)	Tempo [s] Média (Desv.)
k-NN	99,10 (0,48)	99,12 (1,62)	99,16 (1,07)	99,13 (1,18)	0,094 (0,24)
SVM	99,77 (0,38)	98,94 (1,28)	99,64 (0,44)	99,29 (0,45)	0,078 (0,61)

Os altos percentuais alcançados nos indicadores apresentados na Tabela 8.8 mostram o ótimo desempenho da abordagem proposta quando aplicada para classificação de falhas a partir de dados numéricos. Os dois classificadores apresentaram boas taxas de acerto, destacando o baixo custo computacional em ambos. As pontuações obtidas no indicador *F1-score* mostra uma leve vantagem do método SVM sobre o k -NN.

A interpretação do resultado fornecido pelo modelo de diagnóstico é crucial em aplicações industriais, pois permite que especialistas tomem decisões assertivas e de forma transparente. Neste trabalho, o método SHAP foi empregado na etapa de seleção de características e também será utilizado como uma ferramenta de explicabilidade. Isso permitirá avaliar o processo de aprendizagem, compreendendo quais características são mais relevantes e como cada uma contribuiu para a resposta do modelo de diagnóstico.

A Figura 8.9 apresenta de forma resumida o *ranking* das características revelando sua contribuição na resposta final em cada um dos métodos de aprendizado em acordo com o método SHAP enquanto uma ferramenta de explicabilidade. Cada linha apresenta o percentual da contribuição de uma característica (ou recurso) na resposta de cada classificador, conforme indicado pelo valor SHAP. A contribuição é visualizada pelo comprimento (base) de cada barra horizontal, com diferentes condições de falha representadas por cores específicas.

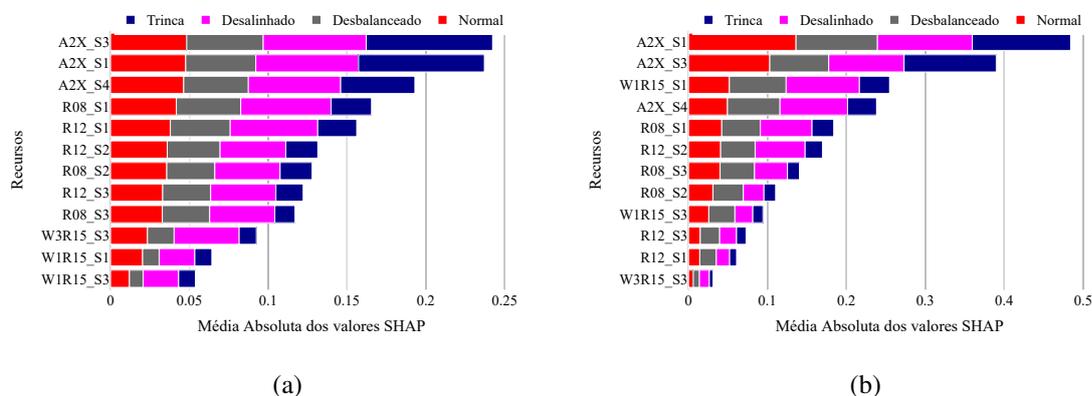


Figura 8.9: Importância SHAP em (a) k -NN e (b) SVM para os dados numéricos.

Conforme visto na Fig. 8.9 (a) e (b), a amplitude da componente 2X nos diferentes planos de medição e direções apresentou maior relevância para todas as condições de falhas avaliadas. Para exemplificação, na Fig. 8.9 (b), a característica $A2X_{S1}$ apresentou maior contribuição para a resposta da SVM com valor SHAP médio de 0,485, dos quais 0,14 (28,87%) estão relacionados à condição normal de operação, 0,1 (20,62%) ao desbalanceamento, 0,12 (24,74%) ao desalinhamento e 0,125 (25,77%) à presença de trinca.

8.2.2 Dados Experimentais

Neste cenário, deseja-se avaliar a metodologia tanto para detecção quanto a identificação das seguintes condições de operação; normal, desbalanceado e desalinhado. Considera-se sinais de vibração coletados em ensaios experimentais realizados no sistema rotativo da bancada de testes. A velocidade de rotação foi mantida constante em 1228,8 rev/min. Cada amostra consiste em quatro arquivos individuais de sinais de vibração registrados para cada condição nos dois sensores de medição nas direções X e Z . Cada arquivo compreende 1 s de aquisição com 2048 pontos medidos pelo analisador Agilent® modelo 35670A em intervalos de 0,0005 segundos, aproximadamente.

O desbalanceamento foi imposto no sistema rotativo adicionando massas desbalanceadoras nos discos D_4 , D_5 e D_6 . A Tab. 8.9 mostra alguns valores para as massas e suas respectivas posições angulares utilizadas nos ensaios. Já o desalinhamento paralelo e angular se deu por meio de duas abordagens: (i) inserção de chapas de aço de 0,25 mm até 0,55 mm sob os pés dianteiros ou traseiros da bancada; e (ii) modificação dos reguladores alinhadores axiais pre-

sentes na bancada, gerando desvios de 0,52 mm até 1,04 mm.

Tabela 8.9: Condições impostas ao sistema rotativo para simulação do desbalanceamento.

Condição	Massa desbalanceadora			Posição angular
	D_4	D_5	D_6	
1	1,5 g		1,5 g	-60°
2	3 g		3 g	-60°
3	3 g	6,15 g	3 g	-60°
4	5,4 g	6,15 g	5,4 g	-160°
5		7,85 g		-60°
6	5,4 g	7,85 g	5,4 g	60°

Um total de 310 amostras foram coletadas experimentalmente, das quais 112 correspondem à condição normal de operação da máquina, 102 para o desbalanceamento e 96 amostras para o desalinhamento. Vale salientar os sinais de vibração não possuem correlação temporal entre si, ou seja, não foram coletados em sequência. Mediante os *insights* obtidos numericamente, somente as características selecionadas durante a análise do modelo matemático pelos métodos de Relevância e SHAP foram extraídas dos sinais de vibração para a formação do conjunto de dados experimental. Posteriormente, para a avaliação da metodologia de detecção e de identificação, este conjunto é subdividido em grupos de treinamento, composto por 70% dos dados, e de teste, contendo os 30% restantes.

Na indústria, os dados disponíveis geralmente se referem às condições normais de operação do sistema rotativo, já que um histórico de dados com falhas implicaria em operar os equipamentos deliberadamente em condições defeituosas, o que é impraticável e indesejável. Diante disso, o ajuste e treinamento dos métodos clusterizadores que constituem o *ensemble* são realizados apenas com amostras normais mediante estratégias de busca em grade e validação cruzada considerando 10 dobras. Os hiperparâmetros ótimos são mostrados na Tab. 8.10.

Tabela 8.10: Hiperparâmetros ótimos dos clusterizadores para os dados experimentais.

Método	Hiperparâmetros
Hierárquico	$n\text{-clusters} = 6$
DbSCAN	$eps = 0,5; min\text{-samples} = 7$
Gmm	$n\text{-components} = 6; covariance\text{-type} = \mathbf{full}$

A Tabela 8.11 mostra os resultados para a metodologia de detecção segundo os indicadores de desempenho, considerando um fator percentual de divergência aceitável de 0,2. A

metodologia é aplicada repetidamente sob as mesmas condições para estimação de média e do desvio-padrão. O tempo médio gasto em cada análise também é estimado.

Tabela 8.11: Resultados experimentais para detecção de falhas.

Método	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)	Tempo [s]
	Média (Desv.)				
<i>ensemble</i>	94,73 (0,042)	95,21 (0,086)	95,71 (0,034)	95,17 (0,11)	3,65 (1,9)

Os resultados da Tab. 8.11 mostram o ótimo desempenho da metodologia na detecção de amostras anômalas. A grande maioria dos indicadores apresentaram uma precisão de aproximadamente 95%, um resultado expressivo, considerando que, em cenários experimentais, as taxas de acerto tendem a ser menores. Apesar da incidência de alguns falsos positivos e negativos, a metodologia possui notável capacidade de distinguir padrões incomuns a partir de dados experimentais e, dessa forma, pode auxiliar diretamente na tomada de decisões acerca da saúde da máquina.

Dada a natureza não supervisionada dos métodos clusterizadores e a similaridade dos sintomas das falhas avaliadas, a metodologia de detecção é insuficiente para auxiliar o especialista na identificação de possíveis falhas existentes no grupo das amostras consideradas como anômalas. Aqui, métodos de aprendizado supervisionado são empregados. Este trabalho, optou-se por utilizar dois métodos tradicionais, o k -NN e SVM, para classificação das falhas avaliadas.

Diante do exposto acima, o conjunto de dados experimentais é novamente subdividido, aleatoriamente, em grupos de treinamentos (70%) e de testes (30%). O ajuste dos modelos de diagnóstico foi realizado mediante estratégias de busca em grade e validação cruzada considerando 10 dobras. A Tabela 8.12 mostra os hiperparâmetros ótimos encontrados. Para avaliação, o conjunto de testes é dividido em 10 subconjuntos e a metodologia é aplicada repetidamente sob as mesmas condições.

Tabela 8.12: Hiperparâmetros ótimos dos classificadores para os dados experimentais.

Método	Hiperparâmetros
k -NN	$n-neighbors = 3$
SVM	$\gamma = 10; C = 0,0001$

Os resultados para a metodologia segundo indicadores de desempenho bem como o tempo computacional para cada um dos classificadores estão apresentadas na Tab. 8.13, bem como os

tempos computacionais. Conforme observado, ambos classificadores apresentaram excelentes taxas de acertabilidade em um cenário totalmente experimental. A ligeira diferença entre alguns indicadores mostra que o método k -NN está mais propenso à presença de falsos positivos e negativos.

Tabela 8.13: Resultados experimentais para classificação de falhas.

	Acurácia (%) Média (Desv.)	Precisão (%) Média (Desv.)	Recall (%) Média (Desv.)	F1-score (%) Média (Desv.)	Tempo [s] Média (Desv.)
k-NN	98,93 (3,02)	98,84 (3,26)	99,09 (2,55)	98,82 (3,32)	0,549 (0,5)
SVM	99,34 (1,86)	99,29 (2,01)	99,39 (1,71)	99,28 (2,02)	0,542 (0,44)

A Figura 8.10 mostra a importância das características para cada classificador de acordo com o SHAP, enquanto ferramenta de explicabilidade. Percebe-se que as características de maior relevância em ambos os classificadores foram a assimetria e a relação entre o seu valor dividido pela curtose. Este último avalia o grau de assimetria em uma distribuição de dados em relação à sua curtose. No entanto, apesar de indicarem a presença de falha e sua correta caracterização, essas características não estão intimamente relacionados a um tipo de falha em específico dificultando o diagnóstico.

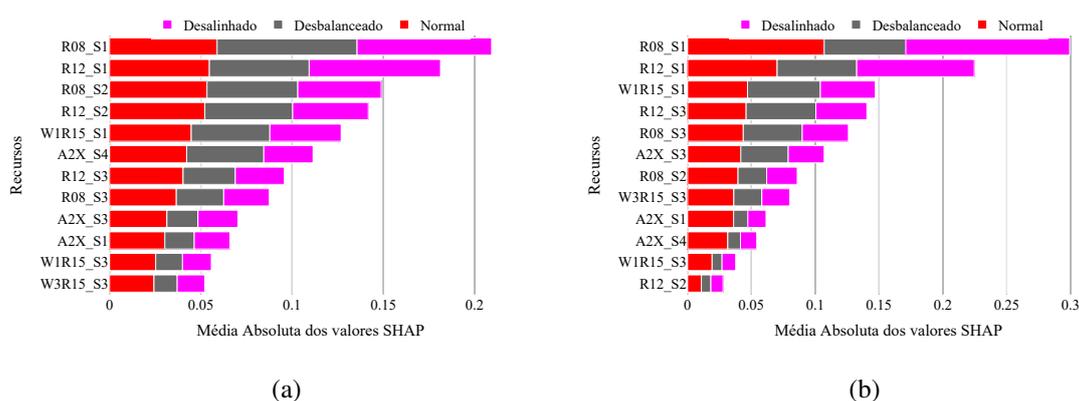


Figura 8.10: Importância SHAP em (a) k -NN e (b) SVM para os dados experimentais.

Embora as características exploradas no conjunto de dados experimentais sejam as mesmas que foram selecionadas para o numérico, um comparativo entre as Figs. 8.9 e 8.10 mostra que as pontuações de importância SHAP e, conseqüentemente, o *ranking* apresentaram mudanças. A observação de que os classificadores mantiveram excelentes resultados, conforme mostrado nas Tabs. 8.8 e 8.13, destaca a flexibilidade e eficácia da metodologia empregada, reforçando a

confiabilidade.

Alterações nas contribuições de cada característica eram esperadas, dado que as falhas avaliadas apresentam sintomas semelhantes, dificultando a classificação com base em características específicas para cada tipo de falha retratadas na literatura. Diante dessa situação, o classificador busca novas relações para a tomada de decisão, muitas vezes divergindo das associações usuais esperadas. Assim, a aplicação de ferramentas de explicabilidade desempenha um papel significativo, permitindo uma compreensão mais profunda sobre a contribuição de cada característica e as razões pelas quais os classificadores tomam suas decisões.

CAPÍTULO IX

CONCLUSÕES E PERSPECTIVAS FUTURAS

Dada a importância das máquinas rotativas na indústria moderna, esta Tese de Doutorado concentrou-se na elaboração de uma metodologia para um sistema de monitoramento e diagnóstico de falhas em máquinas rotativas baseada na combinação entre técnicas de análise de vibração e métodos de aprendizado visando uma ferramenta que permita ações de manutenção proativas e redução do risco de paradas não programadas, garantindo maior eficiência e durabilidade operacional.

Inicialmente foi realizada uma revisão bibliográfica acerca de recentes estudos que investigaram aplicações de modelos inteligentes na detecção e identificação de falhas em sistemas rotativos baseados em sinais de vibração. Foram apresentados estudos científicos que exploraram abordagens tradicionais, tanto supervisionadas quanto não supervisionadas, nos domínios do tempo, frequência e tempo-frequência. A partir desta revisão, constatou-se recentes avanços, tendências e as principais dificuldades enfrentadas pela comunidade acadêmica e pela indústria. Embora a literatura contenha uma gama de abordagens de diagnóstico, esta Tese de Doutorado ofereceu notável contribuição notável ao diagnóstico de falhas como desbalanceamento, desalinhamento e trincas em um sistema rotativo suportados por mancais hidrodinâmicos. Devido à complexidade e sensibilidade deste tipo de sistema em relação à presença e aos sintomas das falhas avaliadas, as metodologias empregadas demandam maior atenção.

A representação matemática de rotores se deu por modelos de Elementos Finitos. Dessa forma, a formulação associada às matrizes de massa, rigidez, amortecimento, do efeito giroscópico, do desbalanceamento, e outros, foi apresentada. Os mancais hidrodinâmicos cilíndricos foram modelados a partir de uma metodologia não linear, um modelo termohidrodinâmico

formulado a partir das equações simplificados de Navier-Stokes. Os coeficientes de rigidez e amortecimento foram estimados através de perturbações nas forças hidrodinâmicas oriundas do campo de pressão atuante nesses componentes.

Os modelos matemáticos foram implementados tomando como base uma bancada de testes munida de um sistema rotativo flexível suportado por mancais hidrodinâmicos, especialmente configurada para a aplicação e validação da metodologia proposta. Todas as etapas foram detalhadas, incluindo informações sobre as partes constituintes do equipamento, o ajuste e validação do modelo matemático (em Elementos Finitos) construído com base nos sinais experimentais medidos diretamente no equipamento. O ajuste foi realizado com o rotor utilizando FRFs obtidas a partir de diferentes posições de excitação e medição. Considerou-se que o efeito giroscópico do sistema não é grande o suficiente para comprometer a identificação dos parâmetros considerados desconhecidos estimados por um método de otimização evolutivo, a Evolução Diferencial. Quanto às respostas ao desbalanceamento, quando comparadas com as experimentais, apresentaram pouca discrepância, como já era esperado devido ao desalinhamento residual ou possíveis deformidades e imperfeições na pista dos mancais hidrodinâmicos. Estes resultados mostraram a capacidade do modelo construído.

Na sequência, foram explorados modelos matemáticos para representação de falhas em sistemas rotativos, com destaque à modelagem do desalinhamento em rotores com acoplamentos flexíveis e métodos de modelagem do fenômeno de *breathing*, característico de trincas em eixos rotativos horizontais flexíveis. O modelo de Mayes foi considerado como o mais adequado, oferecendo um comportamento consistente quando comparado a outros modelos já bem estabelecidos na literatura, mas com um custo computacional significativamente inferior. Análises numéricas envolvendo as falhas avaliadas foram realizadas. Os sinais de vibrações no domínio do tempo e da frequência mostraram que os efeitos das falhas no modelo matemático seguem a mesma tendência observada experimentalmente. Em ambos os casos, observou-se variações nas amplitudes do sinal de vibração, bem como o surgimento e a evolução de múltiplos da frequência de rotação ao longo do espectro. Dessa forma, os efeitos das falhas observados nos ensaios experimentais podem ser replicados no modelo matemático.

Uma metodologia inteligente de diagnóstico de falhas em sistemas rotativos com potencial aplicação na indústria foi apresentada. Esforços foram dedicados na implementação de um modelo de Inteligência Artificial Explicável (XAI) embasado na exploração de sinais de vibração envolvendo a utilização de técnicas para extração e seleção de características, redução de di-

mensionalidade, reconhecimento de falhas por meio de métodos de aprendizado e posterior aplicação de ferramentas de explicabilidade. A metodologia proposta foi avaliada numérica e experimentalmente a partir de dados obtidos pelo modelo matemático ajustado e por meio de ensaios experimentais realizados em sistemas rotativos.

A detecção de anormalidades compreendeu a aplicação do voto majoritário entre métodos de clusterização hierárquica, o DBSCAN e de mistura gaussiana. Dada a natureza não supervisionada dos métodos clusterizadores e a similaridade dos sintomas das falhas avaliadas, a metodologia de detecção é insuficiente para auxiliar o especialista na identificação de possíveis falhas existentes no grupo das amostras consideradas como anômalas. Diante disso, métodos tradicionais de aprendizado supervisionado para classificação, como o k -NN e SVM, são empregados. Este trabalho, optou-se por utilizar dois métodos tradicionais, o k -NN e SVM, para classificação das falhas avaliadas. O ajuste dos hiperparâmetros para todos os métodos de aprendizado envolvidos foi realizado mediante estratégias de busca em grade com validação cruzada.

Em um primeiro momento, a metodologia proposta para detecção de anormalidades foi avaliada segundo dados de ensaios experimentais foram utilizados em dois sistemas rotativos: um rotor suportado por mancais magnéticos e um exaustor industrial. Foi simulado um diagnóstico em tempo real com atualização constante dos sinais, que incluíam diferentes avarias, desde falhas mecânicas até variações de velocidade e impactos. A abordagem baseou-se no emprego de características estatísticas usuais pelos especialistas. A metodologia proposta alcançou uma média para o indicador *F1-score* superior a 94% em ambas as aplicações.

Em um segundo momento, as avaliações da metodologia se concentraram nos dados obtidos a partir do modelo matemático ajustado do sistema rotativo com mancais hidrodinâmicos e nos ensaios realizados na bancada de teste experimental. Dado os sinais de vibração oriundos do modelo matemático, foram aplicadas técnicas de extração de características nos domínios do tempo, frequência e tempo-frequência. Métodos de seleção foram empregados com ênfase no equilíbrio entre representatividade e baixo custo computacional. As características de maior relevância, identificadas pelos métodos de Relevância e SHAP, foram selecionadas com base em pesos e pontuações. Os métodos revelaram padrões e relações relevantes nos dados que podem não ser facilmente perceptíveis à primeira vista, dada à sua complexidade.

Os métodos de aprendizado supervisionado foram aplicados nos dados numéricos para classificação das diferentes condições de operação avaliadas: normal, desbalanceamento, desalinhamento e com trinca. As taxas de acerto mostram excelente desempenho dos métodos

empregados com destaque ao indicador *F1-score* de 99,13% para o *k*-NN e 99,29% para o SVM. Por fim, o método SHAP foi empregado enquanto uma ferramenta de explicabilidade para interpretabilidade, evidenciando as contribuições de cada característica para o resultado final de cada um dos métodos de aprendizado. Diante dos dados abordados, a seleção de características pode assegurar maior robustez ao modelo de diagnóstico, mesmo nos cenários em que os sintomas das falhas são similares ou até mesmo se sobrepõem.

Em posse dos dados obtidos a partir dos sinais de vibração coletados na bancada de teste experimental e extraindo somente as melhores características já verificadas pelos métodos de Relevância e SHAP mediante o modelo matemático, a metodologia de diagnóstico foi avaliada experimentalmente segundo condições normais de operação, desbalanceamento e desalinhamento.

O *ensemble* formado por métodos de clusterização foi empregado para a detecção de falhas. Por meio do voto majoritário entre os clusterizadores alcançou-se um excelente desempenho na identificação de dados normais ou com algum tipo de falha, com destaque para o indicador *F1-score*, superior a 95%. Posteriormente, os métodos de aprendizado foram aplicados ao conjunto de dados. O método *k*-NN alcançou um *F1-score* de 98,82%, enquanto a SVM obteve 99,28%, sugerindo uma incidência ligeiramente maior de falsos positivos ou negativos no primeiro método.

O método SHAP foi aplicado como ferramenta de explicabilidade. A similaridade nos sintomas das falhas avaliadas torna difícil a identificação de uma falha específica utilizando uma única característica, como é comumente feito na literatura. Dada essa semelhança, o classificador busca novas relações para a tomada de decisão com base em informações diferentes do esperado. As excelentes taxas de acerto dos métodos de aprendizado, apesar das mudanças no *ranking* e na pontuação SHAP das características nos conjuntos numérico e experimental, destacam a flexibilidade e eficiência da metodologia de diagnóstico.

As altas taxas de acerto dos modelos, combinadas com sua interpretabilidade, tornam a metodologia proposta uma ferramenta promissora para o monitoramento e diagnóstico de falhas em sistemas rotativos. A aplicação dessa metodologia na indústria pode impactar positivamente o monitoramento de máquinas e equipamentos. Em ambientes industriais, onde a manutenção preditiva é crucial para evitar paradas não programadas e reduzir custos operacionais, a capacidade de identificar e interpretar falhas com precisão é essencial. A integração desses modelos de aprendizado de máquina com ferramentas de explicabilidade permite que os engenheiros não apenas confiem nas previsões, mas também compreendam as razões por trás dessas previsões,

facilitando a tomada de decisões informadas e a implementação de ações corretivas eficazes.

Além disso, a adaptabilidade da metodologia para diferentes tipos de máquinas e condições operacionais, junto com a possibilidade de atualização contínua dos modelos com novos dados, assegura que o sistema permaneça eficaz e relevante em um ambiente industrial. Dessa forma, a metodologia não apenas melhora a confiabilidade dos sistemas rotativos, mas também contribui para a eficiência geral e a segurança das operações industriais.

Com base na experiência adquirida no desenvolvimento desta Tese de Doutorado, os seguintes pontos deverão ser investigados em trabalhos futuros:

- Avaliar a confiabilidade da metodologia proposta por meio da realização de testes estatísticos rigorosos, assegurando robustez e eficácia para uma posterior aplicação na indústria;
- Investigar novas falhas, como ovalização e problemas de lubrificação, que são comuns e particulares em mancais hidrodinâmicos. Neste caso, novos dados oriundos de ensaios experimentais e modelos digitais deverão ser adquiridos e analisados;
- Refinamento dos métodos de aprendizado e dos processos utilizados por meio da adaptação de domínio, utilização de dados sintéticos e aprendizagem por transferência associadas a métodos de interpretabilidade;
- Realizar estudos em Inteligência Artificial Explicável (XAI) para melhor compreensão de como os modelos relacionam as características de entrada ao diagnóstico. A aplicação de técnicas XAI proporcionará *insights* sobre a importância de cada característica, identificando padrões e relações nos dados que podem não ser facilmente perceptíveis, permitindo assim o refinamento dos modelos de diagnóstico, tornando-os mais robustos e adaptáveis a diferentes cenários e tipos de falhas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMS, M. L. *Rotating machinery vibration: from analysis to troubleshooting*. Boca Raton, EUA: CRC Press, 2009. Disponível em: <https://doi.org/10.1201/9781439847558>.
- AGGARWAL, C. C.; REDDY, C. K. Data clustering. *Algorithms and applications*. Chapman&Hall/CRC Data mining and Knowledge Discovery series, Londra, Citeseer, 2014.
- AGGARWAL, N. et al. Mean based relief: an improved feature selection method based on relief. *Applied Intelligence*, Springer, v. 53, n. 19, p. 23004–23028, 2023. Disponível em: <https://doi.org/10.1007/s10489-023-04662-w>.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. *Machine learning*, Springer, v. 6, p. 37–66, 1991. Disponível em: <https://doi.org/10.1007/BF00153759>.
- AL-HUSSAIN, K.; REDMOND, I. Dynamic response of two rotors connected by rigid mechanical coupling with parallel misalignment. *Journal of Sound and vibration*, Elsevier, v. 249, n. 3, p. 483–498, 2002. Disponível em: <https://doi.org/10.1006/jsvi.2001.3866>.
- ALPAYDIN, E. *Introduction to machine learning*. Massachusetts, EUA: MIT press, 2020.
- ALVES, D. S. *Investigação do efeito térmico no comportamento dinâmico de mancais hidrodinâmicos*. 144 p. Tese (Doutorado) — Universidade Estadual de Campinas, 2011.
- AMRUTHNATH, N.; GUPTA, T. A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. *5th international conference on industrial engineering and applications (ICIEA)*, p. 355–361, 2018. Disponível em: <https://doi.org/10.1109/IEA.2018.8387124>.
- ANDERSON, T. L. *Fracture mechanics: fundamentals and applications*. Boca Raton, EUA: CRC press, 2017. Disponível em: <https://doi.org/10.1201/9781315370293>.
- ARCO-VERDE, M. M. *Identificação de falhas em sistemas rotativos empregando técnicas não-lineares*. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, 2008.
- BACHSCHMID, N.; PENNACCHI, P.; TANZI, E. *Cracked rotors: a survey on static and dynamic behaviour including modelling and diagnosis*. Springer Science & Business Media, 2010. Disponível em: <https://doi.org/10.1007/978-3-642-01485-7>.
- BARBOSA, J. S. *Análise de modelos termohidrodinâmicos para mancais de unidades geradoras Francis*. Dissertação (Mestrado), 2018.

- BARBOSA, J. S. *Comportamento Dinâmico de Mancais Segmentados Axiais sob Regime de Lubrificação Híbrido*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2023.
- BISHOP, C. M. *Pattern recognition and machine learning*. Springer-Verlag, Berlin, Heidelberg: Springer, 2006.
- BORGES, F. A. et al. Feature extraction and power quality disturbances classification using smart meters signals. *IEEE Transactions on Industrial Informatics*, IEEE, v. 12, n. 2, p. 824–833, 2015. Disponível em: <https://doi.org/10.1109/TII.2015.2486379>.
- BREGION, D. G. *Desenvolvimento de um modelo termohidrodinâmico para análise em mancais segmentados*. Tese (Doutorado) — Universidade Estadual de Campinas, 2012.
- BRITO, L. C. *Explainable artificial intelligence approaches for fault diagnosis in rotating machinery*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2022.
- CABRAL, L. D. d. S. *Balanceamento de Máquinas Rotativas utilizando Redes Neurais*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, 2023.
- CAPONE, G. Orbital motions of rigid symmetric rotor supported on journal bearings. *La Meccanica Italiana*, v. 199, n. 199, p. 37–46, 1986.
- CARVALHO, V. N. *Balanceamento de máquinas rotativas com eixos flexíveis utilizando metamodelos Kriging*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2022.
- CAVALLINI Jr., A. *Detecção e Identificação de Trincas Transversais Incipientes em Eixos Horizontais Flexíveis de Máquinas Rotativas*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2013.
- CAVALLINI Jr., A. et al. Experimental uncertainty analysis of a flexible rotor supported by fluid film bearings. *Proceedings of the International Symposium on Dynamic Problems of Mechanics (DINAME'15)*, p. 1487–1504, 2015. Disponível em: <https://doi.org/10.1590/1679-78251582>.
- CAVALLINI Jr., A. A. et al. Dynamic analysis of a flexible rotor supported by hydrodynamic bearings with uncertain parameters. *Meccanica*, Springer, v. 52, p. 2931–2943, 2017. Disponível em: <https://doi.org/10.1007/s11012-017-0616-2>.
- CHEN, J. et al. A novel self-learning feature selection approach based on feature attributions. *Expert Systems with Applications*, Elsevier, v. 183, p. 115–219, 2021. Disponível em: <https://doi.org/10.1016/j.eswa.2021.115219>.
- CHENG, Y. et al. Multi-dimensional recurrent neural network for remaining useful life prediction under variable operating conditions and multiple fault modes. *Applied Soft Computing*, Elsevier, v. 118, p. 108507, 2022. Disponível em: <https://doi.org/10.1016/j.asoc.2022.108507>.
- CIABATTONI, L. et al. Statistical spectral analysis for fault diagnosis of rotating machines. *IEEE Transactions on Industrial Electronics*, IEEE, v. 65, n. 5, p. 4301–4310, 2017. Disponível em: <https://doi.org/10.1109/TIE.2017.2762623>.
- DARPE, A. K.; GUPTA, K.; CHAWLA, A. Coupled bending, longitudinal and torsional vibrations of a cracked rotor. *Journal of sound and vibration*, Elsevier, v. 269, n. 1-2, p. 33–60, 2004. Disponível em: [https://doi.org/10.1016/S0022-460X\(03\)00003-8](https://doi.org/10.1016/S0022-460X(03)00003-8).

DAS, O.; DAS, D. B. Smart machine fault diagnostics based on fault specified discrete wavelet transform. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, Springer, v. 45, n. 1, p. 55, 2023. Disponível em: <https://doi.org/10.1007/s40430-022-03975-0>.

DAS, O.; DAS, D. B.; BIRANT, D. Machine learning for fault analysis in rotating machinery: A comprehensive review. *Heliyon*, Elsevier, 2023. Disponível em: <https://doi.org/10.1016/j.heliyon.2023.e17584>.

DASH, M.; ONG, Y.-S. Relief-c: Efficient feature selection for clustering over noisy data. In: IEEE. *2011 IEEE 23rd international conference on tools with artificial intelligence*. Boca Raton, EUA, 2011. p. 869–872. Disponível em: <https://doi.org/10.1109/ICTAI.2011.135>.

DIAS, A. L. *Diagnóstico de anomalias em aplicações de acionamento de motores elétricos a partir de dados de processo de rede PROFINET e aprendizagem de máquinas*. Tese (Doutorado) — Universidade de São Paulo, 2019.

DIMAROGONAS, A. D.; PAIPETIS, S. A.; CHONDROS, T. G. *Analytical methods in rotor dynamics*. [S.l.]: Springer Science & Business Media, 1983.

DOWSON, D. A generalized reynolds equation for fluid-film lubrication. *International Journal of Mechanical Sciences*, Elsevier, v. 4, n. 2, p. 159–170, 1962.

ESTER, M. et al. A density-based algorithm for discovering clusters in large spatial databases with noise. v. 96, n. 34, p. 226–231, 1996.

FERREIRA, B. F. *Detecção de trincas em eixos rotativos através de medição de vibrações*. Dissertação (Mestrado) — Universidade de Brasília, 2010.

FU, R. et al. A new feature selection method based on relief and svm-rfe. *12th International Conference on Signal Processing (ICSP)*, Hangzhou, China, p. 1363–1366, 2014. Disponível em: <https://doi.org/10.1109/ICOSP.2014.7015222>.

GARCIA, M. et al. Efficiency assessment of induction motors operating under different faulty conditions. *IEEE Transactions on Industrial Electronics*, IEEE, v. 66, n. 10, p. 8072–8081, 2018. Disponível em: <https://doi.org/10.1109/TIE.2018.2885719>.

GASCH, R. A survey of the dynamic behaviour of a simple rotating shaft with a transverse crack. *Journal of sound and vibration*, Elsevier, v. 160, n. 2, p. 313–332, 1993. Disponível em: <https://doi.org/10.1006/jsvi.1993.1026>.

GEBREYESUS, Y. et al. Machine learning for data center optimizations: Feature selection using shapley additive explanation (shap). *Future Internet*, MDPI, v. 15, n. 3, p. 88, 2023. Disponível em: <https://doi.org/10.3390/fi15030088>.

GÉRON, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. [S.l.]: O'Reilly Media, 2019.

IMBERT, J.-F. *Analyse des structures par éléments finis*. [S.l.: s.n.], 1995.

ISHIDA, Y.; YAMAMOTO, T. *Linear And Nonlinear Rotordynamics: a modern treatment with applications*. John Wiley & Sons, 2013. Disponível em: <https://doi.org/10.1002/9783527651894>.

ISO, B.; STANDARD, B. Mechanical vibration—evaluation of machine vibration by measurements on non-rotating parts. *Evaluation of machine vibration by measurements on non-rotating parts*, 2009.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, The Royal Society Publishing, v. 374, n. 2065, p. 20150202, 2016. Disponível em: [⟨https://doi.org/10.1098/rsta.2015.0202⟩](https://doi.org/10.1098/rsta.2015.0202).

KIRA, K.; RENDELL, L. A. The feature selection problem: Traditional methods and a new algorithm. *Proceedings of the tenth national conference on Artificial intelligence*, Atlanta, p. 129–134, 1992.

KIRA, K.; RENDELL, L. A. A practical approach to feature selection. In: *Machine learning proceedings 1992*. Burlington: Morgan Kaufmann, 1992. p. 249–256. Disponível em: [⟨https://doi.org/10.1016/B978-1-55860-247-2.50037-1⟩](https://doi.org/10.1016/B978-1-55860-247-2.50037-1).

LALANNE, M.; FERRARIS, G. *Rotordynamics prediction in engineering*. Chichester: John Wiley, 1998. v. 2.

LALLEMENT, G.; LECOANET, H.; Steffen Jr, W. Vibrations de rotors sur paliers à matrice de raideur non symétrique. *Mechanism and Machine Theory*, Elsevier, v. 17, n. 1, p. 47–55, 1982. Disponível em: [⟨https://doi.org/10.1016/0094-114X\(82\)90023-4⟩](https://doi.org/10.1016/0094-114X(82)90023-4).

LEÃO, L. d. S. *Detection and control of transverse cracks on rotating machines*. Tese (Doutorado), 2019.

LEI, Y. et al. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, Elsevier, v. 138, p. 106587, 2020. Disponível em: [⟨https://doi.org/10.1016/j.ymssp.2019.106587⟩](https://doi.org/10.1016/j.ymssp.2019.106587).

LI, Z.; GOEBEL, K.; WU, D. Degradation modeling and remaining useful life prediction of aircraft engines using ensemble learning. *Journal of Engineering for Gas Turbines and Power*, American Society of Mechanical Engineers, v. 141, n. 4, p. 041008, 2019. Disponível em: [⟨https://doi.org/10.1115/1.4041674⟩](https://doi.org/10.1115/1.4041674).

LI, Z. et al. Multi-dimensional variational mode decomposition for bearing-crack detection in wind turbines with large driving-speed variations. *Renewable Energy*, Elsevier, v. 116, p. 55–73, 2018. Disponível em: [⟨https://doi.org/10.1016/j.renene.2016.12.013⟩](https://doi.org/10.1016/j.renene.2016.12.013).

LIBONI, L. H. B. *Diagnóstico de falhas em motores de indução trifásicos baseado em decomposição em componentes ortogonais e aprendizagem de máquinas*. Tese (Doutorado) — Universidade de São Paulo, 2017.

LIONG, R.; PROPPE, C. *Application of the Cohesive Zone Model to the Analysis of Rotors with a Transverse Crack*. KIT Scientific Publishing, 2012. (Schriftenreihe des Instituts für Technische Mechanik, Karlsruher Institut für Technologie). Disponível em: [⟨https://books.google.com.br/books?id=WFJMzwEACAAJ⟩](https://books.google.com.br/books?id=WFJMzwEACAAJ).

LIONG, R. T.; PROPPE, C. Finite element multibody simulation of a breathing crack in a rotor with a cohesive zone model. *International Scholarly Research Notices*, Hindawi, v. 2013, 2013. Disponível em: [⟨https://doi.org/10.1155/2013/249035⟩](https://doi.org/10.1155/2013/249035).

LIU, Q. et al. Feature extraction and classification algorithm, which one is more essential? an experimental study on a specific task of vibration signal diagnosis. *International Journal of Machine Learning and Cybernetics*, Springer, p. 1–12, 2022.

LIU, R. et al. Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine. *IEEE Transactions on Industrial Informatics*, IEEE, v. 13, n. 3, p. 1310–1320, 2016. Disponível em: <https://doi.org/10.1109/TII.2016.2645238>.

LIU, R. et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 33–47, 2018. Disponível em: <https://doi.org/10.1016/j.ymssp.2018.02.016>.

LIU, Y.; ONG, S.; NEE, A. State-of-the-art survey on digital twin implementations. *Advances in Manufacturing*, Springer, v. 10, n. 1, p. 1–23, 2022. Disponível em: <https://doi.org/10.1007/s40436-021-00375-w>.

LLOYD, S. Least squares quantization in pcm. *IEEE transactions on information theory*, IEEE, v. 28, n. 2, p. 129–137, 1982. Disponível em: <https://doi.org/10.1109/TIT.1982.1056489>.

LOBATO, F. et al. Estimation of drying parameters in rotary dryers using differential evolution. *Journal of Physics: Conference Series*, Dourdan (Paris), França, v. 135, n. 1, p. 012063, 2008. Disponível em: <https://doi.org/10.1088/1742-6596/135/1/012063>.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. *Advances in neural information processing systems*, v. 30, 2017.

LUPEA, I.; LUPEA, M. Machine learning techniques for multi-fault analysis and detection on a rotating test rig using vibration signal. *Symmetry*, MDPI, v. 15, n. 1, p. 86, 2022. Disponível em: <https://doi.org/10.3390/sym15010086>.

MACQUEEN, J. et al. Some methods for classification and analysis of multivariate observations. Oakland, CA, EUA, v. 1, n. 14, p. 281–297, 1967.

MALISKA, C. R. *Transferência de Calor e Mecânica dos Fluidos Computacional*. 2. ed. Rio de Janeiro, BR: LTCI, 2004.

MARTÍNEZ-MORALES, J. D.; PALACIOS, E.; CAMPOS-DELGADO, D. U. Data fusion for multiple mechanical fault diagnosis in induction motors at variable operating conditions. *7th International Conference on Electrical Engineering Computing Science and Automatic Control*, IEEE, Tuxtla Gutierrez, México, p. 176–181, 2010. Disponível em: <https://doi.org/10.1109/ICEEE.2010.5608632>.

MAYES, I.; DAVIES, W. Analysis of the response of a multi-rotor-bearing system containing a transverse crack in a rotor. *Journal of vibration, acoustics, stress, and reliability in design*, American Society of Mechanical Engineers, v. 106, n. 1, p. 139–145, 1984. Disponível em: <https://doi.org/10.1115/1.3269142>.

MISBAH, I.; LEE, C.; KEUNG, K. Fault diagnosis in rotating machines based on transfer learning: literature review. *Knowledge-Based Systems*, Elsevier, p. 111158, 2023. Disponível em: <https://doi.org/10.1016/j.knosys.2023.111158>.

- MUSZYNSKA, A. *Rotordynamics*. A.M. Consulting, Minden, Nevada, EUA: CRC press, 2005. Disponível em: <https://doi.org/10.1201/9781420027792>.
- NASCIMENTO, K. B. d. *Análise do comportamento dinâmico de um disco de palhetas flexíveis na presença de uma trinca transversal modelada pela abordagem FLEX*. Dissertação (Mestrado), 2022.
- NELSON, H.; MCVAUGH, J. The dynamics of rotor-bearing systems using finite elements. 1976. Disponível em: <https://doi.org/10.1115/1.3438942>.
- OLIVEIRA, M. V. F. d. *Caracterização numérica e experimental de uma bancada de rotor flexível suportada por mancais magnéticos ativos*. Dissertação (Mestrado), 2015.
- OLIVEIRA, M. V. F. d. *Controle de rotores flexíveis suportados por mancais magnéticos*. Tese (Doutorado), 2019.
- OMRAN, M. G.; ENGELBRECHT, A. P.; SALMAN, A. An overview of clustering methods. *Intelligent Data Analysis*, IOS Press, v. 11, n. 6, p. 583–605, 2007. Disponível em: <https://doi.org/10.3233/IDA-2007-11602>.
- PANDARAKONE, S. E. et al. Development of a methodology for bearing fault scrutiny and diagnosis using svm. *IEEE International Conference on Industrial Technology (ICIT)*, p. 282–287, 2017. Disponível em: <https://doi.org/10.1109/ICIT.2017.7913097>.
- PAPADOPOULOS, C. A.; DIMAROGONAS, A. D. Coupled longitudinal and bending vibrations of a rotating shaft with an open crack. *Journal of sound and vibration*, Elsevier, v. 117, n. 1, p. 81–93, 1987. Disponível em: [https://doi.org/10.1016/0022-460X\(87\)90437-8](https://doi.org/10.1016/0022-460X(87)90437-8).
- PIOTROWSKI, J. *Shaft alignment handbook*. Boca Raton, EUA: Crc Press, 2006. Disponível em: <https://doi.org/10.1201/9781420017878>.
- RAI, A.; UPADHYAY, S. H. Bearing performance degradation assessment based on a combination of empirical mode decomposition and k-medoids clustering. *Mechanical Systems and Signal Processing*, Elsevier, v. 93, p. 16–29, 2017. Disponível em: <https://doi.org/10.1016/j.ymssp.2017.02.003>.
- RAMASWAMY, S.; RASTOGI, R.; SHIM, K. Efficient algorithms for mining outliers from large data sets. *Proceedings of the 2000 ACM SIGMOD international conference on Management of data*, p. 427–438, 2000. Disponível em: <https://doi.org/10.1145/342009.335437>.
- RAZAVI-FAR, R.; FARAJZADEH-ZANJANI, M.; SAIF, M. An integrated class-imbalanced learning scheme for diagnosing bearing defects in induction motors. *IEEE Transactions on Industrial Informatics*, IEEE, v. 13, n. 6, p. 2758–2769, 2017. Disponível em: <https://doi.org/10.1109/TII.2017.2755064>.
- REDMOND, I.; AL-HUSSAIN, K. Misalignment as source vibration rotating shaft systems. *Proceedings of IMAC-XIX: A Conference on Structural Dynamics*, Society for Experimental Mechanics, 2001.
- RENDE, B. R. F. *Análise numérica e experimental do comportamento dinâmico de um sistema rotor-palhetas*. Dissertação (Mestrado), 2020.

RODRIGUES, C. E.; Cairo Júnior, C. L. N.; RADE, D. A. Application of machine learning techniques and spectrum images of vibration orbits for fault classification of rotating machines. *Journal of Control, Automation and Electrical Systems*, Springer, v. 33, n. 1, p. 333–344, 2022. Disponível em: <https://doi.org/10.1007/s40313-021-00805-x>.

SAAVEDRA, P.; RAMIREZ, D. Bearing misalignment - part 1. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, SAGE Publications Sage UK: London, England, v. 218, n. 9, p. 971–985, 2004. Disponível em: <https://doi.org/10.1243/0954406041991297>.

SABERI, A. N. et al. Lightgbm-based fault diagnosis of rotating machinery under changing working conditions using modified recursive feature elimination. *IEEE Access*, IEEE, v. 10, p. 81910–81925, 2022. Disponível em: <https://doi.org/10.1109/ACCESS.2022.3195939>.

SABNAVIS, G. et al. Cracked shaft detection and diagnostics: a literature review. *Shock and Vibration Digest*, Washington, DC: The Center, v. 36, n. 4, p. 287, 2004. Disponível em: <https://doi.org/10.1177/0583102404045439>.

SAHA, D. K.; HOQUE, M. E.; BADIHI, H. Development of intelligent fault diagnosis technique of rotary machine element bearing: A machine learning approach. *Sensors*, MDPI, v. 22, n. 3, p. 1073, 2022. Disponível em: <https://doi.org/10.3390/s22031073>.

SARKAR, D.; BALI, R.; SHARMA, T. Practical machine learning with python. *Book "Practical Machine Learning with Python"*, Springer, p. 25–30, 2018. Disponível em: <https://doi.org/10.1007/978-1-4842-3207-1>.

SAWICKI, J. T. et al. Detecting cracked rotors using auxiliary harmonic excitation. *Journal of Sound and Vibration*, Elsevier, v. 330, n. 7, p. 1365–1381, 2011. Disponível em: <https://doi.org/10.1016/j.jsv.2010.10.006>.

SCHEFFER, C.; GIRDHAR, P. *Practical machinery vibration analysis and predictive maintenance*. Elsevier, 2004. Disponível em: <https://doi.org/10.1016/B978-075066275-8/50001-1>.

SEETON, C. J. Viscosity-temperature correlation for liquids. *International joint tribology conference*, v. 42592, p. 131–142, 2006.

SHLENS, J. A tutorial on principal component analysis. *arXiv preprint arXiv:1404.1100*, 2014.

SICCHIERI, L. C. *Metamodelagem Kriging aplicada em modelos de mancais termo-hidrodinâmicos*. Dissertação (Mestrado), 2019.

SILVA, I. B. d. *Identificação de trincas em máquinas rotativas baseada em técnicas de segunda derivada do modo de vibrar e combinação de ressonância*. Tese (Doutorado), 2023.

SINGH, V. et al. Artificial intelligence application in fault diagnostics of rotating industrial machines: A state-of-the-art review. *Journal of Intelligent Manufacturing*, Springer, v. 34, n. 3, p. 931–960, 2023. Disponível em: <https://doi.org/10.1007/s10845-021-01861-5>.

STITSON, M. et al. Theory of support vector machines. *Relatório técnico, University of London*, 1996.

- STORN, R.; PRICE, K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, Springer, v. 11, n. 4, p. 341–359, 1997. Disponível em: <https://doi.org/10.1023/A:1008202821328>.
- TAHIR, M. M. et al. Classification of unbalance and misalignment faults in rotor using multi-axis time domain features. In: IEEE. *2016 International Conference on Emerging Technologies (ICET)*. 2016. p. 1–4. Disponível em: <https://doi.org/10.1109/ICET.2016.7813273>.
- TAO, F.; QI, Q.; NEE, A. Y. C. *Digital twin driven service*. [S.l.]: Academic Press, 2022.
- URBANOWICZ, R. J. et al. Relief-based feature selection: Introduction and review. *Journal of biomedical informatics*, Elsevier, v. 85, p. 189–203, 2018. Disponível em: <https://doi.org/10.1016/j.jbi.2018.07.014>.
- VAPNIK, V. *Statistical learning theory*. Jhon Wiley, 1998.
- WANG, Q. et al. Investigating the construction, training, and verification methods of k-means clustering fault recognition model for rotating machinery. *IEEE Access*, IEEE, v. 8, p. 196515–196528, 2020. Disponível em: <https://doi.org/10.1109/ACCESS.2020.3028146>.
- WANG, Y.; WEI, Z.; YANG, J. Feature trend extraction and adaptive density peaks search for intelligent fault diagnosis of machines. *IEEE Transactions on Industrial Informatics*, IEEE, v. 15, n. 1, p. 105–115, 2018. Disponível em: <https://doi.org/10.1109/TII.2018.2810226>.
- WEI, Y. et al. A review of early fault diagnosis approaches and their applications in rotating machinery. *Entropy*, MDPI, v. 21, n. 4, p. 409, 2019. Disponível em: <https://doi.org/10.3390/e21040409>.
- WU, J. et al. Intelligent fault diagnosis of rolling bearings based on clustering algorithm of fast search and find of density peaks. *Quality Engineering*, Taylor & Francis, v. 35, n. 3, p. 399–412, 2023. Disponível em: <https://doi.org/10.1080/08982112.2022.2140436>.
- XI, W. et al. A feature extraction and visualization method for fault detection of marine diesel engines. *Measurement*, Elsevier, v. 116, p. 429–437, 2018. Disponível em: <https://doi.org/10.1016/j.measurement.2017.11.035>.
- XIA, Y. et al. Study on vibration response and orbits of misaligned rigid rotors connected by hexangular flexible coupling. *Applied Acoustics*, Elsevier, v. 155, p. 286–296, 2019. Disponível em: <https://doi.org/10.1016/j.apacoust.2019.05.022>.
- XU, D.; TIAN, Y. A comprehensive survey of clustering algorithms. *Annals of Data Science*, Springer, v. 2, n. 2, p. 165–193, 2015. Disponível em: <https://doi.org/10.1007/s40745-015-0040-1>.
- ZAPOMĚL, J.; FERFECKI, P. A computational investigation of the disk-housing impacts of accelerating rotors supported by hydrodynamic bearings. 2011. Disponível em: <https://doi.org/10.1115/1.4002527>.
- ZHANG, W.; CHEN, J. Relief feature selection and parameter optimization for support vector machine based on mixed kernel function. *International Journal of Performability Engineering*, v. 14, n. 2, p. 280, 2018. Disponível em: <https://doi.org/10.23940/ijpe.18.02.p9.280289>.

ZHANG, W.; YANG, D.; WANG, H. Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE systems journal*, IEEE, v. 13, n. 3, p. 2213–2227, 2019. Disponível em: <https://doi.org/10.1109/JSYST.2019.2905565>.