

BEATRIZ GRANADO MARANGONI

**CONTRIBUIÇÃO PARA MONITORAMENTO DE
ROÇAMENTO EM MÁQUINAS ROTATIVAS UTILIZANDO
A TÉCNICA DE EMISSÃO ACÚSTICA**



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

2025

BEATRIZ GRANADO MARANGONI

**CONTRIBUIÇÃO PARA MONITORAMENTO DE ROÇAMENTO EM
MÁQUINAS ROTATIVAS UTILIZANDO A TÉCNICA DE EMISSÃO
ACÚSTICA**

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 **DOUTORA EM ENGENHARIA MECÂNICA**.

Área de concentração: Mecânica dos Sólidos e Vibrações.

Orientador: Prof. Dr. Aldemir Aparecido Cavalini
Junior

Coorientador: Prof. Dr. José dos Reis Vieira de Moura
Junior

UBERLÂNDIA - MG

2025

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

M311c
2025

Marangoni, Beatriz Granado, 1993-
Contribuição para monitoramento de roçamento em máquinas rotativas utilizando a técnica de emissão acústica [recurso eletrônico] / Beatriz Granado Marangoni. - 2025.

Orientador: Aldemir Aparecido Cavalini Junior.
Coorientador: José dos Reis Vieira de Moura Junior.
Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-graduação em Engenharia Mecânica.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.te.2025.10005>
Inclui bibliografia.
Inclui ilustrações.

1. Engenharia mecânica. I. Cavalini Junior, Aldemir Aparecido, 1983-
, (Orient.). II. Moura Junior, José dos Reis Vieira de, 1979-, (Coorient.).
III. Universidade Federal de Uberlândia. Programa de Pós-graduação em Engenharia Mecânica. IV. Título.

CDU: 621

Nelson Marcos Ferreira
Bibliotecário(a)-Documentalista - CRB-6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
Coordenação do Programa de Pós-Graduação em Engenharia
Mecânica

Av. João Naves de Ávila, nº 2121, Bloco 1M, Sala 212 - Bairro Santa Mônica, Uberlândia-
MG, CEP 38400-902
Telefone: (34) 3239-4282 - www.posmecanicaufu.com.br - secposmec@mecanica.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Mecânica				
Defesa de:	Tese de Doutorado, número 396, PPGEM				
Data:	28/02/2025	Hora de início:	13:30	Hora de encerramento:	16:30
Matrícula do Discente:	12013EMC002				
Nome do Discente:	Beatriz Granado Marangoni				
Título do Trabalho:	Contribuição para o Monitoramento de Roçamento em Máquinas Rotativas Utilizando a Técnica de Emissão Acústica				
Área de concentração:	Mecânica dos Sólidos e Vibrações				
Linha de pesquisa:	Dinâmicas de Sistemas Mecânicos				
Projeto de Pesquisa de vinculação:	-				

Reuniu-se por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Prof. Dr. Roberto Mendes Finzi Neto - UFU; Prof. Dr. Valder Steffen Jr - UFU; Prof. Dr. Fabian Andres Lara Molina - UFTM; Prof. Dr. Edson Hideki Koroishi - UTFPR e Prof. Dr. Aldemir Aparecido Cavallini Jr - UFU, orientador da candidata.

Iniciando os trabalhos o presidente da mesa, Dr. Aldemir Aparecido Cavallini Junior, apresentou a Comissão Examinadora e o candidata, 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 a candidata. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

Aprovada.

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 28/02/2025, às 16:32, 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 **Fabian Andres Lara Molina, Usuário Externo**, em 28/02/2025, às 16:33, 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 **Valder Steffen Junior, Professor(a) do Magistério Superior**, em 28/02/2025, às 16:33, 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 **Roberto Mendes Finzi Neto, Professor(a) do Magistério Superior**, em 28/02/2025, às 16:33, 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 **Edson Hideki Koroishi, Usuário Externo**, em 28/02/2025, às 16:34, 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 **6104301** e o código CRC **5C2D9AE8**.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Lucylene e Paulo, pelo suporte, exemplo, apoio e por todo o amor.

Ao meu orientador, Prof. Dr. Aldemir, por todos os ensinamentos profissionais e por todas as oportunidades pessoais e profissionais proporcionadas.

Ao meu coorientador, Prof. Dr. José Reis, por toda a sabedoria e conhecimentos transmitidos, sempre disposto a me ajudar nos momentos que necessitei.

Ao Prof. Dr Ricardo Humberto, que sempre transmitiu seus conhecimentos desde a época de Iniciação Científica na UFTM, confiando em mim, me incentivando e me auxiliando em desafios que surgiram nessa pesquisa.

Aos amigos do Laboratório de Mecânicas de Estruturas (LMEst-UFU), por todas as conversas, discussões e aprendizado, e em especial ao Stanley, Raimundo, Leonardo e Daniel, pela contribuição no trabalho.

À Universidade Federal de Uberlândia e ao Programa de Pós-graduação em Engenharia Mecânica, por todo o aprendizado, conhecimento e oportunidade. E um agradecimento especial a todos os professores e técnicos.

Ao Instituto Nacional de Ciência e Tecnologia – Estruturas Inteligentes em Engenharia (INCT – EIE), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), e especialmente ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por todo o auxílio financeiro proporcionado.

Às empresas Foz do Chapecó, BAESA, ENERCAN, CERAN, CSC Energia e CPFL Energia, pelo apoio financeiro através do projeto de P&D "Solução Integrada para o Diagnóstico de Defeitos, Análise Dinâmica e Monitoramento Contínuo de Unidades Geradoras Francis".

Agradeço, por fim, à todas as pessoas que fazem parte da minha vida e que, de alguma forma, contribuíram para a realização desta tese.

MARANGONI, B. G. **Contribuição para o Monitoramento de Roçamento em Máquinas Rotativas Utilizando a Técnica de Emissão Acústica**. 2025. 113 p. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Uberlândia, Uberlândia, 2025.

RESUMO

A detecção precoce de defeitos em máquinas rotativas é essencial para garantir a confiabilidade e eficiência operacional em diversos setores industriais. Neste contexto, a técnica de Emissão Acústica tem se destacado como uma ferramenta promissora para o monitoramento de integridade estrutural, especialmente para a identificação de defeitos incipientes, como o roçamento leve. Esse tipo de defeito, caracterizado pelo contato entre superfícies dinâmicas e estáticas, pode resultar em degradação acelerada dos componentes mecânicos e em falhas catastróficas se não detectado a tempo. Esta tese investiga a aplicação da técnica de emissão acústica para a detecção e caracterização de roçamento em máquinas rotativas, com ênfase no uso de sensores piezoelétricos de baixo custo, incluindo transdutores de titanato-zirconato de chumbo e buzzers, e na integração de algoritmos de aprendizado de máquina para o processamento e classificação dos sinais adquiridos. Para isso, dados foram adquiridos experimentalmente em uma bancada de testes e em diferentes condições operacionais. As análises foram feitas por meio de abordagens convencionais de processamento de sinais, como Transformada Rápida de Fourier e análise envelope baseado em Transformada de Hilbert, bem como por técnicas baseadas em aprendizado de máquinas. Os resultados indicam que a emissão acústica permite a identificação eficaz de roçamentos leves, mesmo em ambientes ruidosos, onde métodos tradicionais de análise de vibração apresentam limitações, reforçando o potencial da técnica como um método eficiente e complementar para o monitoramento contínuo de máquinas rotativas.

Palavras-chave: Emissão Acústica, Monitoramento de Máquinas Rotativas, Aprendizado de Máquina

MARANGONI, B. G. **Contribution to Rubbing Monitoring in Rotating Machines Using the Acoustic Emission Technique**. 2025. 113 p. Thesis (PhD in Mechanical Engineering) - Federal University of Uberlândia, Uberlândia, 2025.

ABSTRACT

Early detection of faults in rotating machinery is critical for maintaining operational reliability and efficiency across various industrial sectors. The Acoustic Emission technique has emerged as a promising method for structural health monitoring, particularly in identifying incipient defects such as light rubbing. Light rubbing faults, defined by contact between rotating and stationary surfaces, can accelerate mechanical degradation and result in catastrophic failures if not promptly detected. This thesis examines the use of the Acoustic Emission technique for detecting and characterizing rubbing faults in rotating machinery, with a focus on low-cost piezoelectric sensors, including lead zirconate titanate transducers and buzzers, integrated with machine learning algorithms for signal processing and classification. Experimental data were collected using a dedicated test rig under multiple operating conditions. Analyses employed both conventional signal processing methods, such as the Fast Fourier Transform and envelope analysis based on the Hilbert Transform, as well as machine learning-based techniques. The findings indicate that Acoustic Emission enables reliable identification of light rubbing faults even in noisy environments where traditional vibration analysis methods are limited. These results underscore the potential of Acoustic Emission as an effective and complementary approach for continuous condition monitoring of rotating machinery.

Keywords: Acoustic Emission, Rotating Machinery Monitoring, Machine Learning

LISTA DE FIGURAS

3.1	Esquema de detecção de ondas de EA. Fonte: Adaptado de Filippin (2017).	22
3.2	Forma de onda de EA simplificada. Fonte: (FILIPPIN, 2017).	23
3.3	Estrutura básica de um sensor padrão de EA. Fonte: (FILIPPIN, 2017).	25
3.4	Sensores piezelétricos utilizados neste estudo para coleta dos sinais de EA: PZT (a) e <i>Buzzer</i> (b).	27
3.5	Representação de um mesmo sinal no domínio do tempo e da frequência. Fonte: Adaptada de Oliveira Neto et al. (2023).	29
3.6	Exemplo de sinal decomposto em três níveis pela transformada wavelet. Fonte: Adaptado de Oliveira Neto et al. (2023).	35
3.7	Estruturas com e sem danos dado 2 características (a) e <i>Clusters</i> dessas estruturas (b). Fonte: (BARELLA et al., 2021).	37
3.8	Matriz de confusão. Fonte: Traduzido de IBM (2024).	40
3.9	Exemplo de curva ROC.	41
3.10	Classificador Random Forest. Fonte: Adaptado de Breiman (2001).	43
4.1	Bancada de testes: 1. motor elétrico; 2. inversor de frequência; 3. acoplamento; 4. mancal de rolamento; 5. disco; 6. proxímetro; 7. PZTs.	47
4.2	Equipamentos de acionamento da bancada de teste: Motor (a) e Inversor de Frequência (b).	47
4.3	Acoplamento flexível (a) e Rolamento autocompensador de esfera (b).	48
4.4	Proxímetros (a) e Pontos que simulam o roçamento no disco (b).	48
4.5	Sensores de EA: PZTs (a) e <i>Buzzers</i> (b).	49
4.6	Placa de aquisição para os sinais de EA modelo NI PXI.	50
5.1	Aplicação do roçamento leve no disco em um ponto de contato.	52
5.2	Diagrama de blocos do processamento de sinais.	54

5.3	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 11 Hz.	55
5.4	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (<i>buzzer</i>) a 11 Hz.	55
5.5	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 14 Hz.	56
5.6	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (<i>buzzer</i>) a 14 Hz	56
5.7	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 15 Hz.	57
5.8	Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (<i>buzzer</i>) a 15 Hz.	57
5.9	Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 11 Hz.	58
5.10	Comparação entre o sinal bruto do sensor <i>buzzer</i> 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 11 Hz.	59
5.11	Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 14 Hz.	60
5.12	Comparação entre o sinal bruto do sensor <i>buzzer</i> 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 14 Hz.	61
5.13	Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 15 Hz.	62
5.14	Comparação entre o sinal bruto do sensor <i>buzzer</i> 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 15 Hz.	63
5.15	PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 11 Hz.	65

5.16	PSD para o envelope do <i>buzzer</i> 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 11 Hz.	66
5.17	PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 14 Hz.	67
5.18	PSD para o envelope do <i>buzzer</i> 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 14 Hz.	68
5.19	PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 15 Hz.	69
5.20	PSD para o envelope do <i>buzzer</i> 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 15 Hz.	70
5.21	Órbita (a) e dFT do sinal dos proximetros (b), obtido para a velocidade de rotação de 11 Hz.	72
5.22	Órbita (a) e dFT do sinal dos proximetros (b), obtido para a velocidade de rotação de 14 Hz.	73
5.23	Órbita (a) e dFT do sinal dos proximetros (b), obtido para a velocidade de rotação de 15 Hz.	74
5.24	Parâmetro <i>Crest Factor</i> para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	77
5.25	Parâmetro Curtose para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	78
5.26	Parâmetro Energia para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	79
5.27	Parâmetro do valor RMS para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	80
5.28	Parâmetro valor pico para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	81
5.29	Parâmetro variancia para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) <i>buzzer</i>	82
5.30	Matriz Confusão para o <i>Gradient Boosting Classifier</i>	86
5.31	Matriz de confusão do algoritmo <i>Extra Trees Classifier</i>	92
5.32	Matriz de confusão do algoritmo <i>Random Forest Classifier</i>	92
5.33	Resultados da dFT para sinais sem roçamento e com roçamento leve.	94

5.34 Matriz de confusão do <i>Extra Trees Classifier</i>	98
--	----

LISTA DE TABELAS

3.1	Comparação entre os algoritmos Extra Trees e Random Forest	44
5.1	Indicadores quantitativos das órbitas para as condições com e sem roçamento leve.	73
5.2	Resultados dos modelos de ML para a abordagem com sinais brutos de EA.	84
5.3	Resultados da validação cruzada do modelo GBC após o ajuste de hiperparâmetros.	86
5.4	Resultados da classificação do defeito nos dados brutos dos sinais de EA.	87
5.5	Resultados dos modelos de ML para a abordagem com sinais filtrados de EA.	88
5.6	Resultados da validação cruzada do modelo ET após a otimização dos hiperparâmetros.	89
5.7	Resultados da validação cruzada do modelo RF após a otimização dos hiperparâmetros.	90
5.8	Resultados da validação cruzada do modelo RF após nova otimização dos hiperparâmetros.	91
5.9	Resultados da classificação do defeito nos dados pré-processado de sinais de EA.	93
5.10	Resultados dos modelos de ML para a abordagem com sinais de EA no domínio da frequência.	96
5.11	Resultados da validação cruzada do modelo ET após a otimização dos hiperparâmetros para sinais de EA no domínio da frequência.	97
5.12	Resultados da classificação nos dados pré-processado e no domínio da frequência dos sinais de EA.	98

LISTA DE SÍMBOLOS

$a(t)$	Amplitude do envelope do sinal
a_1	Coefficiente de aproximação <i>wavelet</i>
d_1	Coefficiente de detalhe <i>wavelet</i>
K	Curtose
E	Energia do sinal
$\phi(t)$	Fase instantânea do envelope do sinal
k	Índice no domínio da frequência
n	Índice no domínio do tempo
μ	Média
N	Número de amostras
$h(t)$	Sinal analítico
x_i	Sinal da i -ésima amostra do sinal
$x(t)$	Sinal original no tempo
$X(f)$	Transformada de Fourier
$\hat{x}(t)$	Transformada de Hilbert
x_{pico}	Valor de pico do sinal
x_{rms}	Valor RMS do sinal
σ^2	Variância

τ Variável de integração

Abreviações

AE	<i>Autoencoder</i>
ANN	<i>Artificial Neural Networks</i>
BAESA	Usina Hidrelétrica Barra Grande
cGAN	Rede Adversarial Generativa Condicional
CF	Fator de Crista (<i>Crest Factor</i>)
CNN	<i>Convolutional Neural Networks</i>
CPFL	Companhia Paulista de Força e Luz
DBN	<i>Deep Belief Network</i>
DT	<i>Decision Tree</i>
EA	Emissão Acústica
END	Ensaio Não Destrutivo
FEMEC	Faculdade de Engenharia Mecânica
FFT	Transformada Rápida de Fourier
IA	Inteligência Artificial
k-NN	<i>k-Nearest Neighbors</i>
LMEst	Laboratório de Mecânica de Estruturas
ML	<i>Machine Learning</i>

NB	<i>Naive Bayes</i>
PZT	<i>Lead Zirconate Titanate</i>
RMS	<i>Root Mean Square</i>
RNN	<i>Residual Neural Networks</i>
SHM	<i>Structural Health Monitoring</i>
SVM	<i>Support Vector Machines</i>
UFU	Universidade Federal de Uberlândia

SUMÁRIO

LISTA DE FIGURAS	xi
LISTA DE TABELAS	xii
LISTA DE SÍMBOLOS	xiii
CÁPITULO I - Introdução	1
1.1 Contextualização	1
1.2 Contribuições da tese	5
1.3 Estrutura do Trabalho	6
CÁPITULO II - Revisão de Literatura	8
CÁPITULO III - Fundamentação Teórica	20
3.1 Princípios Básicos de Emissão Acústica	20
3.2 Sensor Comercial de Emissão Acústica	24
3.3 Pastilhas Piezelétricas	26
3.4 Técnicas de processamento de sinais para Emissão Acústica na detecção de defeitos em máquinas rotativas	28
3.4.1 Transformada rápida de <i>Fourier</i>	29
3.4.2 Análise Envelope com base na Transformada de Hilbert	30
3.4.3 Métodos Estatísticos	31
3.4.4 Transformada <i>Wavelet</i>	34
3.5 Aprendizado de Máquinas	36
3.5.1 Aprendizado não supervisionado	37
3.5.2 Aprendizado de reforço	37
3.5.3 Aprendizado supervisionado	38

3.5.4	Avaliação da Performance de Modelos	39
3.6	Ferramentas para Criação de Modelos	41
3.6.1	Sklearn	41
3.6.2	Pycaret	42
3.7	Algoritmos de classificação utilizados	42
3.7.1	Floresta Aleatória	42
3.7.2	Extra Trees Classifier	44
3.7.3	Gradient Boosting Classifier	45
CÁPITULO IV - Bancada Experimental de Testes		46
4.1	Bancada de Teste	46
4.2	Placa de aquisição dos sinais de EA	49
CÁPITULO V - Resultados		51
5.1	Metodologia Experimental abordada na Bancada de Testes	51
5.2	Análise dos sinais de Emissão Acústica por Envelope com base na Transformada de Hilbert	53
5.3	Análise dos sinais de Emissão Acústica por algoritmos de Aprendizado de Máquina	83
5.3.1	Abordagem com dados brutos de Emissão Acústica	84
5.3.2	Abordagem com dados de Emissão Acústica pré-processados	87
5.3.3	Abordagem com dados de Emissão Acústica pré-processados e no domínio da frequência	93
CÁPITULO VI - Conclusões e Perspectivas Futuras		100
6.1	Conclusões	100
6.2	Perspectivas futuras	102
REFERÊNCIAS BIBLIOGRÁFICAS		104

CAPÍTULO I

INTRODUÇÃO

1.1 Contextualização

Máquinas rotativas desempenham um papel fundamental em diversos setores da indústria, incluindo a automotiva, a aeroespacial e de geração de energia. Devido às operações contínuas e às condições variadas de carregamento, essas máquinas frequentemente estão sujeitas a falhas em suas superfícies de componentes dinâmicos e estáticos, o que pode resultar em danos severos e até falhas catastróficas (OVY, 2012; SAIMURUGAN, 2013; PRABITH; KRISHNA, 2020). Nesse contexto, a identificação antecipada de falhas assume um papel fundamental para assegurar a confiabilidade e a segurança dos sistemas. Essa abordagem proativa visa prevenir possíveis consequências negativas que possam afetar o desempenho operacional.

A identificação de defeitos incipientes tornou-se uma necessidade fundamental na era industrial atual, permitindo evitar paradas inesperadas, minimizar perdas de produtividade e reduzir significativamente os custos de manutenção (SAIMURUGAN, 2013; PENG et al., 2018). A manutenção preditiva, pautada na análise contínua ou periódica do estado operacional de equipamentos, tem se consolidado como uma estratégia eficaz para a otimização da gestão de ativos industriais.

A partir disso, diversas técnicas de monitoramento estão disponíveis na literatura, destacando-se a análise de vibração que é amplamente aplicada por ser uma ferramenta poderosa na avaliação da condição de operação do rotor (LIU; ONG; NEE, 2022). Os sinais de vibração, ao serem analisados, fornecem informações precisas sobre a natureza e a severidade de diversos defeitos, permitindo que ações corretivas sejam implementadas antes que ocorram paradas não programa-

das e danos mais severos aos equipamentos (HE; ZHANG; FRISWELL, 2009; SAIMURUGAN, 2013).

Embora a análise de vibrações esteja bem consolidada na literatura científica e seja amplamente utilizada na prática industrial, novas abordagens têm surgido para superar algumas de suas limitações, como a sensibilidade reduzida a defeitos iniciais e o mascaramento de sinais por ruídos (HE; ZHANG; FRISWELL, 2009). Neste contexto, o desenvolvimento de técnicas modernas de monitoramento da integridade estrutural, conhecidas como SHM (do inglês *Structural Health Monitoring*), tem ganhado destaque nos últimos anos. Essas técnicas, que se beneficiam de avanços em sensores, processamento de sinais e inteligência artificial, podem ser aplicáveis com a máquina em operação, reduzindo os custos associados e aumentando a confiabilidade, segurança e desempenho dos equipamentos (CAVALINI Jr., 2013; ROY; DATTA; TOPDAR, 2024).

As ferramentas de SHM consistem em uma estratégia sistemática que envolve a observação contínua de estruturas ou sistemas mecânicos ao longo do tempo, utilizando medições periódicas para identificar características sensíveis a defeitos. A partir dessas medições, são realizadas análises estatísticas que permitem avaliar o estado estrutural atual do sistema. Dessa forma, o SHM tem se mostrado uma metodologia promissora para a avaliação em tempo real de defeitos em máquinas rotativas, contribuindo para a manutenção preditiva e a longevidade operacional desses rotores (SAWICKI et al., 2008; NOR, 2018). As abordagens de SHM são amplamente exploradas na literatura, destacando-se entre elas a técnica baseada em Emissão Acústica (EA), que se consolidou como ferramenta eficaz de ensaio não destrutivo (END) para a análise, monitoramento e diagnóstico de defeitos.

A técnica de EA é definida pela detecção de ondas elásticas transitórias geradas durante o desenvolvimento e propagação de danos, tanto internamente quanto na superfície da estrutura. Essa característica confere à EA uma alta sensibilidade a eventos transitórios de baixa energia, tornando-a particularmente eficaz para a detecção de defeitos incipientes e o monitoramento em tempo real de equipamentos (ROY; DATTA; TOPDAR, 2024). Em máquinas rotativas, as fontes de EA incluem a propagação de trincas em componentes estruturais, danos em rolamentos, descargas elétricas parciais em sistemas elétricos, roçamento ou atrito entre partes móveis, e o fenômeno de cavitação em bombas hidráulicas (HECKE; QU; HE, 2015; CHACON, 2015a; PRABITH; KRISHNA, 2020; CIABURRO; IANNACE, 2022).

Dentre essas fontes, o defeito causado pelo roçamento é particularmente preocupante, pois é

uma falha crítica que pode causar danos consideráveis à integridade estrutural do equipamento. Segundo Prabith e Krishna (2020), esse defeito ocorre como resultado do contato entre elementos dinâmicos e estáticos (por exemplo, rotor e superfície), gerando um atrito local que libera energia na forma de ondas elásticas caracterizando microdeformações. Os métodos tradicionais, como a análise de vibração, podem negligenciar esse roçamento devido à sua alta frequência e comportamento transitório, mas que podem ser claramente detectados pela EA. Estudos recentes de Prabith e Krishna (2020) e Li et al. (2020) evidenciam o potencial da técnica de EA para a identificação precoce de eventos de roçamento, possibilitando prevenir falhas catastróficas, sobretudo em máquinas rotativas modernas, cujas tolerâncias reduzidas aumentam a probabilidade de ocorrência desse tipo de defeito.

O trabalho de Sato (1990) foi um dos pioneiros na aplicação de EA para o diagnóstico de roçamento em máquinas rotativas. Mba e Hall (2002) conduziram uma pesquisa completa acerca do uso da EA para detecção, identificação e localização de roçamentos em grandes turbinas industriais. As análises dos autores ampliaram a compreensão da técnica e proporcionaram um progresso notável na sua utilização prática em máquinas rotativas, tornando-a mais sólida e segura para a identificação de defeitos incipientes.

Wang e Chu (2001) inovaram ao aplicarem uma análise de forma de ondas em sinais de EA para identificar características de defeitos por roçamento, e com a metodologia de decomposição wavelet, desenvolveram um método que localizava o roçamento. A pesquisa de He et al. (2014) trouxe uma nova abordagem para identificar defeitos por roçamento em máquinas rotativas. Ao aplicar a teoria de ondas em placas e a análise de pacotes wavelet aos sinais de EA, os autores reduziram a interferência de ruídos e melhoraram a resolução espacial da técnica para a localização do defeito.

Essas pesquisas contribuíram para o desenvolvimento da EA no monitoramento de roçamento em sistemas rotativos, além de oferecerem metodologias de localização desse defeito. Além disso, métodos tradicionais de processamento de sinais de EA geralmente são divididos em análises no domínio do tempo, com base em parâmetros estatísticos característicos da forma de onda desse sinal; e análises no domínio da frequência, utilizando transformada rápida de Fourier (FFT), transformada *Wavelet* e análise envelope com base na transformada *Hilbert*, respectivamente (ZHIHAO et al., 2009; CHACON, 2015a; LI et al., 2020; TANG et al., 2023).

Dentre os principais desafios enfrentados na aplicação da EA em máquinas rotativas, destaca-se a presença de ruído de fundo significativo, resultante de fenômenos como desalinhamento,

desbalanceamento e vibrações normais de operação. Esses fatores dificultam a detecção precisa de defeitos específicos, exigindo o uso de técnicas avançadas de filtragem e extração de características para distinguir sinais de falha dos ruídos operacionais. Além disso, a escolha adequada dos parâmetros de análise, como a seleção da *wavelet* e a definição de bandas de frequência para filtragem, influencia diretamente a eficácia do diagnóstico. Essas metodologias já estão muito bem consolidadas na literatura, mas podem resultar em um custo computacional alto o que pode dificultar o monitoramento de condições em tempo real na indústria atual.

Com a nova era da tecnologia e a ascensão da Indústria 4.0, técnicas de Inteligência Artificial (IA) estão sendo desenvolvidas para diversas aplicações em máquinas e equipamentos, objetivando aumentar a vida útil de seus componentes, evitando paradas desnecessárias e a garantia da continuidade do processo produtivo, de forma mais rápida, precisa e robusta nas tomadas de decisões das equipes de manutenção (LIU et al., 2018; Oliveira Neto et al., 2023; BRITO, 2022; GONÇALVES, 2024).

O desenvolvimento de sistemas inteligentes para monitorar e diagnosticar defeitos em máquinas rotativas representa um desafio que tem sido abordado através da integração de técnicas de extração de características e IA (LIU et al., 2018). Esses modelos de IA são constituídos por métodos de aprendizagem de máquina (ML - *Machine Learning*), como: máquinas de vetores de suporte (SVM), Redes Neurais Artificiais (ANN), k-vizinhos mais próximos (*k*-NN), Árvore de Decisão (DT), *Naive Bayes* (NB), *K*-médias, clusterização, dentre outros. Além disso, nos últimos anos, modelos constituídos por métodos de aprendizagem profunda (DL - *Deep Learning*) estão sendo amplamente aplicados, destacando: *Autoencoder* (AE), Redes Neurais Convolucionais (CNN), Redes Neurais Residuais (RNN), *Deep Belief Network* (DBN). Na arquitetura desses modelos, são exploradas propriedades de classificação de padrões não lineares, oferecendo vantagens para a detecção e identificação automática de condições de defeitos.

Além dos métodos convencionais de ML e das abordagens baseadas em DL, os algoritmos de *ensemble learning* têm se destacado na detecção e diagnóstico de falhas em máquinas rotativas. Essa popularidade se deve à sua capacidade de combinar múltiplos classificadores, o que resulta em uma melhoria significativa na robustez e na precisão das previsões (ROKACH, 2016). Entre esses métodos, o Floresta aleatória (RF) e o *Extra Trees* (ET) têm sido amplamente utilizados, uma vez que se fundamentam em múltiplas árvores de decisão, ajudando a reduzir a variabilidade e a aumentar a estabilidade da classificação (BREIMAN, 2001; GEURTS; ERNST; WEHENKEL, 2006).

A condição de uma máquina pode ser avaliada através da análise de alguns parâmetros, como vibração, temperatura, ruído e EA. Um indicativo de falha é caracterizado quando esses parâmetros desviam dos valores considerados normais para a operação do sistema. A partir da coleta e processamento desses sinais, as técnicas de ML podem identificar padrões que caracterizam defeitos além de automatizar esse processo de análise e classificação, proporcionando um diagnóstico preciso e eficiente.

1.2 Contribuições da tese

Esta tese de doutorado apresenta contribuições inovadoras na aplicação da técnica de EA para a detecção de defeitos incipientes decorrentes do roçamento leve em máquinas rotativas. O trabalho investiga tanto abordagens tradicionais de processamento de sinais quanto métodos baseados em ML, com o objetivo de aprimorar a capacidade de diagnóstico e a eficiência na identificação deste tipo de falha.

Diferentemente da maioria dos estudos disponíveis na literatura, que recorrem a sensores e equipamentos comerciais de alto custo, este trabalho propõe a utilização de sensores piezoelétricos de titanato-zirconato de chumbo (PZT) e *buzzers* como alternativa para a aquisição de sinais de EA. Esses sensores, que são dispositivos de baixo custo e amplamente acessíveis, permitem a captura eficaz dos sinais de EA em condições experimentais controladas. A implementação desses sensores foi realizada em uma bancada experimental situada no Laboratório de Mecânica de Estruturas (LMEst-UFU), desenvolvida especificamente para simular o roçamento leve em sistemas rotativos.

Outro avanço significativo desta tese reside na aplicação de técnicas de ML para a análise do roçamento pelos sinais de EA. Ao contrário das abordagens convencionais, que exigem etapas de pré-processamento complexas e computacionalmente intensivas, como a Transformada Rápida de Fourier (FFT), transformada *Wavelet* e a análise de envelope (Transformada de Hilbert), a utilização de algoritmos de ML possibilita a extração automática de características. Essa técnica reduz consideravelmente o tempo de processamento, tornando o diagnóstico mais rápido e eficiente, além de viabilizar uma implementação mais acessível em ambientes industriais para o monitoramento contínuo.

A pesquisa desenvolvida nesta tese teve origem no projeto de pesquisa e desenvolvimento (P&D) intitulado "Solução Integrada para o Diagnóstico de Defeitos, Análise Dinâmica e

Monitoramento Contínuo de Unidades Geradoras Francis”, em colaboração com as empresas Foz do Chapecó, CERAN, BAESA, ENERCAN, CSC Energia e CPFL Energia. Nesse contexto, as contribuições deste trabalho reforçam as práticas de manutenção preditiva, oferecendo uma metodologia eficaz para o diagnóstico precoce de defeitos em sistemas complexos. A aplicação das técnicas propostas tem o potencial de evitar paradas não programadas, reduzir custos operacionais e assegurar a continuidade do fornecimento de energia elétrica.

Dessa forma, esta tese não apenas apresenta novas perspectivas para o uso da EA na detecção de roçamento leve, mas também ressalta o potencial das técnicas de ML como uma solução robusta e eficiente para o monitoramento de condições em sistemas rotativos industriais.

1.3 Estrutura do Trabalho

Este capítulo contextualiza o tema proposto e detalha as motivações do estudo. Esta Tese de Doutorado está estruturada em mais seis capítulos, além das referências bibliográficas, sendo descritos a seguir.

O Capítulo II apresenta uma revisão bibliográfica de estudos que aplicaram o monitoramento e diagnóstico de defeitos em máquinas rotativas com base na análise de sinais de EA. Também são exploradas pesquisas que utilizam essa metodologia associada a técnicas de métodos de aprendizado, discutindo avanços, desafios e tendências na área.

O Capítulo III apresenta a fundamentação teórica para o monitoramento do roçamento em máquinas rotativas por meio da técnica de EA. Inicialmente, são descritos o conceito e os princípios da EA para, em seguida, abordar sobre os sensores piezelétricos, enfatizando sobre PZTs e *buzzers*. Na sequência, são exploradas as principais metodologias utilizadas para processamento de sinais utilizadas na literatura para a análise dos dados coletados, incluindo a FFT, a análise envelope (Transformada Hilbert), métodos estatísticos e *Wavelet*, destacando suas contribuições na identificação de padrões de defeitos. Após isto, são apresentados os conceitos do aprendizado de máquinas, discutindo os principais algoritmos empregados para a classificação de dados, os indicadores de desempenho utilizados para avaliação dos modelos e algumas das bibliotecas computacionais que foram implementadas nas abordagens desta tese. Por fim, são descritos brevemente os modelos de ML que obtiveram os melhores resultados na classificação dos sinais de EA neste estudo.

O Capítulo IV apresenta detalhes da bancada experimental de testes do sistema rotativo

utilizada para a obtenção dos dados de EA em condições de operação sem roçamento e com roçamento leve. Além dos detalhes acerca das partes constituintes do sistema rotativo, é apresentado o sistema de medição empregado para a aquisição dos sinais de EA.

O Capítulo V é voltado para a apresentação dos resultados obtidos com o conjunto de dados experimental, detalhando as etapas envolvidas no processamento e na extração de informações relevantes. Além da aplicação de modelos de aprendizado de máquina (ML) para diferentes abordagens estudadas explorando técnicas de pré-processamento de sinais, transformações no domínio da frequência e otimização de hiperparâmetros.

O Capítulo VI é dedicado as conclusões do trabalho e apresenta algumas perspectivas futuras para o desenvolvimento das técnicas exploradas nesta tese.

CAPÍTULO II

REVISÃO DE LITERATURA

Ao considerar análises em máquinas rotativas aplicando a técnica de emissão acústica (EA), entre as principais fontes de detecção de emissão estão impactos, fadiga cíclica, vazamentos, atrito/roçamento, perda de material, entre outras. Dentre esses fenômenos, os processos relacionados ao atrito são um dos principais geradores de EA, ocorrendo simultaneamente diversos processos físicos e químicos, como a interação mecânica e química das superfícies em contato, alterações estruturais, modificações químicas e danos nas superfícies envolvidas (CHACON, 2015b). Nesse contexto, esta seção se propõe a apresentar uma revisão de literatura em ordem cronológica, destacando os principais trabalhos que orientaram ao desenvolvimento desta tese.

Um dos primeiros estudos focados na aplicação da EA em máquinas rotativas foi estabelecido no trabalho de Graham, Randall e Hong (1982). Neste estudo, essa técnica foi utilizada para a detecção do início de formação e posterior propagação de trincas em um eixo de uma turbina a vapor de baixa pressão. O sinal de EA foi transmitido ao longo do rotor, porém os autores concluíram que o ruído operacional de fundo mascarou os resultados dos sinais adquiridos, o que dificultou e provocou erros nas análises.

O estudo de Sato (1990) apresentou a aplicação da técnica de EA como uma nova abordagem para o diagnóstico de falhas mecânicas em máquinas rotativas. Nesta pesquisa, foi destacada a capacidade dessa metodologia em detectar precocemente fenômenos como atritos entre rotores e estatores, danos em mancais e trincas em rotores. A utilização de sensores de EA permitiu não apenas identificar essas anomalias, como também localizar a origem dos sinais, mesmo sobre a influência de ambientes industriais desafiadores, como usinas térmicas e siderúrgicas. Além disso, também foi discutido o desenvolvimento de sistemas de diagnóstico que integraram filtros

passa-faixa para processamento de sinais, evidenciando frequências específicas associadas aos eventos de atrito. Essa abordagem demonstrou ser eficaz para monitoramento em tempo real e para a manutenção preditiva de equipamentos críticos, reforçando a relevância da EA como ferramenta essencial na prevenção de falhas e na garantia da segurança operacional de grandes plantas industriais.

O trabalho de Choudhury e Tandon (2000) apresentou que a EA conta com a capacidade de detectar defeitos que, até então, não podiam ser identificados por métodos tradicionais de monitoramento de vibração devido à alta frequência da vibração elástica gerada pela energia de deformação liberada. Os parâmetros EA, contagem de ringdown, eventos e amplitude de pico são fundamentais na detecção de defeitos, especialmente nos primeiros estágios. A pesquisa indicou que a resposta de EA não era muito modificada pela carga aplicada aos rolamentos mas a velocidade, aumentou a emissão à medida que crescia. Além disso, os autores concluíram que a distribuição dos eventos em relação às contagens e à amplitudes serviu de aprimoramento significativo para a etapa de inspeção de qualidade de rolamentos novos e regenerados. Em geral, esses resultados proveram a importância da EA como método de monitoramento não destrutivo em manutenção preditiva em sistemas com rolamentos.

Posteriormente, Morhain e Mba (2003) investigaram experimentalmente defeitos impostos na pista interna e externa de um rolamento presente em uma máquina rotativa de teste. Como esse equipamento foi adaptado para o propósito do estudo, houve uma alta influência de um ruído de fundo na EA, fornecendo um teste realista para diagnóstico de defeitos. Os resultados validaram o uso de parâmetros como valor RMS, amplitude, energia e contagem de EA para diagnóstico. Além disso, este estudo determinou o nível de *threshold* ideal para o diagnóstico de contagem de EA.

Concentrando-se na investigação de possíveis falhas em máquinas rotativos, o uso da técnica de EA na detecção de atritos entre o eixo e os vedantes em turbinas de grande escala tem mostrado resultados promissores, especialmente ao se comparar a métodos tradicionais por análise de vibração. No estudo de Mba et al. (2004), sensores EA foram utilizados para monitorar sinais de uma turbina de 217 MVA, indicando eventos de roçamento/atrito entre o rotor e componentes estacionários. Os autores observaram que os sinais de EA, operando em frequências de 100 kHz a 600 kHz, conseguiram captar fenômenos como deformação, adesão e desgaste nas superfícies em contato. Além disso, pode-se notar que os sinais refletiam a velocidade de rotação da turbina, que no caso em estudo foi de 50 Hz, ajudando a diferenciar atritos contínuos de intermitentes.

Dessa forma, os autores concluíram que a metodologia de EA é eficiente na identificação de defeitos em locais específicos, superando as limitações que existem em métodos tradicionais de análise de vibração, além de reforçar a sua importância no monitoramento de equipamentos críticos.

A fim de avaliar a eficiência da técnica de EA na detecção de defeitos semeados em engrenagens, Toutountzakis, Tan e Mba (2005) apresentaram uma abordagem experimental de testes realizados com duas caixas de engrenagens lubrificadas em banho de óleo, conectadas a um arranjo de rolamentos (quatro mancais de esferas cada). Os sensores de EA foram fixados próximos aos dentes da engrenagem, nos quais os defeitos foram inseridos. Entretanto, essa abordagem foi repleta de dificuldades devido à influência da carga, temperatura do óleo e da dinâmica do sistema nas análises. Conclui-se que uma avaliação melhor da técnica deveria ser realizada em um estudo com condições de *pitting* natural ou desgaste ao invés de introduzir defeitos semeados.

Baseando-se nas análises apresentadas por Toutountzakis, Tan e Mba (2005), o estudo de Tan, Irving e Mba (2005) explorou o processo de *pitting* natural em engrenagens utilizando metodologias diferentes, como: sinais de EA, análise de vibração e amostras de óleo nos mancais. Os resultados mostraram que os sinais de EA foram capazes de detectar o dano nas engrenagens de forma precoce, enquanto a análise de vibração só identificou o defeito quando a taxa de *pitting* superava 30%. Dessa forma, a técnica de EA demonstrou maior sensibilidade e eficácia no monitoramento e detecção antecipada desse tipo de falha.

Mba e Rao (2006) realizaram uma ampla revisão sobre a aplicação da técnica de EA em componentes de máquinas rotativas, incluindo mancais, bombas, caixas de engrenagem, motores e estruturas rotativas. Os autores destacaram que a técnica está associada a fenômenos como impactos, fadiga cíclica, fricção, cavitação e perda de material. Além disso, enfatizaram a capacidade da EA em detectar defeitos de forma precoce, antes mesmo que sejam identificados por métodos convencionais de análise de vibração.

Estudos revisados pelos autores demonstraram que a EA apresenta elevada sensibilidade ao surgimento de microfissuras e defeitos em subsuperfícies de componentes, especialmente em rolamentos submetidos ao estresse de contato de Hertz e ao atrito entre superfícies danificadas. Entretanto, um dos principais desafios observados na aplicação da técnica está relacionado à atenuação do sinal, principalmente quando os sensores são instalados em partes não rotativas da máquina, como carcaças de mancais e redutores. Apesar dessas limitações, os autores

concluíram que a EA permanece como uma ferramenta promissora e eficiente para aplicações em manutenção preditiva industrial.

He, Yin e Chu (2008) investigaram a aplicação da técnica de EA combinando análise modal com o escalograma *Wavelet* reatribuído para o diagnóstico de defeitos por roçamento entre rotor e estator em sistemas rotativos. Com base na teoria de Emissão Acústica Modal (MAE), os autores analisaram as características tempo-frequência das ondas elásticas geradas pelo atrito, identificando a presença de modos flexurais de baixa frequência (<100 kHz) e modos extensionais de alta frequência (>100 kHz). Os resultados mostraram que os sinais de EA associados ao roçamento apresentam natureza multimodal e comportamento impulsivo, características importantes para a detecção de falhas incipientes.

Os autores também verificaram que o escalograma wavelet reatribuído apresentou desempenho superior ao escalograma convencional, proporcionando maior concentração de energia no domínio tempo-frequência e melhor identificação de sinais fracos relacionados aos estágios iniciais do defeito. Além disso, observou-se que a atenuação dos sinais de EA depende tanto do modo de propagação quanto das características do caminho de transmissão. Os modos extensionais mostraram-se mais sensíveis às interfaces e distâncias de propagação, enquanto os modos flexurais apresentaram maior resistência à atenuação. Dessa forma, o estudo demonstrou o potencial da EA associada à análise wavelet para o monitoramento avançado de máquinas rotativas.

No trabalho de Al-Dossary, Hamzah e Mba (2009), a EA foi aplicada para caracterizar os tamanhos de defeitos em um mancal de rolamento carregado radialmente. A análise foi realizada em um equipamento de teste experimental projetado de modo que os defeitos com tamanhos variados pudessem ser introduzidos nas pistas externa e interna do mancal. Os resultados mostraram que há uma correlação direta entre a energia de EA e a gravidade do defeito, sendo possível determiná-la conforme a forma da onda de EA, o que pode ser útil em estratégias de prognóstico e manutenção preditiva. Vale resaltar, que essa correlação somente foi observada na pista externa e não foi válida para os defeitos na pista interna.

He, Zhang e Friswell (2009) investigaram a eficácia da EA como ferramenta para o diagnóstico de defeitos em mancais de rolamento por meio de análises estatísticas de parâmetros como assimetria, curtose, energia, valor RMS, *crest factor* e contagem. Os resultados mostraram que esses indicadores são altamente sensíveis ao tamanho do defeito, permitindo diferenciar defeitos em estágios iniciais com precisão superior à análise de vibração. A abordagem experi-

mental incluiu variações na carga radial e na velocidade de rotação, destacando a robustez da EA em condições operacionais diversas.

Com relação a SHM em aplicações críticas utilizando a técnica por EA, destaca-se o estudo de Holford (2009). Neste trabalho, foram revisados os avanços da aplicação de EA para identificar danos em estruturas, incluindo detecção de trincas e localização de fontes de emissão em sistemas complexos. No monitoramento de estruturas aeronáuticas e turbinas, foi demonstrado que a EA possibilita avaliações contínuas e eficientes de integridade estrutural, impactando nos custos de inspeção que são reduzidos e melhorando a confiabilidade operacional. Além disso, foram discutidos novos métodos de processamento de sinais que possam melhorar a precisão na estimativa da localização e severidade dos danos, contribuindo significativamente para o avanço do SHM em diversas indústrias.

Elforjani e Mba (2011) apresentaram um trabalho experimental para uma máquina rotativa de baixa velocidade utilizando a EA na detecção de defeitos incipientes, como trincas e desgaste em rolamentos e eixos. O estudo foi conduzido em rolamentos sobre condições de lubrificação reduzida, usando bancada de teste desenvolvidas para gerar degradação natural. Os autores demonstraram que a EA é altamente sensível, mesmo em velocidades baixas, e foi eficaz para identificar defeitos iniciais, superando métodos tradicionais como análise de vibração.

Com o objetivo de localizar e determinar a profundidade de uma trinca em um eixo de máquina rotativa, Lu e Chu (2011) exploraram o uso combinado de sinais de EA e de vibração para diagnosticar a trinca, que representa uma das falhas mais críticas nesse tipo de sistema. A Transformada Wavelet foi utilizada para decompor os sinais de EA em bandas de frequência específicas, o que permitiu uma análise detalhada no domínio do tempo e da frequência. Os resultados demonstraram que os sinais de EA foram eficazes para localizar trincas em eixos, enquanto os sinais de vibração se mostraram úteis para determinar a profundidade das trincas.

O estudo de Yu et al. (2011) apresentou uma abordagem diferente de aplicação da técnica, foi investigada a adaptação de sensores de pastilhas piezoelétricas ativas (PWAS) para a aplicação como transdutores de EA, sendo comparado seu desempenho com um sensor de EA comercial padrão, da fabricante PAC (*Physical Acoustics Corporation*) modelo R15I. O estudo avaliou a capacidade desses sensores na detecção de eventos de EA em ensaios de fadiga realizados em amostras metálicas compactas submetidas à tração. Os resultados mostraram que os sensores PWAS são capazes de operar em uma ampla faixa de frequências, embora apresentem uma relação sinal-ruído inferior à observada em sensores comerciais convencionais.

Apesar das limitações relacionadas à qualidade do sinal, os autores destacaram o potencial dos sensores PWAS para aplicações em monitoramento de condição em tempo real. Além disso, o estudo evidenciou que esses sensores podem representar uma alternativa de baixo custo e maior flexibilidade de integração quando comparados aos sensores comerciais tradicionalmente utilizados em sistemas de EA.

Chacon et al. (2014) investigaram a aplicação da técnica de EA na detecção de desalinhamento angular em eixos rotativos, comparando seu desempenho com métodos tradicionais de análise de vibração. Os autores utilizaram sensores de proximidade para medir as deflexões do eixo e sensores de EA para adquirir os sinais sob diferentes condições de carga e velocidade. A metodologia empregada baseou-se na Transformada de *Hilbert* e na análise de envelope para identificar frequências características do desalinhamento. Os resultados mostraram que a EA apresentou maior sensibilidade na detecção do defeito, principalmente em condições de baixa carga e baixa rotação, nas quais a análise de vibração apresentou limitações. Dessa forma, os autores concluíram que a técnica de EA combinada com a análise de envelope é eficaz para a identificação de desalinhamentos e possui potencial para aplicação em outros defeitos rotodinâmicos.

Com o objetivo de reduzir o ruído para realçar características específicas de defeitos, Ruiz-Cárcel et al. (2014) apresentaram um estudo aplicando a Curtose Espectral (*Spectral Kurtosis* - SK) em sinais de EA. Empregou-se essa ferramenta para melhorar a relação sinal-ruído de sinais adquiridos para diferentes tamanhos de defeitos que foram introduzidos experimentalmente em rolamentos. Tal método favoreceu essa relação como também ajudou na identificação de padrões de defeitos que poderiam estar mascarados pelo ruído de fundo.

Hecke, Qu e He (2015) propuseram uma abordagem para o processamento de sinais de EA aplicada ao diagnóstico de defeitos em rolamentos, utilizando técnicas de redução de frequência heteródina e reamostragem síncrona no tempo. O objetivo do estudo foi extrair indicadores de condição capazes de representar características relevantes dos defeitos, convertendo sinais de alta frequência em faixas comparáveis às empregadas na análise de vibração. A metodologia permitiu identificar defeitos na pista interna, pista externa, esferas e gaiola do rolamento. Os experimentos foram realizados sob diferentes condições de velocidade e carga, demonstrando a robustez da técnica em diferentes regimes operacionais. Como principal resultado, os autores verificaram que a abordagem reduziu a necessidade de altas taxas de amostragem, simplificando o processamento e o armazenamento dos dados, sem comprometer a capacidade de diagnóstico.

Castro et al. (2016) investigaram a utilização de sensores piezoelétricos de baixo custo (*buzzers*) para o monitoramento de descargas parciais em transformadores de potência, buscando uma alternativa aos sensores comerciais de EA, geralmente de elevado custo. O estudo comparou o desempenho dos *buzzers* com sensores comerciais RS15I-AST por meio de métricas de análise de sinais acústicos, como densidade espectral de potência, energia e valores de pico. Os experimentos foram conduzidos em diferentes níveis de tensão, permitindo avaliar a resposta dos sensores às variações de intensidade das descargas parciais. Os resultados mostraram que os *buzzers* foram capazes de capturar e analisar adequadamente os sinais de descargas, apresentando comportamento proporcional ao aumento da intensidade do defeito. Dessa forma, os autores concluíram que sensores piezoelétricos de baixo custo possuem potencial para aplicações em manutenção preditiva elétrica, contribuindo para a redução de custos operacionais e aumento da confiabilidade do monitoramento.

Pimentel-Junior et al. (2016) investigaram a aplicação de técnicas de EA na detecção de trincas transversais em eixos rotativos submetidos a ensaios de impacto (*bump tests*). Para isso, os autores utilizaram seis eixos de aço AISI 1020 com diferentes profundidades de trinca, além de um sensor EA de banda larga e um sistema de aquisição de alta frequência. A análise dos sinais foi realizada por meio da Transformada Wavelet e de parâmetros estatísticos, como curtose e assimetria. Os resultados mostraram que o aumento da profundidade da trinca provocou redução nos valores de curtose e assimetria dos sinais de EA, indicando alterações na distribuição das amplitudes associadas ao defeito. Com base nesses resultados, os autores concluíram que as técnicas de EA apresentaram elevada sensibilidade para identificar e monitorar o crescimento de trincas em eixos rotativos.

Elasha et al. (2017) avaliaram a eficácia das técnicas de vibração e EA para o diagnóstico de defeitos em rolamentos dentro de caixas de engrenagens planetárias. O estudo fez uso de técnicas de Curtose Espectral e análise de envelope nos sinais processados, mostrando que a EA teve maior eficácia na determinação de defeitos incipientes, enquanto a vibração apresentou limitações em condições de ruído elevado.

Elizarov et al. (2018) investigou a aplicabilidade da técnica de EA para monitorar equipamentos industriais em condições operacionais de carregamentos estáticos e cíclicos, como rolamentos de fornos rotativos. A pesquisa abordou as restrições da técnica de EA em cenários onde há um alto nível de ruído e de variações na carga durante a operação dos sistemas. Para superar essas limitações, os autores implementaram metodologias de monitoramento contínuo, juntamente com

algoritmos de filtragem, análise de *clusters* e técnicas de localização de sinais, permitindo a distinção entre eventos associados a defeitos e aqueles relacionados ao ruído do processo. Os resultados indicaram que a abordagem foi eficiente em detectar sinais relacionados a trincas, microtrincas, desgaste e falhas estruturais, mesmo sob condições de operação ininterrupta.

A fim de monitorar a propagação de trincas em eixos de máquinas rotativas suportadas por mancais de filme fluido, Faria e Pimentel-Junior (2018) analisaram sinais de EA na identificação de defeitos para diferentes profundidades de trincas. Duas condições de operação foram aplicadas na pesquisa, em velocidades subcríticas e supercríticas, respectivamente. A transformada Wavelet foi utilizada para decomposição dos sinais de EA, o que permitiu uma análise detalhada das características temporais e em frequência associadas à propagação das trincas. A metodologia apresentada identificou com precisão o comportamento das trincas, principalmente na detecção de defeitos em estágios iniciais de propagação.

Viera et al. (2019a) apresentaram um trabalho utilizando sensores piezoelétricos (PZT) para o monitoramento de EA na retificação de cerâmica, a fim de avaliar a qualidade da superfície. Foram comparados os sinais obtidos pelo PZT com os sinais de sensores comerciais tradicionais de EA, podendo ser demonstrado na pesquisa que ambos sensores fornecem resultados semelhantes. A metodologia apresentada para análise tempo-frequência foi a Transformada de Fourier de Curto Prazo (STFT), a qual identificou irregularidades e defeitos no processo estudado. Pode-se destacar a viabilidade do PZT como uma alternativa de baixo custo para a aplicação no monitoramento em tempo real de processos industriais.

Viera et al. (2019b) investigaram o uso de sensores PZTs para o monitoramento da integridade superficial de cerâmicas durante o processo de retificação. Os experimentos foram realizados em diferentes condições de usinagem, abrangendo regimes leves a severos. Nesta etapa, foi realizada uma comparação entre os sinais obtidos pelos PZTs e os sinais obtidos por sensores comerciais de EA. A metodologia empregada incluiu análises no domínio do tempo e da frequência, utilizando métricas como o *Root Mean Square* (RMS) e a Transformada Rápida de Fourier (FFT). Os resultados obtidos demonstraram comportamento similar entre os sensores PZT e os sensores comerciais, além de forte correlação entre os sinais adquiridos e os parâmetros de qualidade superficial, notadamente a rugosidade média (R_a). Com base nos resultados obtidos, os autores concluíram que esses sensores apresentam potencial para aplicações de monitoramento em tempo real com baixo custo e boa confiabilidade.

Outro trabalho investigando a capacidade de sensores PZTs/PWAS para detectar sinais de EA

gerados por trincas em superfícies metálicas devido ao atrito e batidas foi apresentado por Joseph, Bhuiyan e Giurgiutiu (2019). Para a coleta dos resultados, os PZTs foram estrategicamente posicionados em diferentes distâncias da trinca para avaliar a propagação geométrica dos sinais de EA. A pesquisa demonstrou que os sinais de EA são extremamente sensíveis às modificações no comportamento da trinca em movimentos dinâmicos, fornecendo sinais distintos e perceptíveis das assinaturas acústicas em frequências particulares.

Mei et al. (2019) apresentaram uma revisão sobre a utilização de sensores PWAS/PZTs em aplicações de SHM. O trabalho discutiu os avanços atuais do uso de materiais piezoelétricos e suas aplicações em condições severas de análise, como a exposição à radiação e à temperaturas elevadas. Dessa forma, foi demonstrado que os PWAS mantiveram sua integridade estrutural mesmo sob essas condições. Os autores validaram a detecção de EA aplicando os PWAS em tempo real tanto por métodos ativos quanto passivos, o que confirmou sua eficiência na identificação do crescimento de trincas e impactos de baixa velocidade. O estudo concluiu que esses sensores são soluções viáveis e econômicas para SHM devido ao seu baixo custo, leveza e capacidade de integração em grandes áreas estruturais.

Com o objetivo de caracterizar a evolução de descargas parciais (PDs) em transformadores de potência, Santos et al. (2020) apresentaram uma nova metodologia. Foram utilizados sensores PZTs para coletar os sinais de EA gerados por PDs e a Transformada Wavelet Discreta (DWT) para analisar os coeficientes de aproximação e detalhes dos sinais. Na caracterização e identificação dos estágios de degradação dielétrica foram utilizados os valores de Energia apresentados por esses coeficientes. A pesquisa pode demonstrar a eficácia de detecção precoce de defeitos, o que auxilia no planejamento de manutenção e em uma maior confiabilidade de um sistema elétrico.

No estudo de Caso et al. (2020) sensores de EA foram utilizados para identificar desalinhamentos em eixos engrenados operando em baixas velocidades. Testes experimentais foram realizados em diferentes combinações de carga e velocidades de operação, objetivando analisar padrões acústicos característicos de falha por desalinhamento. Os resultados puderam demonstrar que os sinais de EA apresentam alta sensibilidade ao desalinhamento, mesmo sob condições operacionais complexas.

Li et al. (2020) propuseram uma metodologia que integra a EA com Rede Adversariais Generativas Condicionais (cGAN) para detecção de defeitos por roçamento. A partir disso, foram gerados dados sintéticos de alta qualidade, que superaram os dados reais, os quais além

de apresentarem limitações em sua disponibilidade para treinamento, são afetados por ruídos ambientais. A metodologia proposta possibilitou identificar defeitos de forma mais precisa e robusta, mesmo em ambientes ruidosos, contribuindo para a manutenção preditiva na indústria.

Lucas et al. (2020b) apresentaram um estudo usando PZTs na coleta de sinais de EA para estimar a carga em motores de indução trifásicos. Os autores aplicaram Transformada Wavelet (WT) para as análises correlacionando as alterações no padrão de vibração com diferentes condições de carga. Com isso, foi demonstrado que mudanças na carga afetam diretamente o padrão das emissões e vibração.

Mokhtari et al. (2020) realizaram um trabalho experimental monitorar desgaste e regimes de atrito em mancais de deslizamento de turbofans engrenados. Para isso, fizeram uso de sinais de EA combinados com algoritmos de aprendizado de máquina. Condições diferentes de testes foram empregadas: uma para avaliar o atrito sob condições controlada de temperatura e outra, para identificar a relação entre a viscosidade do óleo e os estados de atrito. A Transformada Wavelet Contínua (CWT) foi usada como metodologia para a análise dos sinais. Como método de classificação foi empregado o *Support Vector Machines* (SVM), permitindo identificar os regimes de atrito e monitorar o desgaste progressivo ao longo do tempo. A pesquisa apresentou uma correlação clara entre o volume de desgaste acumulado e os valores RMS dos sinais de EA.

Lucas et al. (2020a) apresentaram uma nova metodologia para a detecção de falhas em motores de indução trifásicos (TIMs) utilizando sinais de EA medidos por sensores PZTs. Foram analisados em condições controladas, os desequilíbrios de tensão (VU), identificação da fase afetada e classificação da magnitude do desequilíbrio. Dessa forma, foi mostrado que os resultados alcançaram uma precisão de 100% na detecção de VU e acima de 96% na identificação da fase afetada. Conforme demonstrado no estudo, uma correlação forte entre os valores de energia e de magnitude do VU foi capaz de validar a eficácia do sistema para diagnósticos precisos.

Lopes et al. (2021) propuseram um estudo que avaliou operações de dressagem em rebolos de óxido de alumínio através do uso de sensores PZTs de baixo custo pela metodologia de EA. Testes experimentais foram realizados comparando o desempenho dos PZTs com sensores comerciais padrões de EA em dois tipos de rebolos e em condições de dressagem e não dressagem. Para essas análises foram utilizadas métricas de Densidade Espectral de Potência (PSD), coeficiente de correlação de Pearson e Coerência Quadrática Média tanto no domínio do tempo quanto da frequência. Pode-se observar pelos resultados, que os sensores apresentaram correlação superior

a 80% nas condições estudadas, e em uma faixa de frequência específica, alcançou mais de 90%, demonstrando a viabilidade de aplicação do PZT em monitoramento de processos de fabricação como alternativa eficaz e econômica.

Ciaburro e Iannace (2022) conduziram uma revisão sobre a utilização de técnicas de ML em conjunto com EA para identificação de danos estruturais. Os modelos fundamentados em ANN, CNN e RNN, capazes de detectar automaticamente falhas a partir de sinais brutos de EA, foram realçados no estudo, o que diminui a dependência de técnicas de pré-processamento convencionais e torna o modelo mais robusto em relação a ruídos e sinais não estacionários. Os resultados obtidos foram analisados e mostraram uma alta precisão no diagnóstico de falhas em diversas aplicações industriais. No entanto, os autores mencionaram limitações, como a necessidade de grandes quantidades de dados rotulados e o alto custo computacional. Por conseguinte, técnicas de ML apresentam grande potencial para elevar a confiabilidade e a precisão do monitoramento por EA.

Ju, Li e Jia (2022) exploraram o uso de métodos de ML para classificar defeitos estruturais com base em sinais de EA. A pesquisa investigou a aplicação de algoritmos não supervisionados, incluindo *K-means*, *Gaussian Mixture Model* (GMM), redes neurais competitivas e *Self-Organizing Feature Map* (SOFM), para contornar as limitações dos métodos tradicionais de avaliação, como a análise RA-AF. Os algoritmos de agrupamento mostraram uma classificação eficiente dos modos de falha, com uma acurácia superior a 90%, e o GMM se destacou com uma precisão de 97,33%. Os autores ainda constataram que a Análise de Componentes Principais (PCA) foi eficaz na extração das características mais importantes dos sinais de EA, o que melhorou o desempenho dos modelos de classificação.

Griffin e Giurgiutiu (2023) realizaram um estudo para analisar a eficácia de sensores PZTs na detecção de EA quando aplicados em SHM. A pesquisa destacou o desempenho desses sensores em captar sinais de alta frequência associados a defeitos estruturais, como trincas e delaminações. Os métodos analíticos compreenderam pitch-catch e impedância eletromecânica, permitindo identificar alterações nos espectros de frequência em consequência de defeitos na adesão ou no dano do sensor. Os resultados indicaram que, mesmo de baixo custo, os PWAS possuem desempenho similar aos sensores comerciais de EA, sendo uma alternativa para monitoramento em tempo real e manutenção preditiva. O trabalho reafirmou o papel do PWAS como uma solução econômica e eficaz para diagnóstico não destrutivo em ambientes industriais e aeroespaciais.

Lucas et al. (2023) propuseram uma metodologia que utiliza sensores PZT e sinais de EA

para diagnosticar curto-circuitos transitórios entre espiras (ITSC) em TIMs. Para detectar o defeito, identificar a fase afetada e classificar sua severidade, o estudo empregou a Transformada Wavelet Discreta (DWT), PCA e um novo índice estatístico que se baseia na correlação cruzada (CCMV). Os resultados indicaram uma alta eficiência do método, alcançando mais de 90% de precisão na detecção das fases com falha e na classificação da intensidade dos ITSCs. Os autores também notaram que o algoritmo manteve sua eficácia em ambientes industriais barulhentos e que apenas um único sensor PZT foi necessário para garantir um monitoramento confiável.

Diante do estado da arte apresentado, esta Tese de Doutorado propõe uma contribuição relevante para o desenvolvimento de metodologias voltadas ao monitoramento e diagnóstico de roçamento em máquinas rotativas por meio da utilização de sensores PZT e *buzzers* na aquisição de sinais de EA. A análise dos dados obtidos em ensaios experimentais possibilita uma avaliação abrangente do comportamento dinâmico e das funcionalidades desses sistemas sob diferentes condições de velocidade de rotação. Além disso, a aplicação de metodologias de diagnóstico baseadas em técnicas de aprendizado de máquina contribui para resultados mais precisos e robustos, favorecendo estratégias de manutenção preditiva e reduzindo paradas não programadas que impactam diretamente os custos operacionais.

CAPÍTULO III

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados os fundamentos teóricos para o monitoramento do roçamento em máquinas rotativas por meio da técnica de Emissão Acústica (EA). Inicialmente, serão descritos o conceito e os princípios da EA para, em seguida, abordar sobre os sensores piezelétricos, com ênfase naqueles que são construídos a partir do titanato-zirconato de chumbo (PZT) e naqueles conhecidos como *buzzer*. Na sequência, são exploradas as principais metodologias utilizadas para processamento de sinais utilizadas na análise dos dados coletados, incluindo a FFT, a análise envelope (Transformada Hilbert), métodos estatísticos e *Wavelet*, destacando suas contribuições na identificação de padrões de defeitos. Além disso, são apresentados os conceitos do aprendizado de máquinas, discutindo os principais algoritmos empregados para a classificação de dados, os indicadores de desempenho utilizados para avaliação dos modelos e algumas das bibliotecas computacionais que foram utilizadas nas abordagens desta tese. Por fim, são descritos brevemente os modelos de ML que obtiveram os melhores resultados na classificação dos sinais de EA neste estudo.

3.1 Princípios Básicos de Emissão Acústica

A EA é uma técnica de END passiva utilizada para detecção de defeitos em micro e macro escala, sendo capaz de identificar trincas, desalinhamento, desbalanceamento, roçamento, defeitos incipientes em mancais, vazamentos, corrosão, entre outros. Entre as vantagens dessa metodologia destacam-se pela sua alta sensibilidade, a ampla cobertura da região analisada e a possibilidade de monitoramento em tempo real.

O fenômeno da EA pode ser descrito como a geração de ondas transitórias que se propagam

pela estrutura, resultantes da liberação rápida de energia em fontes localizadas, sejam elas internas ou superficiais (PAO; GAJEWSKI; CERANOGLU, 1979; NOR, 2018). No contexto desta tese, a EA é caracterizada por ondas elásticas transitórias geradas pela interação entre duas superfícies em movimento relativo devido ao roçamento, um aspecto fundamental para a identificação de defeitos associados ao roçamento entre componentes mecânicos.

Um dos estudos de destaque na identificação de sinais de EA foi a tese de Kaiser (1950). O autor constatou que os materiais, ao serem submetidos a esforços mecânicos, tendem a emitir sinais de EA em razão da liberação de energia associada a microdeformações ou alterações internas. Outra questão observada, foi que após a interrupção desses sinais, uma nova emissão só ocorrerá se o material for novamente submetido a tensões superiores àquelas que geraram os sinais anteriores. Esse comportamento é conhecido na literatura como *Efeito Kaiser* e reflete a capacidade do material de "memorizar" o nível de tensão aplicado anteriormente, não emitindo sinais adicionais até que esse limiar seja ultrapassado.

A partir disso, a técnica de EA captura essas perturbações que geram ondas transitórias através do uso de sensores piezoelétricos que são instalados de forma estacionária sobre a estrutura do equipamento que está sendo monitorado, transformando a energia mecânica em elétrica, e após isso, esses sinais são digitalizados e arquivados para análises posteriores, podendo ser ou não amplificados antes desse processamento (HOLFORD et al., 2013; REZINSKIKH; LUK'YANENKO; SARKISYAN, 2014).

Dentre as técnicas de avaliação de danos descritas na literatura, a EA tem mostrado resultados com alta eficiência. Segundo Holford (2009), isto se deve a três aspectos: não é necessária uma fonte externa para fornecer energia porque essa é originada pela própria estrutura; é capaz de detectar os processos dinâmicos reais associados à degradação da integridade estrutural; e por último, os sensores podem ser fixados em diferentes lugares na estrutura em análise pois são capazes de detectar e localizar uma fonte de EA nas proximidades.

O resultado é uma técnica sensível com um potencial considerável para uma variedade de aplicações, oferecendo assim, novos desafios de pesquisa em engenharia. Além disso, com uma estratégia de monitoramento decisivo implementada, a EA é capaz de monitorar grandes estruturas de alta complexidade com um número relativamente pequeno de sensores. Entretanto, para uma inspeção estrutural utilizando métodos de EA, é importante determinar a relação sinal-ruído e, dessa forma, reduzir a intensidade ou atenuação do sinal.

Máthis e Chmelík (2012) classificam as fontes de EA como dois tipos principais: contínuas

ou descontínuas, que podem ocorrer simultaneamente. As emissões contínuas caracterizam-se por ter uma amplitude acima de um limite específico por um longo intervalo de tempo, sendo associados a fenômenos como deformação plástica e tensões internas nos materiais. Por outro lado, as emissões descontínuas manifestam-se como picos de amplitude bem definidos no domínio do tempo, estando relacionados ao surgimento ou à propagação de um dano, como uma trinca, bem como processos de corrosão.

Os ensaios de EA possuem características únicas quando comparados aos métodos tradicionais de monitoramento. A principal função da EA, é observar a evolução dessas discontinuidades enquanto tensões que estão sendo aplicadas. Isso ocorre desde que as cargas sejam suficientes para induzir fenômenos como deformações localizadas, propagação de defeitos, fricção entre superfícies, entre outros (SILVA et al., 2010).

A técnica de EA se mostra especialmente valiosa em situações que exigem a análise do comportamento dinâmico de defeitos em componentes ou estruturas metálicas complexas. Adicionalmente, ela possibilita o registro preciso da localização desses eventos, tornando-se uma ferramenta extremamente útil para a análise estrutural e o monitoramento em tempo real.

A Figura 3.1 mostra um esquema da aquisição de dados de EA em um vaso pressurizado com uma trinca. Como o vaso já se encontra sob um estado de tensões devido à sua pressurização, a ocorrência ou propagação de uma trinca gera ondas de EA captadas pelos sensores posicionados na estrutura. Os dados coletados pelos sensores são adquiridos pelo sistema de aquisição para serem tratados e interpretados.




Figura 3.1: Esquema de detecção de ondas de EA. Fonte: Adaptado de Filippin (2017).

Os principais parâmetros do sinal de EA utilizados para determinar e avaliar danos estruturais são: amplitude, energia, duração, limiar de detecção, frequência, contagem e tempo de subida

(NOR, 2018; WEVERS; LAMBRIGHS, 2009), conforme ilustra a Fig. 3.2. Esses parâmetros (Fig. 3.2) utilizados em inspeções tradicionais com a técnica de EA são definidos de acordo com a norma ASTM (2014) como:




Figura 3.2: Forma de onda de EA simplificada. Fonte: (FILIPPIN, 2017).

- **Limiar de detecção (*threshold*):** nível de tensão em um comparador eletrônico em que sinais com amplitudes superiores a esse nível serão reconhecidos. Esse nível pode ser ajustado pelo usuário, ser fixo ou flutuar automaticamente. É utilizado para filtrar o ruído durante o monitoramento por EA. Um limiar adequado é estabelecido usando um teste de ruído;
- **Amplitude:** pico de magnitude em tensão da maior excursão alcançada pela onda do sinal de EA em um evento de emissão.
- **Duração:** é o tempo entre o início e o fim de um sinal de emissão acústica, contado a partir do primeiro cruzamento de limiar até o último. Geralmente é medido em microssegundos. Esse parâmetro é útil na caracterização da falha, crescimento e nucleação;

- **Energia:** a área absoluta (positiva e negativa) medida do sinal retificado com unidade proporcional a volts-segundos. Está relacionada à quantidade de energia liberada pelo objeto à medida que o defeito cresce;
- **Contagem:** número de vezes que o sinal de EA ultrapassa o limiar de detecção em qualquer porção selecionada de um teste;
- **Frequência:** número de ciclos por segundo da variação de pressão em uma onda. Como uma onda de EA é composta de múltiplos componentes de frequência, é utilizada a frequência média, definida como a contagem dividida pela duração;
- **Tempo de subida:** tempo entre a primeira ultrapassagem de limiar e a amplitude de pico.

No processamento da forma de onda de EA, as informações necessárias para o monitoramento do mecanismo são caracterizadas como eventos de emissão ou *hits*, representando essa energia acústica gerada por fenômenos físicos, como roçamentos, impactos ou microfissuras. Os *hits* identificam padrões que podem estar associados a anomalias em máquinas rotativas e com uma análise mais detalhada, pode-se oferecer *insights* sobre a localização e a gravidade dos danos, o que é útil para implementações em manutenção preditiva.

Com isso, ao iniciar o monitoramento pela técnica de EA em qualquer estrutura ou máquina, faz-se necessário realizar a identificação e localização das fontes de ruído antes e durante o ensaio. Normalmente, estes ruídos são provenientes do equipamento, material, instalações ou meio utilizado para o ensaio de EA.

3.2 Sensor Comercial de Emissão Acústica

Os sensores de EA são usados em muitas aplicações de END e monitoramento estrutural, e são definidos, em especial, pela largura de banda de funcionamento, sensibilidade e faixa de temperatura de operação. Estes sensores empregam materiais piezoelétricos que transformam ondas mecânicas em sinais elétricos, possibilitando a captura de eventos sonoros relacionados à propagação de falhas estruturais.

A estrutura básica de um sensor comercial de EA pode ser vista na Figura 3.3. Esse dispositivo conta com um elemento piezoelétrico, que se conecta a uma base rígida e é protegido por uma carcaça metálica. Dentro dessa carcaça, há materiais para amortecimento e também para blindagem eletromagnética. Quando o sensor é exposto a tensões mecânicas, o elemento

piezoelétrico gera diferenças de potencial elétrico, graças ao conhecido efeito piezoelétrico. Isso permite que o sensor detecte as ondas acústicas que se propagam pela estrutura. A forma como o sensor reage a diferentes frequências está diretamente ligada às suas características geométricas e à massa do elemento piezoelétrico.

Os sensores de EA podem ser fixados à estrutura utilizando-se bases magnéticas, fitas adesivas ou, em certas situações, adesivos estruturais. Em contextos de monitoramento, é uma prática usual empregar acoplantes entre o sensor e a superfície que está sendo monitorada. O objetivo disso é reduzir ao mínimo a presença de ar na interface e, assim, otimizar a transmissão das ondas acústicas. Para essa função, alguns dos materiais mais frequentemente empregados incluem graxas de silicone, diferentes tipos de adesivos, glicóis com alto peso molecular, e acoplantes ultrassônicos específicos.




Figura 3.3: Estrutura básica de um sensor padrão de EA. Fonte: (FILIPPIN, 2017).

No início deste trabalho, foi utilizado o sensor de EA modelo R15I-AST, um modelo comercial da *Physical Acoustics Corporation* (PAC). Esse equipamento já vinha com um pré-amplificador de 40 dB, um filtro embutido e funcionava numa faixa de 50 kHz a 400 kHz, com sua frequência de ressonância em 150 kHz. Embora fosse bem sensível e não sofresse muito com ruídos, ele precisava de um condicionador próprio e uma fonte de alimentação externa de 28 V. Isso tornava o seu uso, tanto na operação quanto nos experimentos, bastante caro.

Por causa dessa limitação, foi decidido utilizar pastilhas piezoelétricas de PZT, que foram coladas diretamente no mancal da bancada experimental deste trabalho. Esses sensores são mais baratos, muito sensíveis e fáceis de instalar. Já são bastante estudados para monitorar máquinas

rotativas, usando a mesma técnica de EA. Assim, ao usá-los nesta tese, foi possível criar uma forma alternativa e prática de detectar quando há roçamento em rotores, algo que funcionou bem nos testes realizados nesta tese.

3.3 Pastilhas Piezelétricas

As pastilhas piezelétricas (PZT) têm sido muito estudadas em diferentes áreas, como monitoramento de estruturas, controle de vibrações e detecção de danos. Isso acontece porque elas oferecem várias vantagens, como um baixo custo, uma grande sensibilidade e uma facilidade de implementação (VIERA et al., 2019b).

Em aplicações de Engenharia, os materiais à base de titanato-zirconato de chumbo são frequentemente utilizados devido à sua grande capacidade de conversão entre energia elétrica e mecânica. Isso é muito útil em dispositivos que precisam realizar essa conversão de forma eficiente.

Os PZTs podem funcionar de duas maneiras: como sensores, que detectam mudanças na estrutura, ou como atuadores, que aplicam forças para controlar a estrutura. Em alguns casos, eles podem fazer as duas coisas ao mesmo tempo, graças aos efeitos piezelétricos direto e inverso. O efeito piezelétrico direto ocorre quando o material é submetido a uma força mecânica e, em resposta, gera uma diferença de potencial elétrico. Já o efeito inverso acontece quando um campo elétrico é aplicado ao material, causando uma deformação mecânica.

Se considerarmos a piezoelectricidade linear e ignorarmos os efeitos térmicos e magnéticos, podemos descrever o comportamento eletromecânico do material usando as Eqs. (3.1) e (3.2), como foi apresentado por Castro et al. (2016).

$$D_i = d_{ikl}T_{kl} + \epsilon_{ik}^T E_k \quad (3.1)$$

$$S_{ij} = s_{ijkl}^E T_{kl} + d_{kij} E_k \quad (3.2)$$

em que D_i representa o deslocamento elétrico, E_k o campo elétrico aplicado, T_{kl} o tensor de tensões mecânicas, S_{ij} a deformação mecânica, d_{ikl} e d_{kij} as constantes piezelétricas e s_{ijkl}^E a constante de conformidade elástica em campo elétrico constante. Os subscritos decorrem da

notação indicial utilizada na formulação tensorial.

No âmbito desta tese, os PZTs foram empregados como sensores, valendo-se do efeito piezoelétrico direto para transformar deformações mecânicas geradas pela propagação de ondas acústicas em sinais elétricos. Essa propriedade possibilitou o monitoramento dos sinais de EA relacionados ao fenômeno de roçamento na bancada experimental.

Foram utilizados dois tipos de sensores piezoelétricos neste estudo: o PZT convencional de titanato-zirconato de chumbo (Fig. 3.4(a)) e o diafragma piezoelétrico comumente conhecido como *buzzer* comercial (Fig. 3.4(b)).




Figura 3.4: Sensores piezoelétricos utilizados neste estudo para coleta dos sinais de EA: PZT (a) e *Buzzer* (b).

Os *buzzers* consistem em um disco cerâmico piezoelétrico acoplado a uma base metálica, geralmente de latão, e são amplamente utilizados em dispositivos eletrônicos para a geração de som. Devido ao seu baixo custo e ampla disponibilidade, esses componentes têm sido investigados em aplicações de ensaios não destrutivos, apresentando desempenho similar ao de sensores comerciais na identificação de defeitos (CASTRO et al., 2016; VIERA et al., 2019b; VIERA et al., 2020; LUCAS et al., 2020b; LOPES et al., 2021; LUCAS et al., 2023).

Embora a literatura aponte resultados promissores, a utilização de transdutores PZTs e *buzzers* no monitoramento de desgastes por roçamento em máquinas rotativas por meio de sinais de ensaio não destrutivo ainda não está suficientemente explorada. Assim, esta tese busca avançar

no desenvolvimento de metodologias de monitoramento que empreguem sensores piezelétricos acessíveis como alternativa aos métodos tradicionais baseados em vibração, com o objetivo de aprimorar a sensibilidade na detecção de falhas iniciais e otimizar os custos envolvidos nos experimentos.

3.4 Técnicas de processamento de sinais para Emissão Acústica na detecção de defeitos em máquinas rotativas

O processamento de sinais de EA exerce um papel crucial na detecção e caracterização de defeitos em máquinas rotativas, ao possibilitar a extração de informações relevantes relacionadas à presença e ao desenvolvimento de falhas. Métodos estatísticos que operam nos domínios do tempo e da frequência têm sido amplamente adotados, em virtude de sua simplicidade computacional e capacidade de detectar mudanças nos padrões dos sinais associadas a defeitos iniciais. Ademais, técnicas mais sofisticadas, como a análise por envelope fundamentada na Transformada de Hilbert, a Transformada Wavelet e a análise cicloestacionária, têm sido empregadas com o intuito de aumentar a sensibilidade na identificação de falhas complexas em sistemas rotativos.

Recentemente, a incorporação de técnicas de inteligência artificial e aprendizado de máquina no processamento dos sinais de EA tem possibilitado a identificação automática de padrões vinculados a distintas condições operacionais e modos de falha (CIABURRO; IANNACE, 2022; JU; LI; JIA, 2022). Tais abordagens aprimoram a robustez do diagnóstico, mesmo em contextos caracterizados por ruído ambiental e comportamentos dinâmicos não lineares dos sistemas, favorecendo, assim, a aplicação em monitoramento preditivo e na classificação automática de defeitos.

Apesar de muitas técnicas aplicadas em sinais de EA terem origem na literatura referente à análise de vibrações, os sinais acústicos apresentam particularidades, como uma faixa de frequência mais ampla, natureza transitória e maior sensibilidade a fenômenos impulsivos (CHACON, 2015a). Dessa maneira, a adoção dessas metodologias em sinais de emissão acústica exige adaptações específicas para assegurar precisão na detecção e na caracterização dos defeitos, como exemplificado pelo fenômeno de roçamento investigado nesta tese.

3.4.1 Transformada rápida de Fourier

A análise espectral empregando a Transformada Rápida de Fourier (FFT) configura-se como uma das metodologias mais recorrentes no processamento de sinais de EA e vibração, uma vez que viabiliza a identificação de componentes harmônicos, frequências distintas e variações espectrais relacionadas à eventual presença de falhas (VIERA et al., 2019b). Por meio da FFT, é possível converter sinais do domínio temporal para o domínio da frequência, o que facilita o reconhecimento de padrões vinculados ao comportamento dinâmico do sistema monitorado. A Figura 3.5 ilustra um exemplo da representação de um mesmo sinal nos domínios do tempo e da frequência.




Figura 3.5: Representação de um mesmo sinal no domínio do tempo e da frequência. Fonte: Adaptada de Oliveira Neto et al. (2023).

Para um sinal contínuo no tempo, $x(t)$, a Transformada de Fourier é definida pela Eq. (3.3).

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (3.3)$$

A transformação inversa, que recupera o sinal no domínio temporal a partir de seu espectro em frequência, encontra-se descrita na Eq. (3.4).

$$x(t) = \int_{-\infty}^{+\infty} X(f) e^{j2\pi ft} df \quad (3.4)$$

em que j representa a unidade imaginária.

Considerando que, na prática, os sinais adquiridos experimentalmente são discretos, a Transformada Discreta de Fourier (DFT) apresenta-se como mais apropriada para aplicações computacionais. A FFT corresponde a um algoritmo que otimiza o cálculo da DFT, reduzindo significativamente o custo computacional associado à análise espectral (ORALLO et al., 2013). Para uma sequência discreta $x(n)$ composta por N amostras, a DFT é expressa conforme a Eq. (3.5).

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} f(k) e^{-j2\pi \frac{kn}{N}} \quad (3.5)$$

em que k representa o índice no domínio da frequência e n o índice no domínio do tempo.

Os coeficientes espectrais gerados pela DFT possibilitam a avaliação da distribuição da energia do sinal em diferentes frequências. No âmbito deste estudo, a FFT foi utilizada para identificar componentes espectrais relacionadas ao fenômeno de roçamento nos sinais de EA, contribuindo assim para a caracterização dinâmica do defeito e para a extração de atributos relevantes para os algoritmos de classificação.

3.4.2 *Análise Envelope com base na Transformada de Hilbert*

A análise envelope é uma técnica muito usada no processamento de sinais de EA e vibração para encontrar componentes modulados em amplitude que estão relacionados a defeitos mecânicos. Isso ajuda a destacar assinaturas relacionadas a impactos e excitações impulsivas em sistemas rotativos, o que é importante para detectar falhas precocemente em componentes como rolamentos e engrenagens (SIEGEL et al., 2012; ELASHA et al., 2017). Quando se analisa um sinal demodulado, as informações relevantes sobre a condição do sistema tendem a se concentrar em frequências características associadas ao defeito.

Quando há defeitos em rolamentos, como danos nas pistas interna e externa, isso gera impactos repetitivos que podem modular componentes de alta frequência. A análise envelope permite extrair essas modulações e identificar frequências características relacionadas às falhas. O procedimento envolve selecionar uma faixa ressonante de alta frequência, aplicar um filtro passa-banda e, em seguida, demodular o sinal usando a Transformada de Hilbert. Depois disso, a FFT ou a densidade espectral de potência são aplicadas ao envelope para mostrar componentes espectrais associadas ao defeito. É fundamental escolher a banda de filtragem certa para aumentar

a sensibilidade da metodologia (GU; CHOI, 2011; SIEGEL et al., 2012; ELASHA et al., 2017; FILHO, 2018).

A Transformada de Hilbert possibilita a obtenção do sinal analítico, que resulta da combinação do sinal original com sua componente imaginária derivada da transformação do sinal. Para um sinal $x(t)$, a Transformada de Hilbert $\hat{x}(t)$ é formalmente definida pela Eq. (3.6) (HEMMATI; ALQARADAWI; GADALA, 2016).

$$\hat{x}(t) = \frac{1}{\pi t} * x(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (3.6)$$

em que τ representa a variável de integração. A partir dessa transformada, o sinal analítico pode ser expresso conforme a Eq. (3.7).

$$h(t) = x(t) + j\hat{x}(t) = a(t)e^{j\phi(t)} \quad (3.7)$$

Neste caso, $x(t)$ corresponde à parte real do sinal analítico, $\hat{x}(t)$ representa a componente imaginária, $a(t)$ define o envelope do sinal e $\phi(t)$ a fase instantânea. O cálculo do envelope e da fase instantânea segue a Eq. (3.8).

$$a(t) = \sqrt{x^2(t) + \hat{x}^2(t)}, \quad \phi(t) = \arctan\left(\frac{\hat{x}(t)}{x(t)}\right) \quad (3.8)$$

Conforme reportado por Randall e Antoni (2011), defeitos em rolamentos geram impactos periódicos que modulam componentes de alta frequência, o que justifica o uso da análise envelope para a detecção dessas falhas. No presente trabalho, o fenômeno de roçamento entre superfícies rotativas e estacionárias também ocasiona modulações na amplitude dos sinais. Por esse motivo, a análise envelope foi adotada para realçar componentes espectrais associadas ao roçamento leve em sinais de EA, incrementando a sensibilidade na identificação desses defeitos mesmo sob condições operacionais caracterizadas por níveis elevados de ruído.

3.4.3 Métodos Estatísticos

Os sinais de EA exibem características intrinsecamente vinculadas às condições operacionais de máquinas rotativas, possibilitando a detecção de modificações relacionadas a defeitos como roçamento, desbalanceamento e falhas estruturais. Neste cenário, métodos estatísticos

aplicados no domínio do tempo são amplamente adotados, atribuindo-lhes preferência pela simplicidade computacional aliada à sensibilidade na identificação de variações nos padrões dos sinais (ELIZAROV et al., 2018; ELFORJANI; MBA, 2011).

Parâmetros tais como RMS, energia, fator de crista, variância, valor pico e curtose permitem uma caracterização quantitativa dos sinais de EA, sendo recorrentes em estratégias de monitoramento de condição e diagnóstico preliminar de falhas (CHACON, 2015a; Oliveira Neto et al., 2023).

O valor RMS (*root mean square*) quantifica a amplitude média eficaz do sinal, tendo aplicação frequente para detectar incrementos de energia que possam estar associados à presença de defeitos. Para um sinal discreto contendo N amostras, o RMS é expresso conforme a Eq. (3.9) (CHACON, 2015a; HECKE; QU; HE, 2015).

$$x_{rms} = \sqrt{\left(\frac{1}{N}\right) \sum_{i=1}^N x_i^2} \quad (3.9)$$

Nessa equação, x_i indica a i -ésima amostra do sinal e N representa o número total de amostras. Segundo Al-Ghamd e Mba (2006), este parâmetro apresenta elevada sensibilidade para a detecção de falhas em seus estágios iniciais.

A energia do sinal reflete a intensidade global dos eventos acústicos decorrentes de impactos, roçamentos e excitações dinâmicas. Em registros de EA, elevações na energia podem sugerir aumento da atividade mecânica provocada por defeitos, como roçamento ou falhas em componentes rotativos. A energia de um sinal discreto é descrita pela Eq. (3.10).

$$E = \sum_{i=1}^N x_i^2 \quad (3.10)$$

onde E corresponde à energia total do sinal. Conforme destacado por Mokhtari, Grzeszkowski e Gühmann (2017), a combinação desse parâmetro com técnicas de análise envelope tende a melhorar a eficácia na detecção de falhas iniciais.

O fator de crista (CF, do inglês *Crest Factor*) é definido como a razão entre o valor máximo absoluto do sinal e seu valor RMS, conforme apresenta a Eq. (3.11). Esse índice revela particular sensibilidade a eventos impulsivos e transitórios associados a impactos e contatos intermitentes

(CHACON, 2015a).

$$CF = \frac{\max(|x_i|)}{x_{rms}} \quad (3.11)$$

A variância mensura a dispersão das amplitudes em relação à média do sinal, sendo útil para identificar alterações na dinâmica do sistema e modificações no comportamento dos sinais de EA (Oliveira Neto et al., 2023). Sua formulação está descrita na Eq. (3.12).

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (3.12)$$

onde μ representa a média do sinal.

O valor pico consiste na maior amplitude absoluta observada no sinal, sendo comumente utilizado para identificar eventos transitórios ou condições operacionais anômalas em máquinas rotativas (RANDALL, 2021). Esse parâmetro pode ser definido conforme a Eq. (3.13).

$$x_{pico} = \max(|x(t)|) \quad (3.13)$$

A curtose é um parâmetro estatístico utilizado para avaliar o grau de impulsividade do sinal, apresentando sensibilidade significativa para detectar eventos transitórios e impactos repetitivos (DURKHURE; LODWAL, 2014; PIMENTEL-JUNIOR et al., 2016; HEMMATI; ALQARADAWI; GADALA, 2016). Valores elevados de curtose indicam distribuições acentuadamente pontiagudas, geralmente relacionadas à presença de defeitos mecânicos. Sua expressão matemática está disposta na Eq. (3.14).

$$K = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2\right)^2} \quad (3.14)$$

onde K corresponde à curtose do sinal. Investigações como as de McFadden e Smith (1984) e Hemmati, Alqaradawi e Gadala (2016) destacam a eficácia deste parâmetro na identificação de eventos impulsivos em sinais de EA e vibração.

No âmbito desta pesquisa, os referidos parâmetros estatísticos foram empregados para caracterizar modificações nos sinais de EA associados ao fenômeno de roçamento, possibilitando a avaliação de variações vinculadas à intensidade do contato, à ocorrência de impactos e às flutuações dinâmicas do sistema rotativo.

3.4.4 Transformada Wavelet

A Transformada Wavelet (WT), introduzida por Morlet em 1974, é amplamente empregada no processamento de sinais não estacionários em virtude de sua capacidade de realizar análises conjuntas nos domínios do tempo e da frequência. Ao contrário da Transformada Rápida de Fourier (FFT), que pressupõe a estacionariedade do sinal, a WT permite a identificação das variações temporais das componentes espectrais, o que a torna especialmente adequada para a análise de sinais transientes e impulsivos presentes em aplicações de monitoramento por análise de vibração (EA) (YAN; GAO; CHEN, 2014; WEI et al., 2019; Oliveira Neto et al., 2023). Essa característica é favorecedora para a detecção de alterações sutis associadas à presença de defeitos em sistemas mecânicos rotativos.

Diversas implementações da WT são encontradas na literatura, incluindo a Transformada wavelet contínua (CWT), a Transformada wavelet discreta (DWT) e a Transformada de pacotes wavelet (WPT), cujas resoluções temporais e espectrais diferem entre si (YAN; GAO; CHEN, 2014; WEI et al., 2019). Na área de monitoramento de condição, destaca-se a DWT devido à sua menor complexidade computacional e à capacidade de realizar decomposição multirresolução, sendo amplamente utilizada na análise de sinais de EA relacionados a falhas em componentes rotativos (PIMENTEL-JUNIOR et al., 2016; FARIA; PIMENTEL-JUNIOR, 2018).

A DWT efetua a decomposição do sinal ao aplicá-lo sucessivamente a filtros passa-baixa e passa-alta, possibilitando a separação das componentes de baixa e alta frequência. No primeiro nível de decomposição de um sinal discreto $x[n]$, os coeficientes de detalhe $d_1[k]$ e de aproximação $a_1[k]$ são definidos pelas Eqs. (3.15) e (3.16) (YAN; GAO; CHEN, 2014; LUCAS et al., 2020a; CASTRO et al., 2022).

$$d_1[k] = \sum_n g_1[n - 2k]x[n] \quad (3.15)$$

$$a_1[k] = \sum_n h_1[n - 2k]x[n] \quad (3.16)$$

Nessas expressões, $g_1[n]$ e $h_1[n]$ correspondem, respectivamente, aos filtros passa-alta e passa-baixa. Os coeficientes de detalhe capturam componentes de alta frequência relacionadas a variações rápidas e eventos impulsivos, ao passo que os coeficientes de aproximação retêm

informações de baixa frequência associadas ao comportamento geral do sinal. A cada nível subsequente de decomposição, a taxa de amostragem é dividida por dois, viabilizando uma análise multirresolução do sinal (LUCAS et al., 2020a; Oliveira Neto et al., 2023). A Figura 3.6 ilustra um exemplo de decomposição em três níveis por meio da DWT.




Figura 3.6: Exemplo de sinal decomposto em três níveis pela transformada wavelet. Fonte: Adaptado de Oliveira Neto et al. (2023).

No contexto de sinais provenientes de análise de vibração, a DWT possibilita a extração de características relevantes associadas a impactos, modulações e eventos transitórios, o que auxilia na identificação de padrões indicativos de defeitos em máquinas rotativas. Embora esta técnica não tenha sido empregada diretamente nas fases experimentais da presente tese, sua fundamentação é considerada relevante, dada a sua ampla aplicação em monitoramento por análise de vibração e em metodologias para extração de características em sistemas de diagnóstico de falhas.

3.5 Aprendizado de Máquinas

O aprendizado de máquinas (ML – *Machine Learning*) constitui um ramo da inteligência artificial dedicado ao desenvolvimento de modelos capazes de reconhecer padrões, aprender a partir de dados e executar tarefas de classificação, regressão e predição sem a necessidade de programação explícita (CIABURRO; IANNACE, 2022; Oliveira Neto et al., 2023).

Baseado em princípios de estatística, otimização e ciência da computação, o ML tem sido amplamente aplicado em problemas relacionados a monitoramento de condição e diagnóstico de falhas, especialmente devido à sua aptidão para lidar com grandes volumes de dados e captar relações complexas entre variáveis.

No âmbito da manutenção preditiva, técnicas de ML são utilizadas na detecção automática de falhas em máquinas rotativas, a partir da análise de sinais provenientes de sensores de vibração, corrente elétrica e emissão acústica (EA). Tais abordagens possibilitam a identificação de padrões associados a distintas condições operacionais e modos de falha, o que contribui para o aprimoramento da confiabilidade dos diagnósticos e redução dos custos vinculados à manutenção corretiva (JU; LI; JIA, 2022; CIABURRO; IANNACE, 2022). Adicionalmente, os métodos de classificação baseados em ML demonstram boa capacidade de generalização mesmo diante de sistemas ruidosos ou com comportamento não linear.

Quando se tratam de aplicações envolvendo sinais de EA, a adoção do ML apresenta relevância particular, dado o caráter dos sinais acústicos, que frequentemente são compostos por eventos transitórios, componentes de alta frequência e baixa amplitude, além de estarem sujeitos a interferências de ruído e efeitos de atenuação.

Nesse contexto, técnicas de ML favorecem a extração de padrões significativos e aprimoram a sensibilidade na identificação de defeitos, ampliando a eficácia dos sistemas de monitoramento. A combinação entre EA e ML tem sido objeto de estudos relevantes em diagnósticos estruturais e monitoramento de máquinas rotativas, demonstrando avanços expressivos na classificação automática de falhas (CIABURRO; IANNACE, 2022; KUNDU, 2024).

Os modelos de ML podem ser classificados em três grandes grupos: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (Oliveira Neto et al., 2023). Nesta pesquisa, foram adotados métodos supervisionados de classificação, aplicados aos sinais de EA, com o objetivo de identificar as condições operacionais relacionadas ao fenômeno de roçamento.

3.5.1 Aprendizado não supervisionado

No aprendizado não supervisionado, os dados empregados no treinamento carecem de rótulos previamente definidos. Dessa maneira, os modelos buscam extrair padrões, agrupamentos ou relações inerentes aos dados de forma autônoma (BARELLA et al., 2021; Oliveira Neto et al., 2023). Técnicas como agrupamento (*clustering*), redução de dimensionalidade e detecção de anomalias são comumente adotadas para a análise de grandes volumes de dados não rotulados, viabilizando a identificação de comportamentos semelhantes e padrões latentes relevantes em aplicações de monitoramento de condição.

Dentre os métodos frequentemente utilizados, destacam-se o algoritmo k-médias para criação de grupos e a Análise de Componentes Principais (PCA) para redução da dimensionalidade. Em contextos que envolvem sinais de EA, essas estratégias podem contribuir para a distinção de padrões vinculados a distintas condições operacionais, bem como para a extração de características pertinentes a sistemas de diagnóstico de falhas. A Figura 3.7 ilustra um exemplo de aplicação de agrupamento na diferenciação entre estruturas com e sem danos.




Figura 3.7: Estruturas com e sem danos dado 2 características (a) e *Clusters* dessas estruturas (b).
Fonte: (BARELLA et al., 2021).

3.5.2 Aprendizado de reforço

O aprendizado por reforço (*Reinforcement Learning* – RL) caracteriza-se por uma abordagem em que um agente interage com o ambiente e aprende por meio de recompensas e penalizações associadas às ações tomadas (BARELLA et al., 2021; GÉRON, 2022). Diferentemente do aprendizado supervisionado, o RL não demanda dados rotulados, dependendo, em vez disso,

da habilidade do agente em maximizar uma recompensa acumulada ao longo do processo de treinamento.

No âmbito industrial, o RL tem sido explorado em tarefas como manutenção preditiva e otimização operacional, possibilitando a formulação de estratégias de intervenção fundamentadas no estado atual da máquina e em previsões de falha (SIRASKAR et al., 2023; SUPRAMANIAM; AHMAD; YUSOH, 2024). Ainda que sua utilização no diagnóstico de falhas em máquinas rotativas esteja em fase inicial, as técnicas de RL demonstram potencial para aplicação futura associada a sistemas inteligentes de monitoramento.

3.5.3 *Aprendizado supervisionado*

O aprendizado supervisionado envolve o treinamento de modelos a partir de dados que incluem rótulos, nos quais cada conjunto de entradas está relacionado a uma saída conhecida (BARELLA et al., 2021; Oliveira Neto et al., 2023). Durante essa etapa, o modelo identifica padrões que possibilitam a realização de previsões ou classificações para novos dados. Essa metodologia é amplamente aplicada em monitoramento de condição e diagnóstico de falhas em máquinas rotativas.

As tarefas supervisionadas podem ser categorizadas em classificação e regressão. Na classificação, busca-se atribuir categorias discretas às amostras, como estados normais ou defeituosos. Por sua vez, a regressão visa a estimar variáveis contínuas associadas ao comportamento do sistema (GÉRON, 2022; SEN; HAJRA; GHOSH, 2020). Em aplicações com sinais de EA, modelos supervisionados têm sido empregados na identificação automática de padrões relacionados a diferentes tipos de falhas e condições operacionais.

Recentemente, métodos de *ensemble learning* como Floresta Aleatória (*Random Forest* – RF), *Gradient Boosting Machines* (GBM) e *Extra Trees* (ET) ganharam destaque em virtude da sua capacidade de generalização e robustez perante dados ruidosos (GÉRON, 2022). Essas técnicas demonstram elevada eficiência na classificação de sinais de EA, especialmente quando tratam de relações não lineares e múltiplas variáveis.

Neste trabalho, métodos supervisionados foram aplicados aos sinais de EA com o objetivo de identificar condições associadas ao fenômeno de roçamento. A adoção dessas abordagens permitiu automatizar o processo de diagnóstico e aprimorar a confiabilidade na identificação das distintas condições operacionais de máquinas rotativas.

3.5.4 Avaliação da Performance de Modelos

Nesta tese, empregaram-se modelos supervisionados de classificação com o objetivo de identificar padrões relacionados ao fenômeno de roçamento a partir dos sinais de EA. O desempenho desses modelos foi avaliado por meio de métricas quantitativas que mensuram a eficiência dos algoritmos na distinção entre condições operacionais diversas. Para tal, utilizaram-se conjuntos de teste contendo amostras não vistas durante o treinamento, possibilitando a avaliação da capacidade de generalização dos modelos (BARELLA et al., 2021).

Dentre as métricas comumente adotadas em problemas de classificação, destacam-se acurácia, matriz de confusão, precisão (*precision*), *recall*, F_1 -score, curva ROC e AUC. A acurácia representa a proporção de classificações corretas em relação ao total de amostras e é adequada para conjuntos balanceados. Entretanto, em bases desbalanceadas, esta métrica pode levar a interpretações inadequadas, demandando o uso de medidas complementares.

A matriz de confusão possibilita uma análise detalhada do comportamento do classificador ao confrontar as classes reais com as previstas pelo modelo (IBM, 2024). No caso da classificação binária, essa matriz é composta por verdadeiros positivos (TP), falsos positivos (FP), falsos negativos (FN) e verdadeiros negativos (TN), conforme exemplificado na Fig. 3.8. No contexto desta pesquisa, os falsos negativos correspondem a situações em que o modelo não identifica corretamente a presença do roçamento, enquanto os falsos positivos indicam a classificação incorreta de condições normais como defeituosas.

A partir da matriz de confusão podem ser derivadas métricas adicionais, como precisão, *recall* e F_1 -score. A precisão quantifica a proporção de previsões positivas corretas, enquanto o *recall* avalia a capacidade do modelo em identificar todas as instâncias positivas. O F_1 -score corresponde à média harmônica entre precisão e *recall*, sendo especialmente relevante em contextos que exigem equilíbrio entre falsos positivos e falsos negativos (BARELLA et al., 2021; GÉRON, 2022). As definições dessas métricas são apresentadas nas Eqs. (3.17) a (3.19).

$$precision = \frac{TP}{TP + FP} \quad (3.17)$$

$$recall = \frac{TP}{TP + FN} \quad (3.18)$$




Figura 3.8: Matriz de confusão. Fonte: Traduzido de IBM (2024).

$$F_1 = \frac{2}{\frac{1}{precision} + \frac{1}{recall}} \quad (3.19)$$

A curva ROC (*Receiver Operating Characteristic*) é utilizada para avaliar o desempenho de classificadores binários sob diferentes limiares de decisão, relacionando a taxa de verdadeiros positivos (*True Positive Rate* – TPR) à taxa de falsos positivos (*False Positive Rate* – FPR). A área sob a curva ROC (AUC – *Area Under the Curve*) fornece uma medida global da capacidade discriminativa do modelo, com valores próximos a 1 indicando maior eficiência na separação entre as classes (BARELLA et al., 2021; GÉRON, 2022). A Figura 3.9 ilustra um exemplo de curva ROC.




Figura 3.9: Exemplo de curva ROC.

No âmbito desta tese, essas métricas serviram para avaliar a capacidade dos modelos em reconhecer padrões associados ao roçamento nos sinais de EA, viabilizando a comparação do desempenho dos classificadores e a análise de sua robustez diante de distintas condições operacionais da máquina rotativa.

3.6 Ferramentas para Criação de Modelos

3.6.1 Sklearn

O Scikit-Learn constitui uma das bibliotecas mais amplamente adotadas para aprendizado de máquina em Python, disponibilizando ferramentas para tarefas como classificação, regressão, agrupamento, redução de dimensionalidade e avaliação de modelos (BARELLA et al., 2021). A biblioteca oferece implementações eficientes de algoritmos clássicos, entre os quais máquinas de vetores de suporte (SVM), árvores de decisão, *Random Forest*, *Gradient Boosting* e métodos de agrupamento, sendo frequentemente utilizada em investigações relacionadas ao monitoramento de condição e diagnóstico de falhas.

Sua estrutura organiza os dados em matrizes de características (X) e vetores de saída (y), o que favorece a integração com bibliotecas consolidada na análise de dados, como NumPy e Pandas. Além disso, o Scikit-Learn fornece mecanismos para treinamento, validação, ajuste de

hiperparâmetros e avaliação de desempenho, facilitando a criação de pipelines robustos voltados para aplicações de classificação supervisionada (PEDREGOSA et al., 2011).

Para os objetivos desta tese, o Scikit-Learn foi empregado como plataforma para o treinamento, a validação e a avaliação dos algoritmos de classificação aplicados aos sinais de EA associados ao fenômeno de roçamento estudado.

3.6.2 *Pycaret*

Por sua vez, o PyCaret representa uma biblioteca *open source* desenvolvida em Python com o propósito de automatizar fluxos de trabalho em ML (PYCARET, 2024). A ferramenta simplifica etapas como pré-processamento, treinamento, comparação e otimização de modelos, reduzindo consideravelmente o tempo envolvido na construção e avaliação de classificadores.

Ao reunir diversos algoritmos e métricas de desempenho em uma única estrutura computacional, o PyCaret possibilita a comparação padronizada de múltiplos modelos supervisionados. Complementarmente, oferece funcionalidades para ajuste automático de hiperparâmetros e análise de desempenho, o que auxilia na escolha de modelos mais adequados a tarefas de classificação.

Neste estudo, o PyCaret foi adotado para automatizar as etapas de treinamento, comparação e otimização dos algoritmos supervisionados aplicados aos sinais de EA, permitindo uma avaliação eficiente de diferentes modelos e contribuindo para a seleção dos classificadores mais apropriados à identificação do fenômeno de roçamento.

3.7 Algoritmos de classificação utilizados

3.7.1 *Floresta Aleatória*

A Floresta Aleatória (*Random Forest* – RF), introduzida por Breiman (2001), consiste em um algoritmo supervisionado fundamentado em métodos de aprendizado por conjunto (*ensemble learning*), frequentemente aplicado em problemas de classificação e regressão. O procedimento integra múltiplas árvores de decisão, construídas a partir de subconjuntos aleatórios tanto dos dados quanto das variáveis explicativas, o que contribui para aprimorar a capacidade de generalização do modelo e mitigar o sobreajuste geralmente observado em árvores isoladas.

O treinamento do RF ocorre por meio da técnica de *bootstrap aggregation* (*bagging*), na qual diferentes árvores são geradas com amostras aleatórias extraídas do conjunto de treinamento

(Oliveira Neto et al., 2023). Durante a divisão dos nós, apenas subconjuntos aleatórios das variáveis são considerados, o que favorece a diversidade entre as árvores e reduz a variância do modelo. Para tarefas de classificação, a decisão final é tomada pela votação majoritária entre os classificadores individuais.

Entre as propriedades notáveis do RF, destaca-se sua robustez diante de dados com ruído e conjuntos com elevado número de variáveis, além da capacidade de estimar a importância dos atributos empregados no treinamento. Essas características tornam o algoritmo adequado para aplicações envolvendo sinais de EA, os quais frequentemente apresentam componentes impulsivos, ruídos e relações não lineares entre variáveis.

Adicionalmente, o RF demonstrou boa capacidade de generalização, demanda reduzida por ajuste fino de hiperparâmetros e eficiência computacional superior em comparação a outros métodos supervisionados (BREIMAN, 2001; Oliveira Neto et al., 2023; ZHOU; FENG, 2019). Em contextos industriais, este algoritmo tem sido amplamente aplicado em problemas de monitoramento de condição e diagnóstico de falhas, devido à sua estabilidade e interpretabilidade. A Figura 3.10 ilustra a estrutura geral do classificador RF.




Figura 3.10: Classificador Random Forest. Fonte: Adaptado de Breiman (2001).

No âmbito desta tese, o RF foi utilizado para classificar os sinais de EA relacionados ao fenômeno de roçamento, com o objetivo de identificar padrões representativos das distintas condições operacionais da máquina rotativa.

3.7.2 Extra Trees Classifier

O *Extra Trees Classifier* (ET), proposto por Geurts, Ernst e Wehenkel (2006), configura-se como um algoritmo supervisionado por conjuntos que recorre a múltiplas árvores de decisão para atividades de classificação e regressão. Este método distingue-se pelo nível elevado de aleatoriedade empregado na construção das árvores, tanto na seleção das variáveis quanto na determinação dos pontos de divisão dos nós, o que contribui para a redução da variância do modelo e aprimoramento da generalização.

Diferentemente do RF, o ET costuma utilizar a totalidade do conjunto de treinamento para edificar as árvores, e determina os pontos de corte de maneira aleatória, sem buscar divisões ótimas (GEURTS; ERNST; WEHENKEL, 2006). Essa abordagem reduz os custos computacionais associados ao treinamento, tornando o algoritmo mais eficiente para aplicações com grandes volumes de dados e sinais caracterizados por altos níveis de ruído. A Tabela 3.1 apresenta uma comparação entre os algoritmos ET e RF.

Tabela 3.1: Comparação entre os algoritmos Extra Trees e Random Forest

Critério	Extra Trees	Random Forest
Estratégia de divisão	Aleatória	Melhor divisão possível
Tempo de treinamento	Menor	Maior
Variância	Maior	Menor
Overfitting	Menos propenso	Mais propenso
Precisão	Depende da aplicação	Geralmente maior
Sensibilidade a ruído	Maior	Menor
Uso de amostragem bootstrap	Não necessariamente	Sim, por padrão
Número de divisões por nó	Menor (divisão aleatória)	Maior (divisão ótima)

No que tange a aplicações com sinais de EA, o ET demonstra considerável aptidão para lidar com relações não lineares e dados ruidosos, características comuns em monitoramento de máquinas rotativas. Sua capacidade de generalização e o baixo custo computacional salientam sua adequação para tarefas de classificação automática de falhas.

Neste trabalho, o ET foi empregado para classificar sinais de EA relacionados ao fenômeno de roçamento, com intuito de identificar padrões correspondentes às diversas condições operacionais da máquina rotativa.

3.7.3 Gradient Boosting Classifier

O *Gradient Boosting Classifier* (GBC), desenvolvido por Friedman (2001), é um algoritmo de aprendizado supervisionado que se baseia em árvores de decisão e faz parte da categoria dos métodos de *boosting*. Ao contrário de abordagens que utilizam *bagging*, como o RF, o GBC constrói suas árvores de maneira sucessiva, onde cada nova árvore é criada com o objetivo de corrigir os erros das anteriores. Esse processo contínuo ajuda a minimizar o viés do modelo e aprimora sua habilidade de aprender com questões complexas.

O GBC é treinado através da minimização do gradiente de uma função de perda, o que possibilita que o modelo ajuste os resíduos acumulados ao longo das iterações (FRIEDMAN, 2001). Essa abordagem faz com que o algoritmo seja capaz de descobrir relações não lineares e padrões complexos em dados de alta dimensionalidade, de forma eficaz.

Em geral, o GBC consegue refinar mais as previsões do que o RF, uma vez que aprende de forma sequencial. No entanto, essa estratégia pode levar a um aumento do tempo de computação e a uma maior propensão ao *overfitting* se os hiperparâmetros não forem ajustados corretamente (DATACAMP, 2023). Ainda assim, o algoritmo se destaca em tarefas de classificação que lidam com sinais ruidosos e interações complexas entre variáveis.

No campo do monitoramento de condição, o GBC tem sido amplamente utilizado para classificar falhas em máquinas rotativas e para processar sinais acústicos, graças à sua notável capacidade de generalização e precisão nas previsões. No âmbito desta tese, o algoritmo foi aplicado para categorizar os sinais de EA que ocorrem durante o fenômeno de roçamento, possibilitando a identificação de padrões que se relacionam às diversas condições de operação da máquina rotativa.

CAPÍTULO IV

BANCADA EXPERIMENTAL DE TESTES

Este capítulo descreve a bancada experimental empregada para a aquisição dos sinais de Emissão Acústica (EA) sob condições operacionais com e sem roçamento leve. O sistema rotativo, desenvolvido e validado previamente por Júnior (2022), é composto por um rotor flexível acoplado a um disco rígido, sustentado por mancais autocompensadores. Os sensores piezelétricos utilizados para captar os sinais de EA foram instalados diretamente em um dos mancais, o que possibilitou o monitoramento das respostas dinâmicas relacionadas à ocorrência do roçamento. Ao longo deste capítulo, são apresentados os principais elementos da bancada, bem como o sistema de medição adotado nos experimentos.

4.1 Bancada de Teste

A Figura 4.1 ilustra a bancada experimental empregada neste estudo. O eixo flexível é fabricado em aço SAE 1045, com 10 mm de diâmetro e 550 mm de comprimento, e está acoplado a um disco rígido de aço, que possui 100 mm de diâmetro, 40 mm de espessura e massa aproximada de 2,30 kg. O conjunto é apoiado por dois rolamentos autocompensadores de esferas, o que permite a operação do rotor em distintas condições dinâmicas.

O acionamento do sistema é realizado por um motor elétrico trifásico de dois polos, com potência nominal de 0,37 kW, controlado por um inversor de frequência, conforme ilustrado na Fig. 4.2. O controle da velocidade rotacional possibilita a condução de ensaios sob diversas condições operacionais, o que permite investigar como a rotação influencia a resposta dos sinais de EA relacionados ao roçamento leve.





Figura 4.1: Bancada de testes: 1. motor elétrico; 2. inversor de frequência; 3. acoplamento; 4. mancal de rolamento; 5. disco; 6. proxímetro; 7. PZTs.



(a)



(b)

Figura 4.2: Equipamentos de acionamento da bancada de teste: Motor (a) e Inversor de Frequência (b).

A transmissão do torque entre o motor e o eixo principal ocorre por meio de um acoplamento flexível, cuja função é minimizar desalinhamentos e atenuar vibrações indesejadas no sistema. Os mancais foram montados em bases de aço 5052 e equipados com rolamentos autocompensadores de esferas, amplamente utilizados em sistemas rotativos por sua capacidade de operar com baixo atrito e níveis reduzidos de ruído. A Figura 4.3 apresenta o acoplamento flexível empregado e os rolamentos responsáveis pela sustentação do rotor.




Figura 4.3: Acoplamento flexível (a) e Rolamento autocompensador de esfera (b).

Para o monitoramento das vibrações do disco, foram utilizados proximímetros montados ortogonalmente em uma base de aço 5052, posicionados a aproximadamente 2 mm da superfície do disco. Além da instrumentação para vibração, a estrutura contém pontos de contato fabricados em Nylon, destinados a simular, de maneira controlada, o roçamento, conforme ilustrado na Fig. 4.4. Nos experimentos conduzidos, apenas um ponto de contato foi empregado, o que permitiu reproduzir a condição de roçamento leve de forma controlada e repetitiva.




Figura 4.4: Proximímetros (a) e Pontos que simulam o roçamento no disco (b).

A aquisição dos sinais de EA foi realizada por meio de sensores piezelétricos do tipo PZT e *buzzer*, instalados diretamente no mancal do sistema rotativo. O sensor PZT é constituído por

titanato-zirconato de chumbo, enquanto o *buzzer* consiste em um disco piezocerâmico acoplado a uma base metálica de latão. Ambos os sensores demonstraram sensibilidade adequada para a detecção do roçamento leve e foram, portanto, selecionados para as análises desenvolvidas no presente estudo.

Outros sensores piezelétricos foram avaliados experimentalmente em diferentes orientações no mancal. Todavia, tais sensores não apresentaram desempenho satisfatório para a identificação confiável do roçamento leve, motivo pelo qual seus sinais não foram considerados nas análises finais. A Figura 4.5 ilustra o posicionamento dos sensores piezelétricos utilizados no sistema experimental.




Figura 4.5: Sensores de EA: PZTs (a) e *Buzzers* (b).

4.2 Placa de aquisição dos sinais de EA

A aquisição dos sinais de EA gerados no mancal foi efetuada por meio de sensores piezelétricos conectados ao chassi NI PXI-1033, equipado com o módulo NI PXI-5105, conforme ilustrado na Fig. 4.6. A escolha desse sistema decorreu das particularidades dos sinais de EA, caracterizados por sua natureza transitória, baixa amplitude e presença de componentes em altas frequências, o que demanda elevada resolução temporal e altas taxas de amostragem para uma captura adequada.

O módulo NI PXI-5105 dispõe de resolução de 12 bits e pode alcançar taxas de amostragem de até 60 MS/s por canal, possibilitando a aquisição simultânea de múltiplos sinais com alta precisão temporal. Essas especificações tornam o sistema apto à detecção de eventos acústicos rápidos associados a fenômenos como atrito, deformações localizadas e leves contatos em máquinas rotativas. Ademais, a ampla largura de banda do módulo permite a captura de componentes espectrais relevantes às análises de processamento de sinais desenvolvidas no escopo desta tese.




Figura 4.6: Placa de aquisição para os sinais de EA modelo NI PXI.

O chassi NI PXI-1033 oferece uma arquitetura modular que suporta sincronização entre canais, conferindo maior flexibilidade para configurações experimentais e possibilidade de expansão do sistema de aquisição. Tal configuração viabilizou a realização de medições simultâneas nos sensores piezelétricos e nos sensores de vibração, facilitando comparações entre distintas técnicas de monitoramento.

Assim, a combinação do chassi NI PXI-1033 com o módulo NI PXI-5105 constituiu uma plataforma adequada para a aquisição dos sinais de EA investigados, apresentando robustez, confiabilidade e desempenho compatíveis com os requisitos experimentais relacionados à detecção de leves contatos em máquinas rotativas.

CAPÍTULO V

RESULTADOS

Este capítulo descreve a metodologia adotada para a análise dos sinais de Emissão Acústica (EA) coletados na bancada experimental, detalhando as etapas de processamento e extração das características pertinentes desses sinais. Inicialmente, são apresentadas as técnicas convencionais de processamento empregadas na identificação do roçamento leve, acompanhadas de uma comparação entre os sinais de EA e os sinais de vibração capturados por proximetros instalados no sistema rotativo. Essa comparação busca avaliar a sensibilidade e a capacidade da técnica de EA na detecção precoce de falhas, evidenciando seu potencial como técnica complementar às abordagens tradicionais de monitoramento por vibração. Por fim, são expostos e discutidos os resultados obtidos por meio da aplicação de modelos de aprendizado de máquina na classificação dos sinais, com o objetivo de explorar a contribuição desses métodos para o diagnóstico automático de falhas em máquinas rotativas.

5.1 Metodologia Experimental abordada na Bancada de Testes

A Figura 5.1 ilustra a bancada experimental utilizada para adquirir simultaneamente os sinais de Emissão Acústica e os sinais de vibração por proximetros, sob condições controladas de roçamento leve. O roçamento foi direcionado a um ponto de contato específico projetado na estrutura da bancada, o que possibilitou a reprodução controlada do fenômeno em estudo. Os componentes e detalhes construtivos do sistema experimental são abordados no Capítulo IV desta tese.

As condições operacionais foram estabelecidas com base nos modos de vibração identificados na investigação de Júnior (2022), que verificou o primeiro modo do rotor em cerca de 30 Hz

(1800 rpm). A partir desse parâmetro, selecionaram-se três velocidades de rotação abaixo da primeira velocidade crítica do sistema: 11 Hz (660 rpm), 14 Hz (840 rpm) e 15 Hz (900 rpm). Essas condições favoreceram a condução dos ensaios em regime operacional seguro, que representasse adequadamente o comportamento dinâmico do rotor.

Os sinais de vibração foram captados por proximímetros posicionados nas direções horizontal (x) e vertical (z), conectados a um analisador de sinais Agilent® modelo 35670A, operando em faixa de frequência de 0 a 300 Hz. Simultaneamente, os sinais de EA foram registrados por sensores piezelétricos do tipo PZT e *buzzer*, ligados ao chassi NI PXI-1033 e ao módulo NI PXI-5105, com a interface desenvolvida em *LabVIEW*. Para a captura dos sinais de EA, adotou-se uma frequência de amostragem de 2 MHz, o que proporcionou elevada resolução temporal e possibilitou a detecção adequada dos eventos transientes de alta frequência relacionados ao roçamento leve.

Cada aquisição teve duração de 1 segundo, totalizando 2×10^6 amostras por sinal. Ao término dos ensaios, foram obtidos 180 sinais de EA, distribuídos igualmente entre as condições com e sem roçamento leve, resultando em 90 sinais para cada cenário operacional analisado. Esses dados foram utilizados nas análises comparativas e nas etapas de classificação baseadas em aprendizado de máquina.




Figura 5.1: Aplicação do roçamento leve no disco em um ponto de contato.

Para minimizar interferências decorrentes de variações térmicas e assegurar maior estabilidade operacional, as aquisições foram realizadas após mais de duas horas de funcionamento contínuo da bancada, tanto na ausência quanto na presença do roçamento leve. Ademais, o ambiente experimental foi mantido em temperatura controlada de 21°C, considerando que flutuações térmicas podem afetar as propriedades piezelétricas dos sensores PZT e, conseqüentemente, alterar a resposta dos sinais de EA. Essas precauções contribuíram para aprimorar a confiabilidade e a reprodutibilidade dos dados obtidos nos ensaios.

5.2 Análise dos sinais de Emissão Acústica por Envelope com base na Transformada de Hilbert

A abordagem inicial desenvolvida neste estudo envolveu a aplicação da análise de envelope, fundamentada na Transformada de Hilbert, sobre os sinais de EA coletados em condições com e sem a presença de roçamento leve. Essa técnica é comumente empregada na literatura para detectar defeitos emergentes em máquinas rotativas, sobretudo quando as assinaturas do defeito se manifestam por meio de modulações em frequências elevadas.

A Figura 5.2 ilustra o esquema em blocos adotado para o processamento dos sinais de EA. O procedimento foi organizado em quatro fases principais: **(i)** aquisição dos sinais experimentais; **(ii)** extração das componentes de alta frequência relacionadas ao fenômeno de roçamento; **(iii)** aplicação da análise de envelope utilizando a Transformada de Hilbert; e **(iv)** identificação das frequências características por meio da Transformada Discreta de Fourier (DFT) e do cálculo da densidade espectral de potência (PSD). Essa estruturação permitiu uma avaliação metódica dos dados, facilitando a identificação das assinaturas espectrais associadas ao tipo de defeito investigado.

Durante os experimentos, foram detectadas diversas fontes de ruído que afetaram os sinais de EA, tais como desalinhamento e desbalanceamento da bancada, interferências eletromagnéticas originadas do motor elétrico, ausência de aterramento adequado da rede elétrica e ruídos ambientais do laboratório. Além disso, o sistema de aquisição PXI pode ter contribuído com ruídos eletrônicos adicionais, devido à falta de aterramento do equipamento.

Dada a alta sensibilidade dos sinais de EA a interferências eletromagnéticas e a componentes espúrias, a etapa de filtragem revelou-se essencial para aprimorar a confiabilidade na detecção do roçamento leve. Inicialmente, foram eliminadas as componentes abaixo de 2 kHz e acima




Figura 5.2: Diagrama de blocos do processamento de sinais.

de 400 kHz, faixas tipicamente associadas a ruídos ambientais e interferências provenientes do sistema de aquisição.

Em seguida, a faixa de interesse foi delimitada entre 3,4 kHz e 4,7 kHz, com base na identificação das regiões de ressonância observadas na análise espectral dos sinais. Para isolar essas componentes, aplicou-se um filtro passa-banda *Butterworth* de décima ordem, selecionado por apresentar resposta em frequência suave e estabilidade numérica. Essa filtragem permitiu concentrar a análise nas componentes espectrais mais relevantes ao roçamento leve, reduzindo a influência de sinais indesejados e potencializando a sensibilidade do diagnóstico.

As Figuras 5.3 a 5.8 apresentam as faixas de frequência detectadas os sensores PZT 4 e *buzzer* 5 nas velocidades de rotação de 11 Hz, 14 Hz e 15 Hz. Em todas as situações avaliadas, identificou-se a presença de componentes espectrais concentradas na mesma faixa, o que sugere que o fenômeno de roçamento leve gera assinaturas acústicas consistentes independentemente do sensor empregado.

Ao analisar as Figs. 5.3 até 5.8, os dados indicam que o sensor PZT apresentou amplitudes superiores às observadas com o *buzzer*, resultado atribuído à maior sensibilidade piezoelétrica e à resposta dinâmica aprimorada do PZT para eventos transientes de alta frequência. Contudo, mesmo com amplitudes menores, o *buzzer* conseguiu detectar as mesmas regiões espectrais relacionadas ao roçamento leve, apontando para o potencial dos sensores piezoelétricos de baixo custo em aplicações de monitoramento baseadas em emissões acústicas.

Foi ainda constatado um incremento gradual nas amplitudes dos sinais de emissões acústicas com o aumento da velocidade de rotação. Esse comportamento pode ser associado ao acréscimo da energia mecânica transferida durante o contato das superfícies, intensificando os mecanismos de atrito e impacto característicos do roçamento. Tal processo implica uma maior liberação de

energia elástica na forma de ondas acústicas transitórias, refletida no aumento das amplitudes na faixa de frequência de interesse.




Figura 5.3: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 11 Hz.




Figura 5.4: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (*buzzer*) a 11 Hz.

A aplicação do filtro passa-banda contribuiu para a atenuação significativa dos ruídos contidos nos sinais brutos, favorecendo a realce das componentes vinculadas ao roçamento leve no domínio temporal. Após esta etapa, foi empregada a análise de envelope baseada na Transformada de




Figura 5.5: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 14 Hz.




Figura 5.6: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (*buzzer*) a 14 Hz

Hilbert, o que possibilitou a identificação das modulações de amplitude relacionadas ao fenômeno em questão.

As Figuras 5.9 a 5.14 apresentam a comparação entre os sinais brutos e seus respectivos envelopes obtidos para os sensores PZT e *buzzer* após o processamento. Observa-se que a análise de envelope evidenciou de forma mais clara os padrões modulados associados ao roçamento, facilitando a distinção dos eventos transitórios decorrentes do contato entre as superfícies.




Figura 5.7: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 4 (PZT) a 15 Hz.






Figura 5.8: Identificação da faixa de frequência do roçamento nos sinais de EA do sensor 5 (*buzzer*) a 15 Hz.

Os resultados indicam que a metodologia fundamentada na Transformada de Hilbert demonstrou elevada sensibilidade para detectar o roçamento leve, mesmo em ambientes altamente contaminados por ruído. Adicionalmente, essa técnica permitiu identificar diferenças sutis entre os estados operacionais da máquina rotativa, reforçando a utilidade da análise de emissões acústicas como complemento às abordagens tradicionais de monitoramento por vibração.




(a)




(b)

Figura 5.9: Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 11 Hz.




(a)




(b)

Figura 5.10: Comparação entre o sinal bruto do sensor *buzzer* 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 11 Hz.




(a)




(b)

Figura 5.11: Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 14 Hz.




(a)




(b)

Figura 5.12: Comparação entre o sinal bruto do sensor *buzzer* 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 14 Hz.




(a)




(b)

Figura 5.13: Comparação entre o sinal bruto do sensor PZT 4 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 15 Hz.



(a)



(b)

Figura 5.14: Comparação entre o sinal bruto do sensor *buzzer* 5 (a) e o respectivo envelope do sinal filtrado evidenciando o roçamento leve (b), obtido para a velocidade de rotação de 15 Hz.


Conforme ilustrado nas Figuras 5.9(b) a 5.14(b), os envelopes dos sinais exibem padrões periódicos bem definidos, evidenciando a natureza cíclica do fenômeno de roçamento leve. Essa periodicidade sugere que os eventos de contato entre as superfícies ocorrem de maneira sincronizada com a dinâmica rotacional do sistema, resultando em modulações de amplitude em frequências relacionadas às condições operacionais da máquina. Os picos periódicos observados estão diretamente vinculados à excitação mecânica originada pelo contato rotor-estator, comportamento este amplamente documentado na literatura pertinente a falhas de roçamento em sistemas rotativos. Além disso, a identificação dessas modulações viabiliza a distinção do roçamento em relação a outras fontes de excitação mecânica presentes no sistema.

Com o intuito de aprofundar a análise das componentes moduladas identificadas nos envelopes, procedeu-se à avaliação espectral por meio da Densidade Espectral de Potência (PSD). Tal abordagem possibilita a quantificação da distribuição energética das componentes espectrais ao longo do espectro de frequência, facilitando a identificação de assinaturas associadas ao roçamento leve.


Foram adotadas duas abordagens distintas na análise da PSD. A primeira consistiu na aplicação da PSD sobre o envelope do sinal, o que evidenciou componentes de baixa frequência vinculadas às condições dinâmicas e estruturais do sistema rotativo, como desbalanceamento e desalinhamento. A segunda abordagem envolveu a aplicação da PSD diretamente aos sinais filtrados na faixa de interesse, permitindo a identificação de componentes espectrais de maior frequência associadas aos mecanismos de atrito e impacto decorrentes do roçamento leve.

As Figuras 5.15 a 5.20 apresentam os espectros de potência obtidos para os sensores PZT e *buzzer*. Em todas as condições analisadas, os sinais captados pelo sensor PZT exibiram amplitudes superiores às registradas pelo *buzzer*, resultado atribuído à maior sensibilidade e capacidade de resposta dinâmica do PZT frente a eventos transientes de alta frequência.

Adicionalmente, observa-se nas Figuras 5.15(b) a 5.20(b) que as amplitudes espectrais dos sinais referentes ao roçamento leve alcançam níveis significativamente acima daqueles observados na condição sem roçamento. Esse comportamento reforça a estreita relação entre as componentes espectrais identificadas e a presença do defeito, demonstrando que o roçamento gera assinaturas acústicas distintas e energeticamente mais intensas após o processamento apropriado dos sinais de EA.




(a)




(b)

Figura 5.15: PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 11 Hz.




(a)




(b)

Figura 5.16: PSD para o envelope do *buzzer* 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 11 Hz.




(a)




(b)

Figura 5.17: PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 14 Hz.




(a)




(b)

Figura 5.18: PSD para o envelope do *buzzer* 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 14 Hz.



(a)



(b)

Figura 5.19: PSD para o envelope do sinal de EA do PZT 4: com roçamento leve (a) e da FFT do sinal filtrado (b), obtidos para a velocidade de rotação de 15 Hz.





Figura 5.20: PSD para o envelope do *buzzer* 5: com roçamento leve (a) e da FFT do sinal do sinal filtrado (b), obtidos para a velocidade de rotação de 15 Hz.

A análise dos resultados apresentados nas Figs. 5.15 a 5.20 indica que o roçamento leve manifesta-se de modo periódico e sincronizado com a rotação do eixo, confirmando o caráter cíclico do fenômeno. Constatou-se ainda a presença de múltiplas componentes harmônicas da frequência de rotação do rotor (2X, 3X, 4X, entre outras), sugerindo a coexistência de mecanismos dinâmicos adicionais, tais como desbalanceamento residual, desalinhamento e efeitos tribológicos associados ao contato rotor-estator.

Outro aspecto relevante identificado nos espectros foi a persistência das componentes de maior energia na faixa entre 3,4 kHz e 4,7 kHz para todas as velocidades de rotação estudadas. Embora as amplitudes aumentem com a elevação da rotação, a região espectral relacionada ao roçamento manteve-se praticamente estável, indicando sua associação às características dinâmicas locais do contato mecânico e às frequências naturais das estruturas envolvidas no fenômeno.


As Figuras 5.17(a) e 5.18(a) ressaltam a amplificação significativa da componente 2X (28 Hz), comportamento associado à proximidade dessa harmônica com a primeira frequência natural do sistema, estimada em torno de 30 Hz. Nessas condições, observa-se um efeito de amplificação dinâmica típico de fenômenos próximos à ressonância, intensificando a resposta vibratória do sistema. Tal efeito pode ser potencializado pela conjunção das forças periódicas decorrentes do desbalanceamento, desalinhamento e das interações não lineares oriundas do roçamento leve.

As componentes harmônicas presentes no espectro indicam que o roçamento altera de maneira substancial a distribuição de energia no sistema rotativo. Diferentemente de defeitos puramente lineares, o contato intermitente entre rotor e estator introduz excitações não lineares capazes de redistribuir energia entre múltiplas harmônicas da rotação, modificando o comportamento espectral e aumentando a complexidade dinâmica da resposta vibratória.


Nesse cenário, a aplicação das técnicas de filtragem revelou-se crucial para atenuar a influência de ruídos e componentes espúrias que poderiam ocultar as assinaturas espectrais do roçamento leve. A remoção seletiva das componentes fora da faixa de interesse ampliou a sensibilidade da análise espectral, facilitando a detecção das frequências características associadas ao defeito em estudo.

Por fim, os sinais de EA obtidos pelos sensores PZT e *buzzer* foram comparados com os sinais de vibração captados pelos proximetros. As Figuras 5.21 a 5.23 exibem as órbitas e as DFTs nas condições com e sem roçamento leve, em velocidades de 11 Hz, 14 Hz e 15 Hz, possibilitando uma avaliação comparativa da sensibilidade das diferentes técnicas de monitoramento na detecção

do defeito.




(a)




(b)

Figura 5.21: Órbita (a) e dFT do sinal dos proxímetros (b), obtido para a velocidade de rotação de 11 Hz.



(a)



(b)

Figura 5.22: Órbita (a) e dFT do sinal dos proxímetros (b), obtido para a velocidade de rotação de 14 Hz.

Tabela 5.1: Indicadores quantitativos das órbitas para as condições com e sem roçamento leve.

Rotação	Variação da Área Orbital (%)	Variação RMS Orbital (%)
11 Hz	-2,31	-1,31
14 Hz	-4,46	-2,49
15 Hz	3,96	0,57

Com base nos resultados apresentados nas Figs. 5.21(a) a 5.23(a), observa-se que as órbitas do rotor não apresentaram alterações significativas entre as condições com e sem roçamento




Figura 5.23: Órbita (a) e dFT do sinal dos proxímetros (b), obtido para a velocidade de rotação de 15 Hz.

leve. Esse comportamento foi confirmado pelos resultados dos indicadores orbitais apresentados na Tab. 5.1, em que as variações na área orbital e na energia RMS ficaram abaixo de 5% para todas as velocidades que foram analisadas. Em 11 Hz e 14 Hz, houve pequenas reduções nos parâmetros orbitais, enquanto em 15 Hz houve um pequeno aumento nessas grandezas. No entanto, essas alterações não foram muito significativas, o que indica que o defeito não foi grave o suficiente para alterar de forma importante a resposta dinâmica global do sistema rotativo. Como o roçamento leve caracteriza-se por um fenômeno localizado e associado a

eventos transitórios de alta frequência, seus efeitos tendem a não ser facilmente identificados por sensores de proximidade, cuja resposta é predominantemente sensível aos deslocamentos globais do eixo em baixas frequências.

A análise espectral por meio das DFTs, apresentada nas Figs. 5.21(b) a 5.23(b), demonstra que não ocorreram variações significativas nas componentes 1X e 2X associadas à rotação do eixo. Entretanto, as componentes harmônicas permaneceram evidentes em todas as condições analisadas, refletindo principalmente os efeitos de desbalanceamento residual e desalinhamento presentes na bancada experimental. Esses resultados corroboram a literatura, que destaca a elevada eficiência dos sensores de proximidade na identificação de defeitos globais, como desbalanceamento e desalinhamento, mas também suas limitações na detecção de fenômenos localizados de contato superficial, como o roçamento leve.

A ausência de modificações expressivas nas órbitas sugere que o roçamento ainda se encontra em um estágio incipiente, no qual a energia gerada pelo contato não é suficiente para alterar significativamente a dinâmica global do rotor. Além disso, parte da energia produzida durante o contato pode ser dissipada localmente por mecanismos de atrito e amortecimento estrutural, reduzindo a propagação das vibrações para o restante do sistema e dificultando sua identificação por técnicas convencionais de análise de vibração. Assim, os resultados quantitativos da área orbital e da energia RMS evidenciam que a aplicação isolada de parâmetros orbitais pode não ser suficiente para detectar precocemente defeitos incipientes de contato em máquinas rotativas.

Em contrapartida, os resultados obtidos por meio da EA demonstraram elevada sensibilidade à presença do roçamento leve. Após o processamento dos sinais utilizando análise de envelope e a metodologia PSD, foi possível identificar assinaturas espectrais características do contato superficial mesmo em condições nas quais os sinais de vibração não apresentaram alterações perceptíveis. Esse comportamento evidencia a capacidade da EA em detectar fenômenos transitórios de curta duração e alta frequência associados aos estágios iniciais do defeito.

Dessa forma, os resultados demonstram que a técnica de EA possui elevado potencial como ferramenta complementar ao monitoramento convencional por vibração em máquinas rotativas. A integração entre diferentes metodologias de monitoramento permite uma avaliação mais abrangente da condição operacional do sistema, favorecendo diagnósticos mais precisos e estratégias de manutenção preditiva mais eficientes.

Por fim, adotou-se uma abordagem suplementar baseada na extração de parâmetros estatísticos dos sinais de EA, com o propósito de avaliar tendências e variações decorrentes das

diferentes condições operacionais do sistema rotativo. Os parâmetros empregados, apresentados no Capítulo III desta tese, são amplamente utilizados na literatura para a caracterização de sinais de EA, especialmente na detecção de eventos transitórios e defeitos iniciais.


A Figura 5.24 ilustra os resultados obtidos para o fator de crista nas diversas velocidades de rotação, considerando os sensores PZT e *buzzer*. Este parâmetro estatístico é notoriamente sensível à presença de picos impulsivos no sinal, associando-se frequentemente a eventos transitórios de curta duração, como impactos e contatos superficiais oriundos do roçamento leve.

Verificou-se uma diferenciação clara entre as condições com e sem roçamento leve para ambos os sensores, evidenciando a sensibilidade do fator de crista às alterações induzidas pelo defeito. Na velocidade de 11 Hz, a distinção foi mais marcante no sensor PZT, fato que pode ser atribuído à sua sensibilidade piezelétrica superior e à resposta dinâmica aprimorada na faixa de frequência analisada. Em contrapartida, o *buzzer* também possibilitou distinções entre os estados operacionais, embora com maior dispersão dos valores registrados.


Nas velocidades mais elevadas, essa separação tornou-se menos nítida, possivelmente devido ao aumento da influência de outros fenômenos dinâmicos presentes na bancada experimental, incluindo desbalanceamento residual, desalinhamento e componentes harmônicas relacionadas à rotação do eixo. Ainda assim, o sensor PZT mostrou-se mais consistente na distinção entre as condições avaliadas, enquanto o *buzzer* apresentou maior variabilidade estatística. Estes resultados sugerem uma maior aptidão do PZT para capturar variações transitórias nos sinais de EA gerados pelo roçamento leve.

A curtose, exibida na Fig. 5.25, oferece uma medida estatística associada à presença de eventos impulsivos e distribuições com caudas mais pronunciadas nos sinais de EA. Para todas as velocidades investigadas e independentemente do sensor, a condição com roçamento leve apresentou valores de curtose superiores aos da condição saudável. Tal comportamento indica que o defeito inicial introduz eventos transitórios de alta amplitude vinculados a contatos intermitentes entre as superfícies, aumentando a impulsividade dos sinais adquiridos. Além disso, os dados destacam que o roçamento leve gera alterações detectáveis estatisticamente mesmo quando análises orbitais e de vibração não evidenciam modificações significativas.

Os resultados referentes à energia dos sinais de EA, mostrados na Fig. 5.26, revelam uma separação bem definida entre os estados com e sem roçamento leve para ambos os sensores. Observa-se um aumento expressivo da energia na presença do defeito, sugerindo uma maior liberação e propagação de energia mecânica no sistema, em decorrência dos mecanismos de atrito



(a)




(b)


Figura 5.24: Parâmetro *Crest Factor* para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

e impacto durante o contato rotor-estator. Esse padrão reforça a hipótese de que o roçamento leve induz excitações transitórias adicionais que afetam significativamente a resposta energética dos sinais de EA.

O valor RMS, apresentado na Fig. 5.27, apresentou comportamento análogo ao parâmetro energia, refletindo o aumento da amplitude média dos sinais na condição com roçamento leve. Isto indica que o defeito adicionou componentes de alta frequência e curta duração aos sinais de EA, elevando seu conteúdo energético médio. A distinção entre as condições operacionais



(a)




(b)


Figura 5.25: Parâmetro Curtose para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

constatada reforça a sensibilidade da análise de EA para detectar variações dinâmicas sutis, mesmo quando análises orbitais e espectrais dos proxímetros indicam baixa capacidade de diferenciação.

O valor de pico, ilustrado na Fig. 5.28, destaca os eventos de maior magnitude nos sinais de EA. Conforme esperado, a condição com roçamento leve apresentou amplitudes máximas superiores às da condição saudável, enfatizando o caráter impulsivo e transitório do fenômeno investigado. De maneira similar, a variância, exibida na Fig. 5.29, mostrou aumento relevante



(a)




(b)


Figura 5.26: Parâmetro Energia para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

na presença do defeito, indicando maior dispersão e variabilidade das amplitudes associadas ao contato intermitente entre rotor e estator.

Em todos os parâmetros estatísticos analisados, o sensor PZT apresentou amplitudes superiores às registradas pelo buzzer, o que se relaciona à sua maior sensibilidade piezelétrica e resposta dinâmica aprimorada para eventos transitórios de alta frequência. Contudo, mesmo com maior dispersão estatística, o *buzzer* também demonstrou capacidade para distinguir adequadamente as condições operacionais, sugerindo potencial para aplicações de monitoramento baseadas em EA



(a)




(b)


Figura 5.27: Parâmetro do valor RMS para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

que utilizem sensores de baixo custo.

De modo geral, os resultados confirmam que a análise estatística complementa as abordagens espectrais, de envelope e densidade espectral de potência (PSD), ampliando a capacidade de identificação do roçamento leve. A diferenciação observada entre as condições operacionais evidencia que os sinais de EA carregam assinaturas características do defeito já em estágios iniciais, reforçando o potencial da técnica para uso em monitoramento preditivo de máquinas rotativas.



(a)




(b)


Figura 5.28: Parâmetro valor pico para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

Adicionalmente, os dados indicam que a combinação da análise de envelope, PSD e parâmetros estatísticos configura uma metodologia robusta para caracterização de fenômenos transitórios relacionados ao contato rotor-estator. A integração dessas técnicas possibilita uma avaliação mais abrangente da condição dinâmica do sistema, contribuindo para diagnósticos precoces e estratégias de manutenção preditiva mais eficazes.

Por fim, destaca-se que a seleção criteriosa dos parâmetros de filtragem e a adequada configuração da instrumentação experimental foram elementos essenciais para assegurar medições



(a)



(b)

Figura 5.29: Parâmetro variância para as amostras dos sinais de EA em diferentes condições de operação e velocidades do rotor: (a) PZT e (b) *buzzer*.

confiáveis e representativas das condições reais de operação. Esses aspectos revelam-se fundamentais para a aplicação da metodologia proposta em ambientes industriais caracterizados por elevados níveis de ruído e interferências externas.

5.3 Análise dos sinais de Emissão Acústica por algoritmos de Aprendizado de Máquina

Os sinais de EA adquiridos por sensores PZT e *buzzer*, sob condições com e sem roçamento leve nas velocidades de rotação de 11 Hz, 14 Hz e 15 Hz, respectivamente, foram posteriormente submetidos a análise por meio de algoritmos de Aprendizado de Máquina (ML). Esta etapa teve como propósito investigar a capacidade de diversos modelos de classificação em identificar padrões associados ao defeito a partir dos sinais de EA. A adoção de técnicas de ML é particularmente pertinente dado o alto grau de complexidade dos sinais de EA, caracterizados por baixa relação sinal-ruído, elevada sensibilidade a interferências e comportamento não estacionário.

Para a análise dos dados, foram empregados três métodos distintos de ML, o que possibilitou comparar diferentes estratégias de classificação e examinar o desempenho de cada abordagem na identificação das condições operacionais do sistema rotativo. O desenvolvimento dos modelos ocorreu em três fases principais: preparação dos dados, modelagem e validação dos resultados.

Na fase de preparação, realizou-se o pré-processamento das informações experimentais, com o intuito de organizar e padronizar os sinais para a aplicação dos algoritmos de ML. Subsequentemente, durante a modelagem, diferentes classificadores foram avaliados e ajustes nos hiperparâmetros foram efetuados para alcançar configurações mais adequadas à tarefa de classificação. Para otimizar esse procedimento, utilizou-se a biblioteca PyCaret, reconhecida pela automação de etapas como seleção de modelos, ajuste de hiperparâmetros, validação cruzada e análise de desempenho.

Inicialmente, estabeleceu-se um *setup* na PyCaret, no qual foram configurados parâmetros relativos à base de dados, definição da variável alvo, manejo das variáveis, normalização, divisão dos conjuntos de treinamento e teste, além do controle da aleatoriedade por meio da definição de sementes, garantindo a reprodutibilidade dos resultados.

O conjunto de dados compreendeu 360 amostras, das quais 180 correspondiam à condição sem roçamento e 180 à condição com roçamento leve. Cada amostra consistiu em sinais de EA adquiridos com frequência de amostragem de 2 MS/s durante 1 segundo. Para treinamento e validação, os dados foram divididos em dois subconjuntos: 70% dedicados ao treinamento/validação e 30% reservados para teste. Essa divisão visou avaliar a capacidade de generalização dos modelos frente a sinais não utilizados no treinamento, minimizando efeitos de sobreajuste (*overfitting*) e promovendo uma análise mais robusta do desempenho dos classificadores. Os resultados mais relevantes obtidos para cada abordagem serão apresentados e

discutidos nas subseqüentes subseções.

5.3.1 Abordagem com dados brutos de Emissão Acústica

Na primeira abordagem, os sinais de EA foram analisados em sua forma bruta, sem aplicação prévia de filtros ou técnicas adicionais de pré-processamento. O objetivo consistiu em investigar a aptidão dos algoritmos de ML para identificar padrões associados ao roçamento leve diretamente a partir de sinais complexos, com elevado ruído e características não estacionárias — condições comuns em cenários reais de monitoramento baseados em EA.

Para a construção da base de dados, foram extraídas aleatoriamente 200 amostras em janelas de tamanho fixo contendo 2.000 pontos dos sinais de EA. Os dados foram classificados pelo PyCaret considerando uma classificação binária, definida pelas classes 0 (sem roçamento) e 1 (com roçamento leve). Essa estratégia permitiu avaliar o comportamento dos classificadores frente às incertezas e interferências presentes nos sinais brutos de EA.

A seguir, diferentes modelos foram treinados e avaliados por meio de validação cruzada, utilizando a acurácia como métrica inicial principal. A Tabela 5.2 apresenta o desempenho dos modelos analisados pela metodologia. Dentre os classificadores, o *Gradient Boosting Classifier* (GBC) destacou-se pelo melhor desempenho geral, sobretudo em termos de acurácia, AUC e precisão.

Tabela 5.2: Resultados dos modelos de ML para a abordagem com sinais brutos de EA.

Modelo	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
Gradient Boosting Classifier	0.61026	0.67844	0.54556	0.62749	0.56983	0.21797	0.22615	13.19200
Extra Trees Classifier	0.59658	0.61389	0.55667	0.62098	0.57481	0.19074	0.20027	0.55800
Logistic Regression	0.59763	0.61244	0.56778	0.60783	0.57610	0.19213	0.19819	0.58900
Random Forest Classifier	0.59079	0.62506	0.53778	0.61451	0.56252	0.18158	0.19072	0.65500
Ridge Classifier	0.59211	0.61922	0.57889	0.60558	0.58122	0.18235	0.18999	0.54600
Light Gradient Boosting Machine	0.58579	0.63622	0.53889	0.61810	0.55893	0.17345	0.18724	1.46700
Linear Discriminant Analysis	0.57658	0.57978	0.56889	0.58538	0.56509	0.15134	0.15801	0.52300
K Neighbors Classifier	0.57684	0.63044	0.52667	0.58361	0.54665	0.14923	0.15161	0.56800
Quadratic Discriminant Analysis	0.57237	0.57144	0.52889	0.58232	0.54805	0.14121	0.14444	0.50300
Decision Tree Classifier	0.52158	0.52056	0.46778	0.53047	0.48921	0.04083	0.04179	0.75500
SVM - Linear Kernel	0.52026	0.61822	0.67000	0.43319	0.49541	0.03000	0.03505	0.54500
Dummy Classifier	0.50000	0.50000	0.00000	0.00000	0.00000	0.00000	0.00000	0.41500

Observando a Tab 5.2, o GBC alcançou a maior acurácia (0,61026), bem como os melhores valores para AUC (0,67844) e precisão (0,62749). Esse desempenho está possivelmente relacionado à capacidade do algoritmo em construir árvores de decisão sequenciais, em que cada nova árvore busca corrigir as falhas das anteriores. Tal característica confere ao GBC eficiência na

identificação de padrões complexos e não lineares presentes nos sinais brutos de EA, mesmo em situações de elevado ruído.

Outros modelos baseados em árvores, como *Extra Trees* (ET), Floresta Aleatória (*Random Forest* - RF) e Árvores de Decisão (*Decision Tree* - DT), também apresentaram desempenho razoável, demonstrando a robustez dessas técnicas diante de dados ruidosos e variáveis irrelevantes. Contudo, diferentemente do GBC, esses métodos não realizam aprendizado iterativo orientado à minimização progressiva dos erros, o que pode limitar sua capacidade de generalização em sinais com alta variabilidade e baixa relação sinal-ruído.

A análise das métricas suplementares confirma essa tendência. O GBC obteve a maior AUC, indicando maior habilidade para distinguir as classes relacionadas às condições com e sem roçamento leve. Ademais, o modelo demonstrou equilíbrio satisfatório entre precisão, *recall* e *F1-score*, demonstrando consistência na identificação dos eventos ligados ao defeito sem aumento significativo de classificações incorretas. Tal aspecto é especialmente relevante em aplicações de monitoramento de falhas, considerando que a redução de falsos negativos é crucial para diagnósticos precoces e estratégias de manutenção preditiva.

Após a seleção do GBC como melhor classificador, procedeu-se à otimização de seus hiperparâmetros mediante a função `tune_model()`, que emprega validação cruzada com 10 grupos, conforme ilustrado na Tab. 5.3. Contudo, os resultados indicaram que tal ajuste não proporcionou melhorias expressivas no desempenho do modelo. Essa constatação sugere que a elevada complexidade e o ruído presentes nos sinais brutos podem restringir a capacidade de generalização, mesmo após otimizações adicionais.


Além disso, realizou-se análise da matriz de confusão, apresentada na Figura 5.30, visando examinar a distribuição dos erros de classificação entre as diversas condições operacionais avaliadas.

Ao analisar a Fig. 5.30, verifica-se que o modelo classificou corretamente 28 amostras da classe íntegro e 37 amostras da classe danificado, correspondendo aos verdadeiros negativos (TN) e verdadeiros positivos (TP), respectivamente. No entanto, identificaram-se 32 falsos positivos (FP), nos quais amostras íntegras foram incorretamente classificadas como defeituosas, além de 23 falsos negativos (FN), referentes à não detecção parcial das amostras com roçamento leve.

Essa distribuição dos erros sugere uma tendência moderada do modelo em superestimar a presença do defeito. Em contextos de monitoramento preditivo, tal comportamento pode ser desejável até certo ponto, uma vez que a redução dos falsos negativos é essencial para evitar a não

Tabela 5.3: Resultados da validação cruzada do modelo GBC após o ajuste de hiperparâmetros.

Fold	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.7500	0.8100	0.8000	0.7273	0.7619	0.5000	0.5025
1	0.6500	0.5500	0.8000	0.6154	0.6957	0.3000	0.3145
2	0.7000	0.7400	0.6000	0.7500	0.6667	0.4000	0.4082
3	0.5000	0.5000	0.4000	0.5000	0.4444	0.0000	0.0000
4	0.6000	0.5500	0.6000	0.6000	0.6000	0.2000	0.2000
5	0.6500	0.7100	0.8000	0.6154	0.6957	0.3000	0.3145
6	0.6842	0.7111	0.7000	0.7000	0.7000	0.3667	0.3667
7	0.5789	0.7222	0.6000	0.6000	0.6000	0.1556	0.1556
8	0.4211	0.3111	0.3333	0.3750	0.3529	-0.1676	-0.1685
9	0.6842	0.8222	0.3333	1.0000	0.5000	0.3448	0.4564
Mean	0.6218	0.6427	0.5967	0.6483	0.6017	0.2399	0.2550
Std	0.0945	0.1526	0.1767	0.1570	0.1242	0.1897	0.2006

Figura 5.30: Matriz Confusão para o *Gradient Boosting Classifier*.

identificação de falhas iniciais. Entretanto, a elevada quantidade de falsos positivos pode acarretar alarmes desnecessários, comprometendo a confiabilidade operacional caso a metodologia seja empregada em ambientes industriais em tempo real.

A Tabela 5.4 sintetiza os principais indicadores de desempenho extraídos da matriz de confusão. Observa-se que o modelo apresentou desempenho moderado na classificação das condições operacionais a partir dos sinais brutos de EA, com acurácia de 54,16%, precisão de 54,26%, recall de 54,16% e F1-score de 53,90%. Esses valores indicam que, apesar de o

classificador ter captado parcialmente os padrões relacionados ao roçamento leve, a elevada complexidade e o ruído inerentes aos sinais brutos limitaram significativamente sua capacidade de generalização.

Tabela 5.4: Resultados da classificação do defeito nos dados brutos dos sinais de EA.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
<i>Gradient Boosting Classifier</i>	54,16	54,26	54,16	53,90

Os resultados evidenciam que a aplicação direta dos sinais brutos de EA constitui um desafio considerável para algoritmos de aprendizado de máquina, principalmente devido à presença expressiva de ruídos, interferências externas e componentes não estacionários típicos desse tipo de sinal. Nesse sentido, técnicas de pré-processamento e extração de características são essenciais para aumentar a separabilidade entre as classes e aprimorar o desempenho dos classificadores.

Adicionalmente, métodos baseados em aprendizado profundo (*deep learning*), como Redes Neurais Convolucionais (CNNs), podem superar abordagens tradicionais ao lidar com sinais complexos de EA, uma vez que possuem capacidade para aprender hierarquicamente características diretamente das formas de onda no domínio do tempo, possibilitando a identificação integrada de padrões espaciais e temporais frequentemente não capturados por técnicas convencionais.

5.3.2 Abordagem com dados de Emissão Acústica pré-processados

Na segunda abordagem, os sinais de EA foram submetidos previamente a um filtro passa-banda *Butterworth* de ordem 10, aplicado na faixa de frequência entre 3,4 kHz e 4,7 kHz. Tal faixa foi definida com base nas frequências de ressonância associadas ao fenômeno de roçamento leve observadas nas análises espectrais anteriores. O objetivo desse procedimento foi avaliar o impacto da filtragem na capacidade dos algoritmos de aprendizado de máquina para discriminar as condições operacionais do sistema rotativo.

Esse pré-processamento buscou reduzir a influência de componentes espúrias, ruídos ambientais e interferências de baixa frequência, preservando sobretudo as assinaturas espectrais relacionadas ao defeito em análise. Assim, esperava-se melhorar a separação entre as classes e favorecer o desempenho dos classificadores.

Seguindo a metodologia anterior, foram extraídas aleatoriamente 800 amostras dos sinais de EA, utilizando janelas com 15.000 pontos cada. A classificação foi realizada no ambiente

PyCaret, utilizando classes binárias: 0 para condição sem roçamento e 1 para presença de roçamento leve.

Diversos classificadores foram treinados e avaliados por validação cruzada, com os resultados organizados inicialmente segundo a métrica de acurácia. A Tabela 5.5 apresenta os desempenhos completos dos modelos avaliados para os sinais filtrados.

Tabela 5.5: Resultados dos modelos de ML para a abordagem com sinais filtrados de EA.

Modelo	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
Extra Trees Classifier	0.68264	0.73365	0.56962	0.73369	0.63706	0.36552	0.37585	4.45600
Random Forest Classifier	0.65833	0.70823	0.59756	0.67918	0.63340	0.31705	0.32032	5.51200
Quadratic Discriminant Analysis	0.59706	0.70207	0.20474	0.93424	0.32648	0.19484	0.30297	8.87100
Light Gradient Boosting Machine	0.62502	0.67582	0.54372	0.64875	0.58760	0.25032	0.25489	72.61700
Gradient Boosting Classifier	0.61487	0.66407	0.53109	0.63453	0.57405	0.23014	0.23392	654.74400
K Neighbors Classifier	0.59451	0.61564	0.44141	0.63407	0.51807	0.18901	0.19828	5.52700
Decision Tree Classifier	0.55101	0.55103	0.54571	0.55109	0.54806	0.10203	0.10217	32.61200
SVM - Linear Kernel	0.52165	0.50656	0.48929	0.51556	0.40319	0.04337	0.05809	7.67500
Logistic Regression	0.50777	0.49544	0.39808	0.51634	0.44604	0.01571	0.01821	11.31000
Ridge Classifier	0.50141	0.50215	0.39295	0.50716	0.44044	0.00290	0.00464	4.41000
Dummy Classifier	0.50000	0.50000	0.00000	0.00000	0.00000	0.00000	0.00000	3.83300
Linear Discriminant Analysis	0.48103	0.45100	0.38538	0.47537	0.42468	-0.03785	-0.03898	8.35900

Observa-se que o ET alcançou o melhor desempenho global, com acurácia de 0,68264, área sob a curva ROC (AUC) de 0,73365 e *F1-score* de 0,63706. O modelo também apresentou os maiores valores de Kappa (0,36552) e MCC (0,37585), o que indica maior consistência entre as previsões e as classes reais. Esses resultados apontam para uma melhora significativa na capacidade de generalização, em comparação à abordagem com sinais brutos.

O valor elevado de AUC evidenciado pelo ET revela maior habilidade na separação entre as condições com e sem roçamento leve, demonstrando forte poder discriminativo mesmo diante da complexidade dinâmica presente. O equilíbrio entre precisão (0,73369), *recall* (0,56962) e *F1-score* indica que o modelo conseguiu diminuir simultaneamente erros associados a falsos positivos e falsos negativos, aspecto crucial em aplicações de monitoramento preditivo.

Comparando o ET com outros modelos baseados em árvores, como o RF e o GBC, constata-se que o RF obteve *recall* levemente superior (0,59756), sugerindo maior sensibilidade na detecção do defeito. Contudo, o ET apresentou maior precisão e métricas globais mais favoráveis, indicando melhor capacidade de generalização. Por sua vez, o GBC, que performou melhor na análise com sinais brutos, apresentou resultados inferiores após o pré-processamento, o que sugere que a filtragem beneficiou modelos com maior aleatoriedade estrutural, como o ET.

Os resultados indicam ainda que a etapa de filtragem foi determinante para ampliar a separa-

bilidade entre as classes, reduzindo a interferência dos ruídos e preservando principalmente as assinaturas vinculadas ao roçamento leve. Esse fato ressalta a importância do pré-processamento em aplicações de aprendizado de máquina com sinais de EA, sobretudo em cenários industriais marcados por elevada contaminação espectral.

Após a seleção do ET como melhor classificador, procedeu-se à otimização dos seus hiperparâmetros por meio da função `tune_model()`, utilizando validação cruzada em 10 grupos, conforme ilustrado na Tab. 5.6. Contudo, os resultados apontaram desempenho inferior ao apresentado pela configuração padrão. Esse fenômeno indica que o ajuste excessivo dos hiperparâmetros pode ter conduzido a um processo de sobreajuste (*overfitting*), reduzindo a capacidade do modelo de generalizar para dados não vistos durante o treinamento.

Adicionalmente, a busca automática por hiperparâmetros pode ter levado o modelo a configurações demasiadamente específicas ao conjunto de treinamento, comprometendo a preservação dos padrões mais relevantes associados ao roçamento leve. Tal resultado sugere que, em aplicações envolvendo sinais complexos e não estacionários de EA, modelos mais simples e menos ajustados tendem a apresentar maior robustez e consistência.

Tabela 5.6: Resultados da validação cruzada do modelo ET após a otimização dos hiperparâmetros.

Fold	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.6076	0.7115	0.4359	0.6538	0.5231	0.2118	0.2244
1	0.6456	0.6865	0.4872	0.7037	0.5758	0.2883	0.3027
2	0.7595	0.8269	0.6000	0.8889	0.7164	0.5209	0.5514
3	0.5696	0.6301	0.2750	0.6875	0.3929	0.1457	0.1826
4	0.7308	0.8389	0.5641	0.8462	0.6769	0.4615	0.4895
5	0.6410	0.7298	0.5385	0.6774	0.6000	0.2821	0.2882
6	0.6410	0.7337	0.4872	0.7037	0.5758	0.2821	0.2964
7	0.7564	0.7922	0.6410	0.8333	0.7246	0.5128	0.5270
8	0.6923	0.7396	0.5641	0.7586	0.6471	0.3846	0.3979
9	0.7051	0.7541	0.6154	0.7500	0.6761	0.4103	0.4170
Mean	0.6749	0.7444	0.5208	0.7503	0.6109	0.3500	0.3677
Std	0.0608	0.0600	0.1018	0.0763	0.0958	0.1212	0.1215

Diante disso, foram implementadas modificações no processo de otimização, priorizando a seleção criteriosa dos hiperparâmetros mais relevantes para o ET, conforme a Tab. 5.7. Segundo a literatura especializada, a otimização de modelos baseados em árvores deve focar em parâmetros que impactam diretamente a complexidade estrutural, a capacidade de generalização e a robustez

diante de ruídos e variabilidades dos dados. Assim, a busca concentrou-se nos hiperparâmetros `n_estimators`, que determina a quantidade de árvores no ensemble; `min_samples_leaf`, associado ao controle da complexidade das árvores e mitigação do overfitting; e `max_features`, que regula o número de atributos considerados em cada divisão, favorecendo diversidade entre as árvores e equilíbrio entre viés e variância.

Para comparar o impacto dessa otimização em diferentes arquiteturas de ensemble, optou-se também pela otimização do segundo melhor modelo identificado anteriormente, o RF, apresentado na Tab. 5.8. Os hiperparâmetros ajustados foram `n_estimators`, `min_samples_leaf`, `max_features` e `bootstrap`, visando avaliar se um ajuste mais refinado poderia elevar o desempenho do RF a patamares superiores aos do ET. Essa estratégia permitiu verificar se os limites de desempenho devem-se principalmente à configuração dos modelos ou à complexidade intrínseca dos sinais de EA.

Tabela 5.7: Resultados da validação cruzada do modelo RF após a otimização dos hiperparâmetros.

Fold	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.6582	0.7494	0.4359	0.7727	0.5574	0.3126	0.3468
1	0.7215	0.7554	0.5641	0.8148	0.6667	0.4408	0.4629
2	0.7342	0.7875	0.5500	0.8800	0.6769	0.4708	0.5085
3	0.6329	0.6455	0.3250	0.8667	0.4727	0.2715	0.3489
4	0.7436	0.8412	0.5897	0.8519	0.6970	0.4872	0.5120
5	0.7051	0.7594	0.6154	0.7500	0.6761	0.4103	0.4170
6	0.6667	0.7512	0.5128	0.7407	0.6061	0.3333	0.3503
7	0.6410	0.7712	0.5128	0.6897	0.5882	0.2821	0.2918
8	0.7051	0.7452	0.5897	0.7667	0.6667	0.4103	0.4216
9	0.7051	0.7751	0.5897	0.7667	0.6667	0.4103	0.4216
Mean	0.6914	0.7581	0.5285	0.7900	0.6274	0.3829	0.4082
Std	0.0370	0.0461	0.0843	0.0582	0.0672	0.0736	0.0696

Conforme ilustrado nas Tabs. 5.7 e 5.8, a otimização dirigida dos hiperparâmetros promoveu melhorias moderadas no desempenho dos classificadores. No entanto, os avanços permaneceram abaixo do esperado, indicando que a alta complexidade dos sinais de EA continua representando um desafio significativo, mesmo após as etapas de filtragem e pré-processamento. A natureza não estacionária dos sinais, aliada à variabilidade espectral elevada e à sobreposição parcial entre as classes íntegro e danificado, reduz a separabilidade dos padrões, dificultando o aprendizado dos classificadores baseados em árvores.

Tabela 5.8: Resultados da validação cruzada do modelo RF após nova otimização dos hiperparâmetros.

Fold	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.6076	0.6718	0.4872	0.6333	0.5507	0.2128	0.2186
1	0.6835	0.6968	0.6410	0.6944	0.6667	0.3664	0.3674
2	0.7468	0.7410	0.6750	0.7941	0.7297	0.4946	0.5003
3	0.6329	0.5801	0.5000	0.6897	0.5797	0.2683	0.2793
4	0.7051	0.7738	0.6154	0.7500	0.6761	0.4103	0.4170
5	0.6795	0.7456	0.6667	0.6842	0.6753	0.3590	0.3591
6	0.6410	0.7272	0.6154	0.6486	0.6316	0.2821	0.2824
7	0.7821	0.7778	0.7436	0.8056	0.7733	0.5641	0.5658
8	0.6538	0.7226	0.6667	0.6500	0.6582	0.3077	0.3078
9	0.7692	0.7765	0.7692	0.7692	0.7692	0.5385	0.5385
Mean	0.6902	0.7213	0.6380	0.7119	0.6711	0.3804	0.3836
Std	0.0567	0.0574	0.0861	0.0599	0.0694	0.1135	0.1126

Esse quadro demonstra que, apesar de o pré-processamento ter ampliado a separação entre as classes, persistem componentes residuais e padrões espúrios capazes de comprometer parcialmente a generalização dos modelos. Nesse contexto, técnicas adicionais de mineração de dados, seleção automática de características e métodos avançados de extração de atributos podem contribuir para melhorar a representação dos sinais e aumentar a eficiência da classificação.

Adicionalmente, observa-se que o ET apresentou desempenho ligeiramente superior ao RF em métricas globais, destacando-se na acurácia média (0,6914 versus 0,6902), AUC (0,7581 versus 0,7213), MCC (0,4082 versus 0,3836) e precisão (0,7900 versus 0,7119). Esses resultados indicam maior robustez do ET na redução de falsos positivos, tornando o modelo mais confiável na identificação das amostras associadas ao roçamento leve. Por outro lado, o RF obteve maior *recall* (0,6380 frente a 0,5285), indicando maior sensibilidade na detecção da classe danificado, embora acompanhado por uma maior taxa de classificações incorretas da classe íntegro.

As diferenças entre os modelos estão relacionadas à forma como as árvores de decisão são construídas. O RF utiliza a estratégia de bootstrap aggregation (bagging), na qual cada árvore é treinada a partir de amostras do dataset, promovendo diversidade entre os classificadores. Já o ET introduz um grau adicional de aleatoriedade ao selecionar aleatoriamente os pontos de divisão dos nós, reduzindo a variância do modelo e aumentando sua robustez frente a padrões residuais e ruídos remanescentes nos sinais pré-processados.

Para aprofundar a análise do desempenho, as matrizes de confusão dos modelos ET e RF

foram examinadas, conforme ilustrado nas Figs. 5.31 e 5.32. A partir delas, foram obtidos os indicadores de desempenho da Tabela 5.9.




Figura 5.31: Matriz de confusão do algoritmo *Extra Trees Classifier*.




Figura 5.32: Matriz de confusão do algoritmo *Random Forest Classifier*.

Tabela 5.9: Resultados da classificação do defeito nos dados pré-processado de sinais de EA.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
<i>Extra Trees Classifier</i>	70,83	74,80	70,83	69,62
<i>Random Forest Classifier</i>	62,71	62,83	62,71	62,62

A avaliação das matrizes de confusão demonstra que o ET superou o RF na classificação da condição íntegro, identificando corretamente 218 amostras verdadeiramente negativas (TN) e registrando apenas 22 falsos positivos (FP). Em contraste, o RF classificou corretamente 162 amostras íntegras, apresentando 78 FP, o que indica maior propensão a superestimar a condição de defeito.

Por outro lado, o RF evidenciou maior sensibilidade na identificação da condição danificado, classificando corretamente 139 amostras como verdadeiros positivos (TP), frente a 122 amostras corretamente identificadas pelo ET. Entretanto, esse aumento na sensibilidade esteve associado a um número maior de falsos positivos, reduzindo a precisão geral do modelo. Dessa forma, os resultados sugerem que o ET demonstrou um equilíbrio mais adequado entre sensibilidade e confiabilidade das classificações.

Os dados da Tabela 5.9 indicam avanços significativos em todas as métricas quando comparados aos resultados obtidos com sinais brutos de EA apresentados na Tabela 5.4. Destaca-se o aumento expressivo na acurácia e no *F1-score*, evidenciando que o pré-processamento contribuiu diretamente para ampliar a separabilidade entre as classes e diminuir a interferência dos ruídos presentes nos sinais originais.

Esses achados corroboram a literatura relacionada ao monitoramento de máquinas rotativas por meio de EA, que ressalta como componentes espúrias e ruídos podem comprometer substancialmente o aprendizado dos classificadores. Adicionalmente, os ganhos no recall mostram que a etapa de filtragem permitiu aos modelos identificar de forma mais eficaz os padrões vinculados ao roçamento leve, reduzindo a ocorrência de falsos negativos. Tal aspecto assume relevância particular em aplicações de manutenção preditiva, nas quais a não detecção de defeitos iniciais pode levar a falhas progressivas e prejudicar a confiabilidade operacional do sistema.

5.3.3 Abordagem com dados de Emissão Acústica pré-processados e no domínio da frequência

Na terceira abordagem, os sinais de EA previamente filtrados foram transformados para o domínio da frequência por meio da Transformada Discreta de Fourier (dFT). Essa estratégia

objetivou explorar diretamente as assinaturas espectrais associadas ao fenômeno de roçamento leve, permitindo uma representação mais estruturada e distintiva dos padrões presentes nos sinais de EA. Conforme ilustrado na Fig. 5.33, a transição para o domínio da frequência possibilitou uma separação mais nítida entre as condições com e sem roçamento leve. Observa-se que,




Figura 5.33: Resultados da dFT para sinais sem roçamento e com roçamento leve.

embora as amplitudes espectrais aumentem com o incremento da velocidade de rotação, as bandas de ressonância vinculadas ao roçamento mantiveram-se praticamente constantes na faixa analisada. Esse comportamento indica a presença de componentes espectrais características do defeito, independentemente das condições operacionais do rotor, o que sugere que essas frequências estão fortemente relacionadas às ressonâncias estruturais acionadas pelo contato superficial.

A manutenção desse padrão espectral ao longo das diferentes velocidades constitui uma vantagem relevante para os algoritmos de aprendizado de máquina, pois diminui a variabilidade das características associadas ao defeito e favorece a identificação de padrões discriminativos mais consistentes entre as classes analisadas.

Com o intuito de otimizar a capacidade de generalização dos modelos de classificação, foi necessário estruturar adequadamente os dados de entrada no domínio da frequência. Para isso, cada amostra foi dividida em quatro grupos referentes às bandas de frequência entre 3400 e 3600 Hz (Grupo 1), 3800 e 4000 Hz (Grupo 2), 4000 e 4200 Hz (Grupo 3) e 4400 e 4600 Hz (Grupo

4), totalizando 200 pontos espectrais por grupo. A seleção dessas faixas baseou-se diretamente nas regiões de maior concentração energética identificadas nas análises espectrais prévias.

Essa segmentação permitiu expandir o conjunto total para 1.440 amostras, aumentando a diversidade dos dados empregados no treinamento dos modelos e potencializando sua capacidade de generalização. Além disso, a divisão em grupos espectrais específicos viabilizou uma análise mais detalhada das variações locais do espectro associadas ao roçamento leve, permitindo que os classificadores explorassem de forma mais eficaz as diferenças entre os padrões espectrais correspondentes às classes íntegra e danificada.

Adicionalmente, a padronização das bandas de frequência para todas as amostras assegurou maior consistência na extração das características espectrais, reduzindo possíveis variações decorrentes das diferentes condições operacionais do rotor. Tal procedimento contribuiu para aumentar a robustez do processo de classificação e mitigar a influência de componentes espectrais não relacionados ao defeito.

A classificação continuou sendo realizada de forma binária, na qual a classe 0 representava a condição sem roçamento (baseline) e a classe 1 indicava a presença de roçamento leve. Posteriormente, diferentes algoritmos de aprendizado de máquina foram treinados e avaliados mediante validação cruzada, adotando a acurácia como métrica principal para a comparação inicial entre os modelos.

Os resultados evidenciaram novamente a superioridade do ET, que obteve o melhor desempenho entre os algoritmos avaliados, conforme mostrado na Tab. 5.10. Esse comportamento reforça a elevada capacidade do ET em lidar com dados espectrais de alta dimensionalidade e com características parcialmente não lineares, típicas dos sinais de EA relacionados ao fenômeno de roçamento leve.

Observando a Tab. 5.10, nota-se que o ET apresentou o desempenho global mais elevado entre todos os classificadores, alcançando acurácia de 0,93195, *F1-score* de 0,93012, *Kappa* de 0,86396 e MCC de 0,86633. Tais resultados indicam uma forte capacidade de generalização e consistência estatística na distinção entre as classes íntegra e danificada. O desempenho superior do ET pode ser atribuído à sua eficácia na exploração das características espectrais dos sinais de EA, valendo-se da elevada aleatoriedade na construção das árvores de decisão, o que reduz a variância do modelo. Essa propriedade torna o algoritmo particularmente robusto para identificar pequenas variações nas amplitudes espectrais associadas ao roçamento leve.

Em comparação com os modelos subsequentes, observa-se que o SVM com núcleo linear

Tabela 5.10: Resultados dos modelos de ML para a abordagem com sinais de EA no domínio da frequência.

Modelo	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
Extra Trees Classifier	0.93195	0.98060	0.90698	0.95614	0.93012	0.86396	0.86633	0.28000
SVM - Linear Kernel	0.91050	0.97606	0.90071	0.92134	0.90927	0.82104	0.82389	0.16800
Light Gradient Boosting Machine	0.90370	0.95075	0.87063	0.92917	0.89690	0.80768	0.81132	1.66500
Ridge Classifier	0.87787	0.97022	0.80183	0.94771	0.86663	0.75589	0.76728	0.16300
Logistic Regression	0.87934	0.97265	0.81603	0.93657	0.87064	0.75880	0.76699	0.17300
K Neighbors Classifier	0.85672	0.99845	0.71421	1.00000	0.83102	0.71375	0.74602	0.19200
Gradient Boosting Classifier	0.86099	0.94670	0.81032	0.90582	0.85287	0.72199	0.72931	3.94400
Random Forest Classifier	0.85388	0.94051	0.83016	0.87292	0.84989	0.70781	0.71025	0.36800
Linear Discriminant Analysis	0.82980	0.89078	0.74786	0.89678	0.81412	0.65966	0.67034	0.20300
Quadratic Discriminant Analysis	0.77028	0.92406	0.96056	0.69824	0.80800	0.54011	0.58481	0.21400
Decision Tree Classifier	0.77312	0.77286	0.75913	0.78408	0.76881	0.54595	0.54945	0.25900
Dummy Classifier	0.49930	0.50000	0.00000	0.00000	0.00000	0.00000	0.00000	0.15600

apresentou desempenho competitivo, atingindo acurácia de 0,91050 e *recall* de 0,90071. No entanto, os valores inferiores de Kappa (0,82104) e MCC (0,82389) sugerem menor robustez estatística e menor equilíbrio global entre sensibilidade e precisão em relação ao ET. Este padrão sugere que o SVM é mais sensível a certas distribuições espectrais, podendo ser mais suscetível a sobreposições entre as classes.

O *Light Gradient Boosting Machine* (LightGBM) também demonstrou resultados expressivos, com acurácia de 0,90370 e AUC de 0,95075. No entanto, seus índices de Kappa (0,80578) e MCC (0,81039) permaneceram abaixo dos obtidos pelo ET, indicando menor estabilidade nas classificações. Esse comportamento pode estar relacionado à estratégia folha a folha adotada pelo LightGBM, que, embora eficiente em termos computacionais, pode apresentar menor robustez em situações de alta dimensionalidade espectral e variabilidade local dos dados.

A Regressão Logística (*Logistic Regression* - LR), apesar de apresentar acurácia relativamente elevada (0,87934), obteve *recall* inferior (0,86303), sugerindo menor capacidade para identificar amostras associadas ao roçamento leve. Esse resultado é coerente com as limitações inerentes a modelos lineares na representação de relações não lineares complexas entre componentes espectrais, característica frequentemente observada nos sinais de EA.

Por outro lado, o algoritmo dos k-vizinhos mais próximos (k-NN) exibiu o maior valor de AUC entre todos os classificadores (0,99845), indicando excelente separabilidade teórica entre as classes. Contudo, acurácia (0,85672) e *recall* (0,71421) permaneceram inferiores aos obtidos pelo ET, denotando dificuldades do modelo diante da elevada complexidade espectral dos sinais. Ademais, o modelo apresentou precisão igual a 1,0000, acompanhada de *recall* significativamente menor, indicando um comportamento excessivamente conservador na classificação da classe

danificada.

De forma análoga às abordagens anteriores, realizou-se a otimização dos hiperparâmetros do ET por meio da função `tune_model()` com validação cruzada em 10 grupos, conforme ilustrado na Tab. 5.11. O ajuste concentrou-se nos hiperparâmetros `n_estimators`, `min_samples_leaf` e `max_features`, buscando aprimorar a capacidade de generalização do classificador.

Tabela 5.11: Resultados da validação cruzada do modelo ET após a otimização dos hiperparâmetros para sinais de EA no domínio da frequência.

Fold	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
0	0.9718	0.9968	0.9429	1.0000	0.9706	0.9436	0.9451
1	0.9718	0.9984	0.9429	1.0000	0.9706	0.9436	0.9451
2	0.8873	0.9718	0.8889	0.8889	0.8889	0.7746	0.7746
3	0.8873	0.9627	0.8611	0.9118	0.8857	0.7748	0.7760
4	0.9155	0.9651	0.8333	1.0000	0.9091	0.8314	0.8434
5	0.9286	0.9845	0.8857	0.9688	0.9254	0.8571	0.8603
6	0.9571	0.9898	0.9714	0.9444	0.9577	0.9143	0.9147
7	0.9429	0.9951	0.9143	0.9697	0.9412	0.8857	0.8872
8	0.9571	0.9943	0.9429	0.9706	0.9565	0.9143	0.9147
9	0.9286	0.9710	0.8571	1.0000	0.9231	0.8571	0.8660
Mean	0.9348	0.9830	0.9040	0.9654	0.9329	0.8697	0.8727
Std	0.0296	0.0132	0.0433	0.0374	0.0299	0.0592	0.0585

Os resultados indicaram uma melhora discreta no desempenho do modelo em relação à configuração inicial, principalmente nos índices de acurácia e precisão. Essa constatação sugere que os sinais de EA no domínio da frequência já possuíam alta capacidade discriminativa antes mesmo do refinamento dos hiperparâmetros. Assim, os ganhos adicionais provenientes do ajuste fino mostraram-se naturalmente limitados, dado que a estrutura espectral dos dados favorecia uma separabilidade elevada entre as classes.

Esse resultado reforça a importância da conversão para o domínio da frequência na análise de sinais de EA associados ao roçamento leve. A representação espectral evidenciou bandas de ressonância específicas vinculadas ao fenômeno estudado, atenuando significativamente a influência de ruídos e componentes não relacionados ao defeito.

Posteriormente, a matriz de confusão do modelo otimizado foi examinada para avaliar detalhadamente a distribuição dos erros de classificação, conforme apresentado na Fig. 5.34. A partir dessa matriz, foram extraídos os indicadores de desempenho mostrados na Tab. 5.12..




Figura 5.34: Matriz de confusão do *Extra Trees Classifier*.

Tabela 5.12: Resultados da classificação nos dados pré-processado e no domínio da frequência dos sinais de EA.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
<i>Extra Trees Classifier</i>	94,21	94,29	94,20	94,21

Analisando a Fig. 5.34, verifica-se que o ET classificou corretamente 208 amostras da classe íntegra, correspondentes aos verdadeiros negativos (TN), e 199 amostras da classe danificada, referentes aos verdadeiros positivos (TP), totalizando 407 classificações acertadas. Ademais, o modelo apresentou apenas 8 falsos positivos (FP) e 17 falsos negativos (FN), indicando elevada capacidade de distinção entre as condições operacionais examinadas.

Esse desempenho relaciona-se diretamente à aptidão do ET em explorar eficientemente as características espectrais dos sinais de EA. No domínio da frequência, as assinaturas associadas ao roçamento tornam-se mais evidentes devido à presença de bandas de ressonância específicas e ao aumento localizado da energia espectral. A elevada aleatoriedade utilizada pelo ET na seleção de atributos e pontos de divisão nas árvores favorece a captura dessas pequenas variações espectrais, incrementando a robustez e a capacidade de generalização do modelo.

Além disso, por se basear em *ensemble learning*, o ET oferece maior estabilidade estatística e menor propensão ao *overfitting*, aspectos particularmente relevantes em aplicações que envolvem sinais complexos e parcialmente não estacionários, como os sinais de EA investigados neste

estudo.

Os resultados apresentados na Tab. 5.12 demonstram desempenho significativamente superior em relação às duas abordagens anteriores. O modelo atingiu acurácia de 94,21%, acompanhada por elevados índices de precisão, *recall* e *F1-score*, evidenciando forte capacidade de generalização e confiabilidade na identificação do roçamento leve.

Ao comparar os resultados das três abordagens desenvolvidas nesta tese, observa-se que a transformação dos sinais de EA para o domínio da frequência constituiu a etapa mais relevante para o incremento da capacidade discriminativa dos modelos de aprendizado de máquina. Enquanto os sinais brutos apresentaram elevada variabilidade e forte influência de ruídos, e os sinais apenas filtrados mantiveram limitações decorrentes da sobreposição parcial entre as classes, a representação espectral possibilitou revelar padrões mais consistentes e diretamente vinculados ao fenômeno físico do roçamento leve.

Nesse contexto, os resultados obtidos corroboram que o emprego conjunto de técnicas de pré-processamento, análise espectral e algoritmos de aprendizado de máquina configura uma estratégia promissora para aplicações de monitoramento preditivo a partir de sinais de EA. Ademais, os elevados índices de classificação alcançados indicam o potencial da metodologia proposta para a detecção precoce de defeitos iniciais em máquinas rotativas, sobretudo em cenários nos quais técnicas convencionais de análise vibracional enfrentam limitações relevantes.

CAPÍTULO VI

CONCLUSÕES E PERSPECTIVAS FUTURAS

6.1 Conclusões

Considerando a crescente necessidade de métodos mais sensíveis e confiáveis para o monitoramento da integridade estrutural em máquinas rotativas, esta tese de doutorado propõe uma metodologia voltada à detecção e diagnóstico de roçamentos leves por meio da técnica de Emissão Acústica (EA), combinada com sensores piezoelétricos de baixo custo e algoritmos de aprendizado de máquina. A investigação abrangeu desde a aquisição experimental e o processamento dos sinais até a implementação, avaliação e otimização de modelos de classificação, com o objetivo de desenvolver uma abordagem que se mostre mais sensível e robusta em comparação às técnicas convencionais baseadas exclusivamente na análise de vibração.

Em um primeiro momento, foram examinadas distintas estratégias para análise dos sinais de EA, que variaram desde a utilização dos dados brutos até técnicas de pré-processamento nos domínios temporal e frequencial. Entre as metodologias avaliadas, destacou-se a aplicação da Transformada de Hilbert para extração do envelope dos sinais, o que permitiu evidenciar padrões periódicos e assinaturas específicas relacionadas ao roçamento leve. Tal procedimento revelou-se essencial para ressaltar componentes ressonantes de interesse, facilitando a distinção entre diferentes condições operacionais e contribuindo para a melhora da qualidade dos dados submetidos aos modelos de classificação.

Os experimentos indicaram que os sinais de EA apresentaram uma sensibilidade elevada à presença do roçamento leve, mesmo diante de condições em que os sinais dos sensores de proximidade não exibiram alterações significativas. As análises orbitais e espectrais dos sinais de

vibração identificaram apenas pequenas variações quantitativas, tanto na área orbital quanto na energia RMS das órbitas, indicando que o defeito se manteve em estágio incipiente, sem provocar alterações relevantes na dinâmica global do rotor. Esses achados evidenciam as limitações dos sensores de proximidade para a detecção de fenômenos localizados e de alta frequência, como é o caso do roçamento leve, cuja energia tende a se concentrar na região do contato e a se dissipar localmente por meio de mecanismos de atrito e amortecimento estrutural.

Em contraste, a análise dos sinais de EA possibilitou a identificação clara de componentes espectrais vinculados ao defeito, especialmente na faixa de frequência entre 3,4 kHz e 4,7 kHz, que manteve-se praticamente constante para as diferentes velocidades de rotação testadas. A aplicação de filtro passa-banda e a conversão dos sinais para o domínio da frequência contribuíram para mitigar a interferência de ruídos e ressaltaram padrões mais representativos do fenômeno estudado, resultando em uma estrutura de dados mais organizada e discriminativa para os algoritmos de aprendizado de máquina.

No âmbito das abordagens de aprendizado de máquina, verificou-se que os modelos aplicados diretamente aos sinais brutos apresentaram desempenho limitado, reflexo da elevada complexidade e da baixa relação sinal-ruído característica dos sinais de EA. Entretanto, à medida que foram incorporadas técnicas de pré-processamento e segmentação espectral, observou-se um aumento expressivo na capacidade de generalização e classificação dos modelos. Entre os algoritmos avaliados, destacou-se o Extra Trees Classifier como o mais eficiente, especialmente na terceira abordagem, baseada em sinais pré-processados e analisados no domínio da frequência.

Após a otimização dos hiperparâmetros, o modelo alcançou uma acurácia superior a 93%, além de elevados valores de AUC, F1-score, Kappa e MCC, demonstrando alta capacidade discriminativa e robustez estatística. A análise da matriz de confusão confirmou a eficiência do modelo otimizado, com baixos índices de falsos positivos e falsos negativos, aspecto crucial para aplicações em monitoramento preditivo, nas quais falhas na detecção podem comprometer a confiabilidade operacional do sistema.

Adicionalmente, os resultados indicaram que a segmentação dos sinais em janelas espectrais específicas, associadas às frequências de ressonância do roçamento, foi determinante para ampliar o conjunto de dados e melhorar a representatividade das características empregadas no treinamento dos modelos. Esse procedimento favoreceu a extração de padrões mais consistentes, permitindo que os algoritmos explorassem com maior eficiência as diferenças entre as condições com e sem defeito.

Dessa forma, esta pesquisa demonstra a viabilidade da combinação entre a técnica de EA e algoritmos de aprendizado de máquina para o monitoramento preditivo de máquinas rotativas, especialmente na identificação de defeitos incipientes que apresentam dificuldade de detecção por métodos tradicionais. A metodologia proposta evidenciou potencial elevado para aplicação em ambientes industriais, contribuindo para a detecção precoce de falhas, redução de riscos operacionais e adoção de estratégias mais eficientes de manutenção preditiva.

Por fim, os resultados apontam que a integração entre técnicas avançadas de processamento de sinais, análise espectral e aprendizado de máquina configura uma alternativa promissora para a implementação de sistemas inteligentes de monitoramento em máquinas rotativas. Entre as perspectivas futuras, destaca-se a necessidade de ampliar a base experimental, investigar diferentes níveis de severidade do roçamento, aplicar técnicas de aprendizado profundo (deep learning) e validar a metodologia em condições reais de operação industrial, visando fortalecer a robustez e a capacidade de generalização dos modelos desenvolvidos.

6.2 Perspectivas futuras

Com base nos resultados e nas limitações identificadas durante o desenvolvimento experimental e computacional, diversas direções podem ser exploradas para aprimorar a aplicação da técnica de EA no monitoramento e detecção precoce de defeitos em máquinas rotativas.

- a) **Expansão do banco de dados experimental:** Ampliar a base abrangendo variadas condições operacionais, níveis distintos de severidade do roçamento e outros tipos de defeitos em máquinas rotativas representa um passo fundamental para a consolidação estatística dos modelos. A inclusão de diferentes regimes de carga, velocidades de rotação e condições ambientais tende a ampliar a capacidade de generalização dos algoritmos, reforçando a confiabilidade em cenários industriais reais.
- b) **Aprimoramento das técnicas de pré-processamento:** A busca por métodos mais sofisticados de processamento de sinais pode otimizar a extração de características. Técnicas como filtragem adaptativa, decomposição empírica de modos (*Empirical Mode Decomposition* – EMD), Transformada Wavelet e abordagens híbridas que combinam Transformada de Hilbert e Wavelets têm potencial para aprimorar a separação entre ruído e componentes relacionadas ao defeito, favorecendo a identificação de padrões transitórios complexos nos sinais de EA.

- c) **Aplicação de técnicas avançadas para seleção e redução de características:** Métodos de redução de dimensionalidade, incluindo Análise de Componentes Principais (PCA), *t-distributed Stochastic Neighbor Embedding* (t-SNE) e algoritmos genéticos, podem ser explorados para otimizar a representação dos dados e eliminar redundâncias nas características extraídas. Tais estratégias podem incrementar a eficiência computacional, reduzir o tempo de treinamento e, simultaneamente, preservar informações relevantes para a classificação.
- d) **Desenvolvimento de modelos híbridos e abordagens de aprendizado profundo:** Integrar modelos tradicionais de aprendizado de máquina com arquiteturas de *deep learning*, como Redes Neurais Convolucionais (CNNs), Redes Neurais Recorrentes (RNNs) e modelos baseados em *Transformers*, constitui uma linha promissora para aplicações futuras. Essas abordagens automatizam a exploração de padrões complexos presentes nos sinais de EA, sobretudo em cenários com grandes volumes de dados e múltiplas condições operacionais, ampliando a capacidade preditiva e a autonomia dos sistemas de monitoramento..
- e) **Otimização do sistema de aquisição de sinais:** Melhorias na etapa de aquisição podem elevar a qualidade das análises. Estratégias de aterramento elétrico adequado, blindagem eletromagnética e filtragem adaptativa têm potencial para reduzir interferências externas e aprimorar a relação sinal-ruído dos sinais de EA. Ainda, o desenvolvimento de sistemas embarcados capazes de aquisição em tempo real pode viabilizar aplicações industriais contínuas e monitoramento remoto.
- f) **Validação em ambientes industriais reais:** Apesar dos resultados satisfatórios obtidos em bancada, a validação da metodologia em ambientes industriais representa etapa crucial para confirmar sua aplicabilidade prática. Ensaio em máquinas sob condições reais de carga, vibração e ruído possibilitarão avaliar a robustez da abordagem diante das variabilidades típicas desses ambientes.
- g) **Integração com estratégias de manutenção preditiva:** Outra vertente relevante é a incorporação da metodologia em plataformas preditivas e sistemas contínuos de monitoramento alinhados aos princípios da Indústria 4.0. Sistemas inteligentes conectados podem proporcionar diagnósticos automatizados em tempo real, favorecendo tomadas de decisão ágeis e contribuindo para a redução de custos operacionais associados a falhas inesperadas.

Assim, as perspectivas apresentadas ressaltam que a conjugação de técnicas avançadas de processamento de sinais, Emissão Acústica e inteligência artificial possui potencial significativo para o desenvolvimento de sistemas de monitoramento mais autônomos, robustos e aplicáveis em contextos industriais complexos.

REFERÊNCIAS BIBLIOGRÁFICAS

AL-DOSSARY, S.; HAMZAH, R. R.; MBA, D. Observations of changes in acoustic emission waveform for varying seeded defect sizes in a rolling element bearing. *Applied acoustics*, Elsevier, v. 70, n. 1, p. 58–81, 2009. DOI: 10.1016/j.apacoust.2008.01.005. Citado 1 vez na página 11.

AL-GHAMD, A. M.; MBA, D. A comparative experimental study on the use of acoustic emission and vibration analysis for bearing defect identification and estimation of defect size. *Mechanical systems and signal processing*, Elsevier, v. 20, n. 7, p. 1537–1571, 2006. DOI: 10.1016/j.ymssp.2004.10.013. Citado 1 vez na página 32.

ASTM. *Standard Terminology for Nondestructive Examinations (ASTM E1316)*. [S.l.]: ASTM International West Conshohocken, PA, USA, 2014. Citado 1 vez na página 23.

BARELLA, B. P. et al. *Modelagem com aprendizado de máquina aplicada aos sistemas de monitoramento de integridade estrutural*. Dissertação (Mestrado) — Universidade Federal de Goiás, 2021. Citado 6 vezes nas páginas viii, 37, 38, 39, 40 e 41.

BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, p. 5–32, 2001. DOI: 10.1023/A:1010933404324. Citado 4 vezes nas páginas viii, 4, 42 e 43.

BRITO, L. C. *Explainable artificial intelligence approaches for fault diagnosis in rotating machinery*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2022. Citado 1 vez na página 4.

CASO, E.; RINCON, A. Fernandez-del; GARCIA, P.; IGLESIAS, M.; VIADERO, F. Monitoring of misalignment in low speed geared shafts with acoustic emission sensors. *Applied Acoustics*, Elsevier, v. 159, p. 107092, 2020. DOI: 10.1016/j.apacoust.2019.107092. Citado 1 vez na página 16.

CASTRO, B.; CLERICE, G.; RAMOS, C.; ANDREOLI, A.; BAPTISTA, F.; CAMPOS, F.; ULSON, J. Partial discharge monitoring in power transformers using low-cost piezoelectric sensors. *Sensors*, MDPI, v. 16, n. 8, p. 1266, 2016. DOI: 10.3390/s16081266. Citado 3 vezes nas páginas 14, 26 e 27.

CASTRO, B. A. de; SANTOS, V. V. D.; LUCAS, G. B.; ARDILA-REY, J. A.; RIEHL, R. R.; ANDREOLI, A. L. A comparative analysis applied to the partial discharges identification in dry-type transformers by hall and acoustic emission sensors. *Sensors*, MDPI, v. 22, n. 5, p. 1716, 2022. DOI: 10.3390/s22051716. Citado 1 vez na página 34.

CAVALINI Jr., A. *Detecção e Identificação de Trincas Transversais Incipientes em Eixos Horizontais Flexíveis de Máquinas Rotativas*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2013. Citado 1 vez na página 2.

CHACON, J. L. F. *Fault detection in rotating machinery using acoustic emission*. Tese (Doutorado) — Brunel University London, 2015. Citado 5 vezes nas páginas 2, 3, 28, 32 e 33.

CHACON, J. L. F. *Fault Detection in Rotating Machinery Using Acoustic Emission*. Tese (Doutorado), 10 2015. DOI: 10.13140/RG.2.1.2369.5444. Citado 1 vez na página 8.

CHACON, J. L. F.; ANDICOBERRY, E. A.; KAPPATOS, V.; ASFIS, G.; GAN, T.-H.; BALACHANDRAN, W. Shaft angular misalignment detection using acoustic emission. *Applied acoustics*, Elsevier, v. 85, p. 12–22, 2014. DOI: 10.1016/j.apacoust.2014.03.018. Citado 1 vez na página 13.

CHOUDHURY, A.; TANDON, N. Application of acoustic emission technique for the detection of defects in rolling element bearings. *Tribology international*, Elsevier, v. 33, n. 1, p. 39–45, 2000. DOI: 10.1016/S0301-679X(00)00012-8. Citado 1 vez na página 9.

CIABURRO, G.; IANNACE, G. Machine-learning-based methods for acoustic emission testing: a review. *Applied Sciences*, MDPI, v. 12, n. 20, p. 10476, 2022. DOI: 10.3390/app122010476. Citado 4 vezes nas páginas 2, 18, 28 e 36.

DATA CAMP. *A Guide to the Gradient Boosting Algorithm*. 2023. Acessado em: 24 jan. 2025. Disponível em: <https://www.datacamp.com/tutorial/guide-to-the-gradient-boosting-algorithm>. Citado 1 vez na página 45.

DURKHURE, P.; LODWAL, A. Fault diagnosis of ball bearing using time domain analysis and fast fourier transformation. *International journal of engineering sciences & research technology*, v. 3, p. 711–715, 2014. Disponível em: https://www.academia.edu/7877580/Fault_Diagnosis_of_Ball_Bearing_using_Time_Domain_Analysis_and_Fast_Fourier_Transformation. Citado 1 vez na página 33.

ELASHA, F.; GREAVES, M.; MBA, D.; FANG, D. A comparative study of the effectiveness of vibration and acoustic emission in diagnosing a defective bearing in a planetary gearbox. *Applied Acoustics*, Elsevier, v. 115, p. 181–195, 2017. DOI: 10.1016/j.apacoust.2016.07.026. Citado 3 vezes nas páginas 14, 30 e 31.

ELFORJANI, M.; MBA, D. Condition monitoring of slow-speed shafts and bearings with acoustic emission. *Strain*, Wiley Online Library, v. 47, p. 350–363, 2011. DOI: 10.1111/j.1475-1305.2010.00776.x. Citado 2 vezes nas páginas 12 e 32.

ELIZAROV, S. V.; BARAT, V. A.; TEREITYEV, D. A.; KOSTENKO, P. P.; BARDAKOV, V. V.; ALYAKRITSKY, A. L.; KOLTISOV, V. G.; TROFIMOV, P. N. Acoustic emission monitoring of industrial facilities under static and cyclic loading. *Applied Sciences*, MDPI, v. 8, n. 8, p. 1228, 2018. DOI: 10.3390/app8081228. Citado 2 vezes nas páginas 14 e 32.

FARIA, M. T. C.; PIMENTEL-JUNIOR, G. L. On the crack propagation in rotating shafts supported by fluid film bearings using high-frequency acoustic emission analysis. *Arabian Journal for Science and Engineering*, Springer, v. 44, n. 2, p. 1709–1712, 2018. DOI: 10.1007/s13369-018-3453-2. Citado 2 vezes nas páginas 15 e 34.

FILHO, P. H. C. d. A. *Estudo comparativo de métodos de diagnóstico de falhas em rolamentos através da análise de vibração com ênfase em turbinas eólicas*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 2018. Citado 1 vez na página 31.

FILIPPIN, C. G. *Emissão Acústica: Conceitos e Aplicações*. Curitiba: Institutos Lactec, 2017. Citado 4 vezes nas páginas viii, 22, 23 e 25.

FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, JSTOR, p. 1189–1232, 2001. DOI: 10.1214/aos/1013203451. Citado 1 vez na página 45.

GÉRON, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. [S.l.]: "O'Reilly Media, Inc.", 2022. Citado 4 vezes nas páginas 37, 38, 39 e 40.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. *Machine learning*, Springer, v. 63, p. 3–42, 2006. DOI: 10.1007/s10994-006-6226-1. Citado 2 vezes nas páginas 4 e 44.

GONÇALVES, D. F. *Contribuição ao uso de inteligência artificial para detecção e diagnóstico de falhas em máquinas rotativas*. Tese (Doutorado) — Universidade Federal de Uberlândia, 2024. Citado 1 vez na página 4.

Graham, L. J.; Randall, R. L.; Hong, C. Acoustic emission monitoring of steam turbines. In: *Power generation conference*. [s.n.], 1982. p. 4–8. Disponível em: <https://ui.adsabs.harvard.edu/abs/1982ric..reptR....G>. Citado 1 vez na página 8.

GRIFFIN, C.; GIURGIUTIU, V. Piezoelectric wafer active sensor transducers for acoustic emission applications. *Sensors*, MDPI, v. 23, n. 16, p. 7103, 2023. DOI: 10.3390/s23167103. Citado 1 vez na página 18.

GU, D. S.; CHOI, B. K. Machinery faults detection using acoustic emission signal. *Acoustic Waves-From Microdevices to Helioseismology*, IntechOpen, p. 171–190, 2011. DOI: 10.5772/22892. Citado 1 vez na página 31.

HE, T.; XIAO, D.; PAN, Q.; LIU, X.; SHAN, Y. Analysis on accuracy improvement of rotor–stator rubbing localization based on acoustic emission beamforming method. *Ultrasonics*, Elsevier, v. 54, n. 1, p. 318–329, 2014. DOI: 10.1016/j.ultras.2013.04.017. Citado 1 vez na página 3.

HE, Y.; YIN, X.; CHU, F. Modal analysis of rubbing acoustic emission for rotor-bearing system based on reassigned wavelet scalogram. *Journal of Vibration and Acoustics*, v. 130, 2008. DOI: 10.1115/1.2981091. Citado 1 vez na página 11.

HE, Y.; ZHANG, X.; FRISWELL, M. I. Defect diagnosis for rolling element bearings using acoustic emission. *Journal of Vibration and Acoustics*, v. 131, 2009. DOI: 10.1115/1.4000480. Citado 2 vezes nas páginas 2 e 11.

HECKE, B. V.; QU, Y.; HE, D. Bearing fault diagnosis based on a new acoustic emission sensor technique. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, SAGE Publications Sage UK: London, England, v. 229, n. 2, p. 105–118, 2015. DOI: 10.1177/1748006X14558900. Citado 3 vezes nas páginas 2, 13 e 32.

HEMMATI, F.; ALQARADAWI, M.; GADALA, M. S. Rolling element bearing fault diagnostics using acoustic emission technique and advanced signal processing. *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, SAGE Publications Sage UK: London, England, v. 230, n. 1, p. 64–77, 2016. DOI: 10.1177/1350650115591233. Citado 2 vezes nas páginas 31 e 33.

HOLFORD, K.; EATON, M.; CLARKE, A.; PEARSON, M.; FEATHERSTON, C.; PULLIN, R. Approaches to acoustic emission monitoring with applicability to key components in wind turbines. In: *Proceedings of 9th International Workshop on Structural Health Monitoring*. Stanford University, USA. [s.n.], 2013. Disponível em: https://www.dpi-proceedings.com/index.php/shm2013/article/view/23057?utm_source=chatgpt.com. Citado 1 vez na página 21.

HOLFORD, K. M. Acoustic emission in structural health monitoring. *Key Engineering Materials*, Trans Tech Publ, v. 413, p. 15–28, 2009. DOI: 10.4028/www.scientific.net/KEM.413-414.15. Citado 2 vezes nas páginas 12 e 21.

IBM. *Confusion Matrix*. 2024. Acessado em: 20 jan. 2025. Disponível em: <https://www.ibm.com/br-pt/topics/confusion-matrix>. Citado 3 vezes nas páginas viii, 39 e 40.

JOSEPH, R.; BHUIYAN, M. Y.; GIURGIUTIU, V. Piezoelectric wafer active sensors for sensing acoustic emission due to crack rubbing/clapping. In: *SPIE. Active and Passive Smart Structures and Integrated Systems XIII*. [S.l.], 2019. v. 10967, p. 583–593. DOI: 10.1117/12.2515314. Citado 1 vez na página 16.

JU, S.; LI, D.; JIA, J. Machine-learning-based methods for crack classification using acoustic emission technique. *Mechanical Systems and Signal Processing*, Elsevier, v. 178, p. 109253, 2022. DOI: 10.1016/j.ymssp.2022.109253. Citado 3 vezes nas páginas 18, 28 e 36.

JÚNIOR, M. S. S. *Análise do comportamento dinâmico de rotores embarcados quando da ocorrência de contato mecânico*. Tese (Tese (Doutorado em Engenharia Mecânica)) — Universidade Federal de Uberlândia, Uberlândia, 2022. 128 f. Citado 2 vezes nas páginas 46 e 51.

KAISER, J. *Untersuchung über das Auftreten von Geräuschen beim Zugversuch*. Tese (Doutorado) — Fakultät für Maschinenwesen und Elektrotechnik der Technischen Universität München, 1950. Dr.-Ing. Dissertation, 15.2.1950. Citado 1 vez na página 21.

KUNDU, P. Review of rotating machinery elements condition monitoring using acoustic emission signal. *Expert Systems with Applications*, Elsevier, v. 252, p. 124169, 2024. DOI: 10.1016/j.eswa.2024.124169. Citado 1 vez na página 36.

LI, J.; DENG, A.; YANG, Y.; ZHU, J.; DENG, M. Research on the method of rub-impact fault recognition based on the conditional generative adversarial nets and acoustic emission. In: *2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD)*. [S.l.: s.n.], 2020. p. 633–637. DOI: 10.1109/ICSMD50554.2020.9261705. Citado 2 vezes nas páginas 3 e 16.

LIU, R.; YANG, B.; ZIO, E.; CHEN, X. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 33–47, 2018. DOI: 10.1016/j.ymssp.2018.02.016. Citado 1 vez na página 4.

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. DOI: 10.1007/s40436-021-00375-w. Citado 1 vez na página 1.

LOPES, W. N.; AGUIAR, P. R.; JUNIOR, P. O. C.; DOTTO, F. R.; FERNANDEZ, B. O.; BIANCHI, E. C. Study of the use of piezoelectric diaphragm as a low-cost alternative to the acoustic emission sensor in dressing operation of aluminum oxide wheels. *IEEE Sensors Journal*, IEEE, v. 21, n. 16, p. 18055–18062, 2021. DOI: 10.1109/JSEN.2021.3085246. Citado 2 vezes nas páginas 17 e 27.

LU, W.; CHU, F. Shaft crack identification based on vibration and ae signals. *Shock and Vibration*, Wiley Online Library, v. 18, n. 1-2, p. 115–126, 2011. DOI: 10.3233/SAV-2010-0580. Citado 1 vez na página 12.

LUCAS, G. B.; CASTRO, B. A. D.; ARDILA-REY, J. A.; GLOWACZ, A.; LEÃO, J. V. F.; ANDREOLI, A. L. A novel approach applied to transient short-circuit diagnosis in tims by piezoelectric sensors, pca, and wavelet transform. *IEEE Sensors Journal*, IEEE, v. 23, n. 8, p. 8899–8908, 2023. DOI: 10.1109/JSEN.2023.3252816. Citado 2 vezes nas páginas 18 e 27.

LUCAS, G. B.; CASTRO, B. A. D.; ROCHA, M. A.; ANDREOLI, A. L. A new acoustic emission-based approach for supply disturbances evaluation in three-phase induction motors. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 70, p. 1–10, 2020. DOI: 10.1109/TIM.2020.3047492. Citado 3 vezes nas páginas 17, 34 e 35.

LUCAS, G. B.; CASTRO, B. A. de; ROCHA, M. A.; ANDREOLI, A. L. Three-phase induction motor loading estimation based on wavelet transform and low-cost piezoelectric sensors. *Measurement*, Elsevier, v. 164, p. 107956, 2020. DOI: 10.1016/j.measurement.2020.107956. Citado 2 vezes nas páginas 17 e 27.

MÁTHIS, K.; CHMELÍK, F. Exploring plastic deformation of metallic materials by the acoustic emission technique. *Acoustic emission*, InTech Rijeka, Croatia, p. 23–48, 2012. DOI: 10.5772/31660. Citado 1 vez na página 21.

MBA, D.; COOKE, A.; ROBY, D.; HEWITT, G. Detection of shaft-seal rubbing in large-scale power generation turbines with acoustic emissions. case study. *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, SAGE Publications Sage UK: London, England, v. 218, n. 2, p. 71–81, 2004. DOI: 10.1243/095765004773644076. Citado 1 vez na página 9.

MBA, D.; HALL, L. The transmission of acoustic emission across large-scale turbine rotors. *Ndt & E International*, Elsevier, v. 35, n. 8, p. 529–539, 2002. DOI: 10.1016/S0963-8695(02)00026-9. Citado 1 vez na página 3.

MBA, D.; RAO, R. Development of acoustic emission technology for condition monitoring and diagnosis of rotating machines: bearings, pumps, gearboxes, engines, and rotating structures. *Shock and Vibration Digest*, Washington, DC: The Center, v. 38, n. 1, p. 3–18, 2006. DOI: 10.1177/0583102405059054. Citado 1 vez na página 10.

MCFADDEN, P.; SMITH, J. Model for the vibration produced by a single point defect in a rolling element bearing. *Journal of Sound and Vibration*, v. 96, n. 1, p. 69–82, 1984. ISSN 0022-460X. DOI: 10.1016/0022-460X(84)90595-9. Citado 1 vez na página 33.

MEI, H.; HAIDER, M. F.; JOSEPH, R.; MIGOT, A.; GIURGIUTIU, V. Recent advances in piezoelectric wafer active sensors for structural health monitoring applications. *Sensors*, MDPI, v. 19, n. 2, p. 383, 2019. DOI: 10.3390/s19020383. Citado 1 vez na página 16.

MOKHTARI, N.; GRZESZKOWSKI, M.; GÜHMANN, C. Vibration signal analysis for the lifetime-prediction and failure detection of future turbofan components. *Technische Mechanik-European Journal of Engineering Mechanics*, v. 37, n. 2-5, p. 422–431, 2017. DOI: 10.24352/UB.OVGU-2017-118. Citado 1 vez na página 32.

MOKHTARI, N.; PELHAM, J. G.; NOWOISKY, S.; BOTE-GARCIA, J.-L.; GÜHMANN, C. Friction and wear monitoring methods for journal bearings of geared turbofans based on acoustic emission signals and machine learning. *Lubricants*, MDPI, v. 8, n. 3, p. 29, 2020. DOI: 10.3390/lubricants8030029. Citado 1 vez na página 17.

MORHAIN, A.; MBA, D. Bearing defect diagnosis and acoustic emission. *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, SAGE Publications Sage UK: London, England, v. 217, n. 4, p. 257–272, 2003. DOI: 10.1243/135065003768618614. Citado 1 vez na página 9.

NOR, N. M. Structural health monitoring through acoustic emission. In: PACHECO-TORGAL, F.; MELCHERS, R. E.; SHI, X.; BELIE, N. D.; TITTELBOOM, K. V.; SáEZ, A. (Ed.). *Eco-Efficient Repair and Rehabilitation of Concrete Infrastructures*. [S.l.]: Woodhead Publishing, 2018, (Woodhead Publishing Series in Civil and Structural Engineering). p. 123–146. ISBN 978-0-08-102181-1. DOI: 10.1016/B978-0-08-102181-1.00006-X. Citado 3 vezes nas páginas 2, 21 e 23.

Oliveira Neto, J. M. d. et al. *Desenvolvimento de um sistema inteligente de monitoramento prescritivo para severidade das condições de funcionamento de um redutor do tipo coroa sem-fim*. Tese (Doutorado) — Universidade Federal da Paraíba, 2023. Citado 11 vezes nas páginas viii, 4, 29, 32, 33, 34, 35, 36, 37, 38 e 43.

ORALLO, C. M.; CARUGATI, I.; MAESTRI, S.; DONATO, P. G.; CARRICA, D.; BENEDETTI, M. Harmonics measurement with a modulated sliding discrete fourier transform algorithm. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 63, n. 4, p. 781–793, 2013. DOI: 10.1109/TIM.2013.2287801. Citado 1 vez na página 30.

OVY, E. G. *Study of Rubbing Phenomenon due to Contact Between Rotor and Guide in Rotating Machinery and Its Minimization*. Tese (Doutorado) — Islamic University of Technology, Bangladesh, 2012. Disponível em: <https://repository.iutoic-dhaka.edu/items/69c909e2-d600-4b17-af49-a34e0cf862f8>. Citado 1 vez na página 1.

PAO, Y.-H.; GAJEWSKI, R. R.; CERANOGLU, A. N. Acoustic emission and transient waves in an elastic plate. *The Journal of the Acoustical Society of America*, Acoustical Society of America, v. 65, n. 1, p. 96–105, 1979. DOI: 10.1121/1.382274. Citado 1 vez na página 21.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. *Scikit-learn: Machine Learning in Python*. [S.l.], 2011. v. 12, 2825–2830 p. Disponível em: https://scikit-learn.org/stable/user_guide.html. Citado 1 vez na página 42.

- PENG, W.; LIU, W.; CHENG, X.; SHI, L. Feedforward chaotic neural network model for rotor rub-impact fault recognition using acoustic emission method. *Journal of Electrical and Computer Engineering*, Wiley Online Library, v. 2018, n. 1, p. 9718951:1–9718951:9, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:52982800>. Citado 1 vez na página 1.
- PIMENTEL-JUNIOR, G. L. S.; OLIVEIRA, F. B.; FARIA, M. T. C. et al. On the bump tests of cracked shafts using acoustic emission techniques. *Engineering*, Scientific Research Publishing, v. 8, n. 09, p. 572, 2016. DOI: 10.4236/eng.2016.89053. Citado 3 vezes nas páginas 14, 33 e 34.
- PRABITH, K.; KRISHNA, I. P. The numerical modeling of rotor–stator rubbing in rotating machinery: a comprehensive review. *Nonlinear Dynamics*, Springer, v. 101, n. 2, p. 1317–1363, 2020. DOI: 10.1007/s11071-020-05832-y. Citado 3 vezes nas páginas 1, 2 e 3.
- PYCARET. *PyCaret Official Website*. 2024. Accessed: 21-Jan-2025. Disponível em: <https://pycaret.org>. Citado 1 vez na página 42.
- RANDALL, R. B. *Vibration-based condition monitoring: industrial, automotive and aerospace applications*. [S.l.]: John Wiley & Sons, 2021. Citado 1 vez na página 33.
- RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics—a tutorial. *Mechanical systems and signal processing*, Elsevier, v. 25, n. 2, p. 485–520, 2011. DOI: 10.1016/j.ymssp.2010.07.017. Citado 1 vez na página 31.
- REZINSKIKH, V.; LUK'YANENKO, V.; SARKISYAN, V. A technique for nondestructive testing of intermediate-and low-pressure rotors of turbines at thermal power plants without dismounting shrunk-on disks during maintenance. *Power Technology and Engineering*, Springer, v. 47, n. 5, p. 367–372, 2014. DOI: 10.1007/s10749-014-0455-4. Citado 1 vez na página 21.
- ROKACH, L. Decision forest: Twenty years of research. *Information Fusion*, Elsevier, v. 27, p. 111–125, 2016. DOI: 10.1016/j.inffus.2015.06.005. Citado 1 vez na página 4.
- ROY, P.; DATTA, A. K.; TOPDAR, P. A study on the efficacy of modal acoustic emission technique for health monitoring of structures with different geometries. *Nondestructive Testing and Evaluation*, Taylor & Francis, v. 39, n. 4, p. 846–885, 2024. DOI: 10.1080/10589759.2023.2231611. Citado 1 vez na página 2.
- RUIZ-CÁRCEL, C.; HERNANI-ROS, E.; CAO, Y.; MBA, D. Use of spectral kurtosis for improving signal to noise ratio of acoustic emission signal from defective bearings. *Journal of Failure Analysis and Prevention*, Springer, v. 14, p. 363–371, 2014. DOI: 10.1007/s11668-014-9805-7. Citado 1 vez na página 13.
- SAIMURUGAN, M. *A Machine Learning Approach to Multicomponent Fault Diagnosis of Rotating Machines Using Sound and Vibration Signals*. Tese (Doutorado) — Amrita School of Engineering, Amrita Vishwa Vidyapeetham, Coimbatore, India, 2013. Citado 2 vezes nas páginas 1 e 2.
- SANTOS, V. V. d.; CASTRO, B. A. d.; BINOTTO, A.; REY, J. A. A.; LUCAS, G. B.; ANDREOLI, A. L. An application of wavelet analysis to assess partial discharge evolution by acoustic emission sensor. *Engineering Proceedings*, MDPI, v. 2, n. 1, p. 33, 2020. DOI: 10.3390/ecsa-7-08244. Citado 1 vez na página 16.

SATO, I. Rotating machinery diagnosis with acoustic emission techniques. *Electrical engineering in Japan*, v. 110, n. 2, 1990. Disponível em: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/eej.4391100211>. Citado 2 vezes nas páginas 3 e 8.

SAWICKI, J. T.; FRISWELL, M. I.; PESCH, A. H.; WROBLEWSKI, A. Condition monitoring of rotor using active magnetic actuator. In: *Turbo Expo: Power for Land, Sea, and Air*. [S.l.: s.n.], 2008. v. 43154, p. 1257–1265. DOI: 10.1115/GT2008-51169. Citado 1 vez na página 2.

SEN, P. C.; HAJRA, M.; GHOSH, M. Supervised classification algorithms in machine learning: A survey and review. In: SPRINGER. *Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018*. [S.l.], 2020. p. 99–111. DOI: 10.1007/978-981-13-7403-6_11. Citado 1 vez na página 38.

SIEGEL, D.; AL-ATAT, H.; SHAUCHE, V.; LIAO, L.; SNYDER, J.; LEE, J. Novel method for rolling element bearing health assessment—a tachometer-less synchronously averaged envelope feature extraction technique. *Mechanical Systems and Signal Processing*, Elsevier, v. 29, p. 362–376, 2012. DOI: 10.1016/j.ymssp.2012.01.003. Citado 2 vezes nas páginas 30 e 31.

SILVA, H. R. d. et al. *Metodologia para análise de trincas de hidrogênio em soldas através de ensaios destrutivos e emissão acústica*. 150 p. Dissertação (Mestrado) — Universidade Federal de Uberlândia, 2010. Citado 1 vez na página 22.

SIRASKAR, R.; KUMAR, S.; PATIL, S.; BONGALE, A.; KOTTECHA, K. Reinforcement learning for predictive maintenance: A systematic technical review. *Artificial Intelligence Review*, Springer, v. 56, n. 11, p. 12885–12947, 2023. DOI: 10.1007/s10462-023-10468-6. Citado 1 vez na página 38.

SUPRAMANIAM, A.; AHMAD, S. S. S.; YUSOH, Z. I. M. Predictive maintenance using deep reinforcement learning. In: IEEE. *2024 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)*. [S.l.], 2024. p. 671–676. DOI: 10.1109/IICAET62352.2024.10730350. Citado 1 vez na página 38.

TAN, C. K.; IRVING, P.; MBA, D. Diagnostics and prognostics with acoustic emission, vibration and spectrometric oil analysis for spur gears—a comparative study. *Insight-Non-Destructive Testing and Condition Monitoring*, The British Institute of Non-Destructive Testing, v. 47, n. 8, p. 478–480, 2005. DOI: 10.1784/insi.2005.47.8.478. Citado 1 vez na página 10.

TANG, L.; WU, X.; WANG, D.; LIU, X. A comparative experimental study of vibration and acoustic emission on fault diagnosis of low-speed bearing. *IEEE Transactions on Instrumentation and Measurement*, IEEE, 2023. DOI: 10.1109/TIM.2023.3312761. Citado 1 vez na página 3.

TOUOUNTZAKIS, T.; TAN, C. K.; MBA, D. Application of acoustic emission to seeded gear fault detection. *Ndt & E International*, Elsevier, v. 38, n. 1, p. 27–36, 2005. DOI: 10.1016/j.ndteint.2004.06.008. Citado 1 vez na página 10.

VIERA, M. A. A.; AGUIAR, P. R.; JUNIOR, P. O.; ALEXANDRE, F. A.; LOPES, W. N.; BIANCHI, E. C.; SILVA, R. B. da; D'ADDONA, D.; ANDREOLI, A. A time–frequency acoustic emission-based technique to assess workpiece surface quality in ceramic grinding with pzt transducer. *Sensors*, MDPI, v. 19, n. 18, p. 3913, 2019. DOI: 10.3390/s19183913. Citado 1 vez na página 15.

- VIERA, M. A. A.; AGUIAR, P. R. D.; JUNIOR, P. O.; SILVA, R. B. D.; JACKSON, M. J.; ALEXANDRE, F. A.; BIANCHI, E. C. Low-cost piezoelectric transducer for ceramic grinding monitoring. *IEEE Sensors Journal*, IEEE, v. 19, n. 17, p. 7605–7612, 2019. DOI: 10.1109/JSEN.2019.2917119. Citado 4 vezes nas páginas 15, 26, 27 e 29.
- VIERA, M. A. A.; GÖTZ, R.; AGUIAR, P. R. D.; ALEXANDRE, F. A.; FERNANDEZ, B. O.; JUNIOR, P. O. A low-cost acoustic emission sensor based on piezoelectric diaphragm. *IEEE Sensors Journal*, IEEE, v. 20, n. 16, p. 9377–9384, 2020. DOI: 10.1109/JSEN.2020.2988478. Citado 1 vez na página 27.
- WANG, Q.; CHU, F. Experimental determination of the rubbing location by means of acoustic emission and wavelet transform. *Journal of Sound and Vibration*, Elsevier, v. 248, n. 1, p. 91–103, 2001. DOI: 10.1006/jsvi.2001.3676. Citado 1 vez na página 3.
- WEI, Y.; LI, Y.; XU, M.; HUANG, W. A review of early fault diagnosis approaches and their applications in rotating machinery. *Entropy*, MDPI, v. 21, n. 4, p. 409, 2019. DOI: 10.3390/e21040409. Citado 1 vez na página 34.
- WEVERS, M.; LAMBRIGHS, K. Applications of acoustic emission for shm: A review. *Encyclopedia of Structural Health Monitoring*, Wiley Online Library, 2009. DOI: 10.1002/9780470061626.shm011. Citado 1 vez na página 23.
- YAN, R.; GAO, R. X.; CHEN, X. Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal processing*, Elsevier, v. 96, p. 1–15, 2014. DOI: 10.1016/j.sigpro.2013.04.015. Citado 1 vez na página 34.
- YU, L.; MOMENI, S.; GODINEZ, V.; GIURGIUTIU, V. Adaptation of pw as transducers to acoustic emission sensors. In: SPIE. *Nondestructive Characterization for Composite Materials, Aerospace Engineering, Civil Infrastructure, and Homeland Security 2011*. [S.l.], 2011. v. 7983, p. 658–667. DOI: 10.1117/12.880157. Citado 1 vez na página 12.
- ZHIHAO, J.; DAN, W.; WEN, J.; BANGCHUN, W. The wavelet transform in the acoustic emission signal feature extraction of the rubbing fault. In: IEEE. *2009 First International Workshop on Database Technology and Applications*. [S.l.], 2009. p. 283–286. DOI: 10.1109/DBTA.2009.164. Citado 1 vez na página 3.
- ZHOU, Z.-H.; FENG, J. Deep forest. *National science review*, Oxford University Press, v. 6, n. 1, p. 74–86, 2019. DOI: 10.48550/arXiv.1702.08835. Citado 1 vez na página 43.