



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA ELÉTRICA

FELIPE SILVEIRA PIANO

**ANÁLISE DE ATRIBUTOS DE SINAIS DE VIBRAÇÃO PARA O
DIAGNÓSTICO DE FALHAS EM ROLAMENTOS UTILIZANDO PCA E
CLUSTERING HIERÁRQUICO**

TUCURUÍ

2026

FELIPE SILVEIRA PIANO

**ANÁLISE DE ATRIBUTOS DE SINAIS DE VIBRAÇÃO PARA O
DIAGNÓSTICO DE FALHAS EM ROLAMENTOS UTILIZANDO PCA E
CLUSTERING HIERÁRQUICO**

Trabalho de Conclusão de Curso, apresentado
como requisito parcial para a obtenção de
grau de Bacharel em Engenharia Elétrica,
pela Universidade Federal do Pará.

Orientador:
Prof. Dr. Rafael Suzuki Bayma.

TUCURUÍ

2026

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

S587a Silveira Piano, Felipe.
 Análise de atributos de sinais de vibração para o diagnóstico de
 falhas em rolamentos utilizando pca e clustering hierárquico /
 Felipe Silveira Piano. — 2026.
 xvii, 76 f. : il. color.

 Orientador(a): Prof. Dr. Rafael Suzuki Bayma
 Trabalho de Curso (Graduação) - Universidade Federal do Pará,
 Campus Universitário de Tucuruí, Faculdade de Engenharia
 Elétrica, Tucuruí, 2026.

 1. diagnóstico de falhas. 2. rolamentos. 3. principal
 component analysis. 4. clustering hierárquico. I. Título.

CDD 006.31

FELIPE SILVEIRA PIANO

**ANÁLISE DE ATRIBUTOS DE SINAIS DE VIBRAÇÃO PARA O
DIAGNÓSTICO DE FALHAS EM ROLAMENTOS UTILIZANDO PCA E
CLUSTERING HIERÁRQUICO**

Trabalho de Conclusão de Curso, apresentado como requisito parcial para a obtenção de grau de Bacharel em Engenharia Elétrica, pela Universidade Federal do Pará.

Data de aprovação: 24/07/2026

Banca Examinadora:

Prof. Dr. Rafael Suzuki Bayma
Orientador - FEE/CAMTUC/UFPA

Prof. Dr. Cleison Daniel Silva
Avaliador Interno - FEE/CAMTUC/UFPA

Prof. Dr. Raphael Barros Teixeira
Avaliador Interno - FEE/CAMTUC/UFPA

TUCURUÍ

2026



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA ELÉTRICA

Título	ANÁLISE DE ATRIBUTOS DE SINAIS DE VIBRAÇÃO PARA O DIAGNÓSTICO DE FALHAS EM ROLAMENTOS UTILIZANDO PCA E CLUSTERING HIERÁRQUICO
Discente	FELIPE SILVEIRA PIANO
Matrícula	201733940030

#	BANCA EXAMINADORA	CONDIÇÃO
1	Cleison Daniel Silva (NDAE/UFPA)	Examinador interno
2	Raphael Barros Teixeira	Examinador interno
3	Rafael Suzuki Bayma (CAMTUC/UFPA)	Orientador

Data da Defesa: 24/07/2026	Hora Início: 08:32	Hora Término: 09:05
----------------------------	--------------------	---------------------

Trabalho Escrito (0 a 10 pontos por critério)			
Critério	Examinador 1	Examinador 2	Examinador 3
Formatação	10,0	10,0	10
Linguagem (gramática e semântica)	9,8	10,0	10,0
Conteúdo técnico	9,8	9,6	10,0
Média	9,9	9,9	10,0

Defesa Oral (0 a 10 pontos por critério)			
Critério	Examinador 1	Examinador 2	Examinador 3
Sequência lógica de apresentação	9,8	9,6	9,8
Administração do tempo	9,8	10,0	10,0
Expressão oral	9,8	9,8	9,8
Domínio do tema	10,0	10,0	10,0
Média	9,9	9,9	9,9

Média por examinador	9,9	9,9	10,0
Média Final	9,9		
Conceito Final	EXC		

Documento assinado digitalmente
gov.br CLEISON DANIEL SILVA
Data: 24/07/2026 10:42:06-0300
Verifique em <https://validar.iti.gov.br>

Cleison Daniel Silva
Membro

Documento assinado digitalmente
gov.br RAPHAEL BARROS TEIXEIRA
Data: 24/07/2026 10:36:38-0300
Verifique em <https://validar.iti.gov.br>

Raphael Barros Teixeira
Membro

Documento assinado digitalmente
gov.br RAFAEL SUZUKI BAYMA
Data: 24/07/2026 10:14:31-0300
Verifique em <https://validar.iti.gov.br>

Rafael Suzuki Bayma
Orientador

Dedico este trabalho aos meus pais, Carlos e Eldenice, pelo amor incondicional, apoio financeiro e incentivo constante em todos os momentos da minha jornada acadêmica. A vocês, minha eterna gratidão.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me dado forças para chegar até aqui. Segundo aos meus pais, Carlos e Eldenice, por todo amor, educação, suporte financeiro e incentivo em todos os momentos, não só durante a graduação, mas na vida. A minha mãe obrigado por cada palavra de incentivo, força e oração, que mesmo diante das dificuldades sempre acreditou em mim e me motivou a estudar. A meu pai obrigado por todo suporte, por cada viagem a Tucuruí para levar minhas compras mensais, que mesmo sendo semianalfabeto, sempre acreditou na educação como caminho para transformação.

Ao corpo docente da FEE-CAMTUC-UFPA pelo empenho e dedicação em oferecer um ensino de excelência, mesmo diante das dificuldades. Em especial, gostaria de agradecer ao Prof. Dr. André Felipe por todo conhecimento e experiências repassadas durante o projeto LETRON. Ao Prof. Dr. Jefferson Costa pela inspiração pessoal e profissional. Ao Prof. Dr. Cleison Daniel, a quem tive a oportunidade de ser monitor nas disciplinas de Sistemas de Controle. E claro, ao meu orientador Prof. Dr. Rafael Bayma, por todos os conselhos, paciência e dedicação na orientação deste trabalho.

Aos meus colegas da turma de 2017, com quem tive a oportunidade de compartilhar essa trajetória. Em especial, agradeço à companhia e à amizade de Amanda Beatriz e Dywles Soares, por estarem ao meu lado nos momentos mais desafiadores de cada semestre. Pelas madrugadas de estudos e pelos momentos de descontração, sem dúvidas, vivi com vocês os dias mais felizes da minha graduação. Agradeço também à tia Segina, mãe da Amanda, que sempre me acolheu como um filho. Obrigado por todo o suporte durante os trabalhos e estudos em sua casa, e pelas palavras de motivação e incentivo.

Por fim, agradeço a todos que de alguma forma fizeram parte da minha trajetória acadêmica. Obrigado por fazerem parte de um sonho, que agora está se concretizando.

*“Se você quiser descobrir os segredos do Universo,
pense em termos de energia, frequência e vibração.”*

(Nikola Tesla)

RESUMO

Nas indústrias, é indispensável obter alta disponibilidade e confiabilidade dos equipamentos para garantir a continuidade operacional das plantas. Nesse contexto, os rolamentos são os componentes de maior ocorrência em máquinas rotativas de plantas industriais. Por isso, o monitoramento das condições desse componente cresceu significativamente nas últimas décadas, e a manutenção preditiva está utilizando técnicas cada vez mais sofisticadas para a detecção e diagnóstico de falhas em rolamentos. As abordagens modernas consistem na análise dos sinais de vibrações e sua classificação por ferramentas de Aprendizado de Máquina. As pesquisas nesse ramo se concentram em métodos de aprendizado supervisionado. Portanto, este trabalho busca contribuir com as lacunas de pesquisas em aprendizado não supervisionado para analisar essas falhas, utilizando as técnicas de *Principal Component Analysis* (PCA) e *Clustering* Hierárquico. Os sinais de vibração analisados fazem parte de um banco de dados disponibilizado publicamente, oferecido pela *Case Western Reserve University* - CWRU. Inicialmente, os sinais são janelados e são obtidos os seguintes atributos no domínio do tempo para cada janela: Nível Global RMS, Fator de Crista, Fator K, Curtose e Assimetria. Com esses atributos, foram elaborados os gráficos de *boxplot*, histograma, *pairplot* e matriz de correlação. Em seguida, os atributos são padronizados e é aplicado o PCA para diminuir as ambiguidades e reduzir a dimensionalidade dos dados. As duas primeiras componentes principais foram utilizadas como novos atributos para o *Clustering* Hierárquico. Por fim, foram elaborados o dendrograma e uma tabela rastreando as classes presentes em cada *cluster* encontrado. Os resultados demonstraram a viabilidade de se utilizar técnicas de Aprendizado de Máquina não supervisionado na análise de atributos para o diagnóstico de falhas em rolamentos.

Palavras-chave: diagnóstico de falhas; rolamentos; *principal component analysis*; *clustering* hierárquico.

ABSTRACT

In industrial settings, achieving high equipment availability and reliability is essential to ensure operational continuity. Bearings are among the most common components in the rotating machinery of industrial plants. Consequently, monitoring the condition of these components has gained significant importance in recent decades, with predictive maintenance increasingly employing sophisticated techniques for bearing fault detection and diagnosis. Modern approaches involve analyzing vibration signals and classifying them using machine learning tools. Research in this field has largely focused on supervised learning methods. Therefore, this study aims to address research gaps regarding unsupervised learning approaches for analyzing these faults by employing Principal Component Analysis (PCA) and Hierarchical Clustering. The vibration signals analyzed are drawn from a publicly available dataset provided by Case Western Reserve University (CWRU). Initially, the signals are segmented into windows, and the following time-domain features are extracted for each window: Overall RMS Level, Crest Factor, K-Factor, Kurtosis, and Skewness. Boxplots, histograms, pairplots, and correlation matrices were generated based on these features. Subsequently, the features were standardized, and PCA was applied to minimize ambiguity and reduce data dimensionality. The first two principal components served as new features for Hierarchical Clustering. Finally, a dendrogram and a table tracking the classes present in each identified cluster were produced. The results demonstrate the feasibility of using unsupervised machine learning techniques to analyze features for bearing fault diagnosis.

Keywords: fault diagnosis; bearings; principal component analysis; hierarchical clustering.

LISTA DE ILUSTRAÇÕES

Figura 1 – Tipos de Manutenção.	22
Figura 2 – Diferença entre rolamentos radiais de esferas e rolos cilíndricos.	26
Figura 3 – Estrutura típica de um rolamento radial de esferas.	27
Figura 4 – Curva de Stribeck	28
Figura 5 – Rolamentos radiais, axiais e de carga combinada.	28
Figura 6 – Vista em corte de um motor de indução com rotor de gaiola de esquilo.	29
Figura 7 – Representação das folgas internas radial e axial em rolamentos.	29
Figura 8 – Formas de carregamentos radiais em um rolamento rígido de esferas.	30
Figura 9 – Frequência de ocorrência dos modos de falha dos rolamentos.	31
Figura 10 – Lascamentos e microfissuras em rolamentos.	32
Figura 11 – Surgimento da falha por fadiga subsuperficial em um rolamento.	33
Figura 12 – Distribuição típica da vida de rolamentos.	34
Figura 13 – Obtenção de falhas induzidas com uma microrretífica.	35
Figura 14 – Exemplos de falso brinelismo em diferentes componentes de rolamentos.	36
Figura 15 – Falha em rolamento causada por passagem de corrente elétrica.	37
Figura 16 – Acelerômetros unidirecionais comerciais.	38
Figura 17 – Diagrama de corpo livre do sistema eixo-carcaça de um rolamento.	38
Figura 18 – Impacto do elemento rolante em um defeito na pista externa do rolamento.	40
Figura 19 – Simulação de defeito em um rolamento de esferas pelas Equações 8 e 12.	41
Figura 20 – Sinais típicos de defeitos e seus envelopes em um rolamento de esferas.	42
Figura 21 – Tendência de X_{pico} , X_{rms} e F_{cr} para diferentes condições do rolamento.	44
Figura 22 – Comportamento de F_k para diferentes condições do rolamento.	44
Figura 23 – Comportamento da distribuição para três condições de assimetria.	45
Figura 24 – Comportamento da distribuição para três condições de curtose.	46
Figura 25 – Direções das projeções do primeiro e segundo componentes principais.	49
Figura 26 – Projeção ortogonal de $\mathbf{x}_n$ no subespaço principal na direção de ϕ_1	49
Figura 27 – Diferença entre agrupamento aglomerativo e divisivo.	53
Figura 28 – Dendrograma obtido por meio de agrupamento hierárquico aglomerativo com <i>average linkage</i> utilizando dados de microarranjos de tumores humanos.	54
Figura 29 – Dendrogramas obtidos a partir do agrupamento hierárquico aglomerativo utilizando dados de microarranjos de tumores humanos.	56
Figura 30 – Bancada de teste da CWRU onde foram coletados os sinais de vibração.	58
Figura 31 – Ambiente do Jupyter Notebook em um navegador web.	61
Figura 32 – Exemplo de um DataFrame do Pandas.	63
Figura 33 – Sinais no domínio do tempo para cada condição do rolamento.	65

Figura 34 – Processo de janelamento dos sinais com sobreposição de janelas.	66
Figura 35 – Fluxograma do processamento dos sinais de vibração e dos atributos. . .	70
Figura 36 – <i>Boxplot</i> dos atributos calculados.	72
Figura 37 – Comparação entre duas janelas das classes PE7 e PE21.	73
Figura 38 – Histograma dos atributos calculados.	74
Figura 39 – <i>Pairplot</i> dos atributos calculados.	75
Figura 40 – Matriz de correlação dos atributos calculados.	77
Figura 41 – Gráfico de espalhamento das componentes principais.	78
Figura 42 – <i>Boxplot</i> das componentes principais.	79
Figura 43 – Dendrograma das componentes principais.	79
Figura 44 – Estrutura hierárquica dos sinais de vibração analisados.	82

LISTA DE TABELAS

Tabela 1 – Condições de operação do motor durante o experimento.	58
Tabela 2 – Condições e rótulos dos rolamentos analisados.	59
Tabela 3 – Especificações do rolamento 6205-2RS JEM SKF.	59
Tabela 4 – Frequências características de falhas para condição de motor a vazio (1797 rpm).	59

LISTA DE QUADROS

Quadro 1 – Evolução da Manutenção.	21
Quadro 2 – Principais <i>clusters</i> encontrados.	80

LISTA DE ABREVIATURAS E SIGLAS

ABMA	<i>American Bearing Manufactures Association</i>
AISI	<i>American Iron and Steel Institute</i>
ANSI	<i>American National Standards Institute</i>
BPFI	<i>Ballpass frequency, inner racer</i>
BPFO	<i>Ballpass frequency, outer racer</i>
BSF	<i>Ball spin frequency</i>
CWRU	<i>Case Western Reserve University</i>
DOFs	<i>Degrees of Freedom</i>
EDM	<i>Electrical Discharge Machining</i>
FTF	<i>Fundamental train frequency</i>
IA	Inteligência Artificial
IMS	<i>Center for Intelligent Maintenance Systems</i>
ISO	<i>International Organization for Standardization</i>
MCC	Manutenção Centrada em Confiabilidade
ML	<i>Machine Learning</i>
NASA	<i>National Aeronautics and Space Administration</i>
PCA	<i>Principal Component Analysis</i>
PCM	Planejamento e Controle da Manutenção
PHM	<i>Prognostics and Health Management</i>
RCM	<i>Reliability Centered Maintenance</i>
RMS	<i>Root Mean Square</i>
rpm	Rotações por minuto

LISTA DE SÍMBOLOS

$\%$	Porcentagem;
L_{10}	Vida nominal com confiabilidade de 90% (milhões de revoluções);
L_{10h}	Vida nominal com confiabilidade de 90% (horas de funcionamento);
P	Carga dinâmica equivalente (kN);
C	Classificação de carga dinâmica (kN);
f_r	Velocidade de rotação do eixo (Hz);
d	Diâmetro da esfera ou rolo (mm);
D	Diâmetro entre centro de esferas ou rolos (mm);
α	Ângulo de contato;
α_k	Fator de amortecimento;
ω_k	Frequência natural do sistema (Hz);
T_k	Período dos impulsos do defeito k (s);
f_k	Frequência característica do defeito k (Hz);
$U(t)$	Função degrau unitário (Heaviside);
$q(t)$	Distribuição de carga (N);
q_0	Intensidade máxima da carga (N);
ε	Fator de distribuição de carga;
ψ	Intervalo de posição angular da distribuição de carga ($^\circ$);
$*$	Produto de convolução;
$h(t)$	Resposta impulsiva do caminho de transmissão;
X_{rms}	Nível Global RMS;
X_{pico}	Pico de aceleração;
F_{cr}	Fator de Crista;
F_k	Fator K.

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Justificativa	19
1.2	Objetivos	19
1.2.1	Objetivo Geral	19
1.2.2	Objetivos Específicos	19
1.3	Estrutura da Monografia	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Manutenção em Sistemas de Engenharia	20
2.1.1	Manutenção Corretiva	23
2.1.2	Manutenção Preventiva	23
2.1.3	Manutenção Preditiva	24
2.2	Rolamentos	26
2.2.1	Falhas em Rolamentos	31
2.3	Vibrações em Rolamentos	37
2.3.1	Técnicas de Identificação de Falhas em Rolamentos por Sinal de Vibração no Domínio do Tempo	43
2.3.1.1	Nível Global RMS	43
2.3.1.2	Fator de Crista	43
2.3.1.3	Fator K	44
2.3.1.4	Assimetria	45
2.3.1.5	Curtose	46
2.4	Aprendizado de Máquina	47
2.4.1	<i>Principal Component Analysis</i> (PCA)	48
2.4.2	<i>Clustering</i> Hierárquico	53
2.4.2.1	<i>Clustering</i> Hierárquico Aglomerativo	55
3	MATERIAIS E MÉTODOS	57
3.1	Bancada de Teste	57
3.2	Ambiente de Desenvolvimento Python	60
3.2.1	Jupyter Notebook	60
3.2.2	Bibliotecas Python	62
3.2.2.1	NumPy	62
3.2.2.2	Matplotlib	62
3.2.2.3	Pandas	63
3.2.2.4	SciPy	63

3.2.2.5	Scikit-Learn	64
3.3	Processamento dos Sinais	64
3.3.1	Janelamento	65
3.3.2	Extração de Atributos	67
3.4	Processamento dos Atributos	68
3.4.1	Fluxograma	69
4	RESULTADOS E DISCUSSÕES	71
4.1	Análise dos Atributos	71
4.1.1	Boxplot	71
4.1.2	Histograma	74
4.1.3	Pairplot	75
4.1.4	Matriz de Correlação	76
4.2	Aplicação do PCA	77
4.2.1	Gráfico de Espalhamento das Componentes Principais	78
4.2.2	<i>Boxplot</i> das Componentes Principais	78
4.3	Aplicação do <i>Clustering</i> Hierárquico	79
4.3.1	Dendrograma	79
4.3.2	<i>Clusters</i> Encontrados	80
4.3.3	Estrutura Hierárquica das Classes	82
5	CONCLUSÃO E TRABALHOS FUTUROS	83
5.1	Trabalhos Futuros	84
	Referências	85
	APÊNDICES	92
	APÊNDICE A – REPOSITÓRIO NO GITHUB	93

1 INTRODUÇÃO

Rolamentos são alguns dos componentes mais comuns em máquinas rotativas, e suas falhas estão entre as causas mais frequentes de danos nessas máquinas (SMITH; RANDALL, 2015). Além disso, estima-se que 90% dos rolamentos falhem prematuramente (BAILLIE; MATHEW, 1994). Dessa forma, devido a crescente complexidade dos equipamentos industriais e aos elevados custos associados a paradas operacionais, o monitoramento das condições desse componente cresceu consideravelmente nas últimas décadas.

No contexto industrial, o monitoramento de condições é realizado principalmente pela manutenção preditiva. Esse tipo de manutenção tem como objetivo antever falhas nos equipamentos através do monitoramento sistemático de parâmetros de condição. Dentre as várias técnicas utilizadas pela manutenção preditiva, a análise de vibrações mecânicas se destaca para o monitoramento de rolamentos (VIANA, 2002).

Em indústrias modernas o monitoramento das condições é realizado de forma contínua. Para isso, sensores são conectados ao processo para a medição de variáveis críticas, como a vibração (CAMPOS et al., 2022). As abordagens atuais para detecção e diagnóstico de falhas em rolamentos consistem na análise dos sinais de vibrações e classificação desses por técnicas de Aprendizado de Máquina (PINTO; CUADROS; SOARES, 2021).

Na literatura há várias abordagens relacionadas a detecção e classificação de falhas em rolamentos utilizando Aprendizado de Máquina. Por isso, há disponível diversos bancos de dados com sinais de vibração de rolamentos, dentre eles, se destaca o da *Case Western Reserve University* - CWRU, cujos sinais estão publicamente disponíveis e são amplamente utilizados (SMITH; RANDALL, 2015). Diversos estudos obtiveram ótimas acurácias de classificação desse banco de dados, como os realizados por Souza (2019), Santos e Araújo (2023), Souza et al. (2022) e Pinto, Cuadros e Soares (2021); entretanto, poucos estudos se propõem a realizar uma análise não supervisionada dele.

Dessa forma, este trabalho se propõe a aplicar as técnicas de Aprendizado de Máquina não supervisionado *Principal Component Analysis* (PCA) e *Clustering* Hierárquico ao banco de dados da CWRU, com o intuito de analisar a estrutura hierárquica das diferentes classes de defeitos em rolamentos. Para tal propósito, foram obtidos atributos no domínio do tempo dos sinais de vibração dos rolamentos com defeito e sem defeito, sendo eles: Nível Global RMS, Fator de Crista, Fator K, Curtose e Assimetria. Para diminuir a ambiguidade entre os atributos e facilitar a visualização foi aplicado o PCA, que reduziu a dimensionalidade dos dados. As duas primeiras componentes principais foram utilizadas como novos atributos para o *Clustering* Hierárquico. Por fim, foi elaborado o dendrograma e rastreado as classes presentes em cada *cluster* encontrado.

1.1 Justificativa

O presente trabalho visa contribuir ao crescente interesse da indústria em utilizar técnicas de Aprendizado de Máquina para analisar, detectar e diagnosticar defeitos em rolamentos pelo monitoramento de sinais de vibração. A maioria das pesquisas encontradas utilizam ferramentas de aprendizado supervisionado, demonstrando resultados promissores e elevadas acurácias na classificação dos defeitos. Portanto, este trabalho pretende colaborar com as lacunas na utilização do aprendizado não supervisionado para analisar essas falhas.

1.2 Objetivos

1.2.1 Objetivo Geral

Analisar atributos de sinais de vibração para o diagnóstico de falhas em rolamentos através das técnicas de aprendizado não supervisionado PCA e *Clustering* Hierárquico.

1.2.2 Objetivos Específicos

- a) Calcular os atributos no domínio do tempo;
- b) Elaborar os gráficos de *boxplot*, histograma, *pairplot* e matriz de correlação;
- c) Obter as componentes principais através da técnica de PCA;
- d) Utilizar as componentes principais para aplicar o *Clustering* Hierárquico;
- e) Elaborar o dendrograma e identificar os principais *clusters* encontrados;
- f) Rastrear as classes das amostras presente em cada *cluster* encontrado.

1.3 Estrutura da Monografia

Este trabalho está estruturado em cinco capítulos. O Capítulo 1 é introdutório, neste são apresentados a justificativa, objetivos e estrutura do trabalho desenvolvido. O Capítulo 2 apresenta os fundamentos teóricos do trabalho, desde a manutenção em sistemas de engenharia até o fundamentos de aprendizado de máquina. O Capítulo 3 aborda os materiais e métodos utilizados para analisar os atributos, nele é apresentada a bancada de onde foi obtido os sinais e elaborado o fluxograma de todo o processamento dos dados. O Capítulo 4 apresenta os resultados e discussões do trabalho, nele é apresentado e analisado todos os gráficos obtidos durante a implementação do PCA e Clustering. Por fim, no Capítulo 5 são apresentadas as considerações finais e perspectivas de trabalhos futuros. A demais referências bibliográficas e apêndices.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos teóricos deste trabalho. Inicialmente, contextualiza-se a evolução da manutenção industrial em suas vertentes corretiva, preventiva e preditiva. Em seguida, abordam-se os rolamentos, suas aplicações práticas, falhas prematuras e o papel estratégico da manutenção para mitigá-las. Adicionalmente, o texto introduz os conceitos de vibrações mecânicas em rolamentos (com e sem defeitos), detalhando os métodos de mensuração, simulação e as técnicas de identificação de falhas no domínio do tempo. Por fim, apresentam-se os fundamentos de aprendizado de máquina, com ênfase em aprendizado não supervisionado, definindo as técnicas de *Principal Component Analysis* (PCA) e *Clustering* Hierárquico que serão aplicadas neste trabalho.

2.1 Manutenção em Sistemas de Engenharia

A manutenção é uma das áreas mais relevantes dentro de qualquer complexo industrial, sendo responsável por conservar, sustentar e garantir o bom funcionamento de máquinas, instalações, processos e até pessoas. Derivada do latim *manus tenere*, que significa manter o que se tem, a manutenção se faz presente na história humana desde o advento da Revolução Industrial no final do século XVIII, com a aparição dos primeiros teares mecânicos (VIANA, 2002).

Segundo Monchy (1989, p. 3), “o termo ‘manutenção’ tem sua origem no vocabulário militar, cujo sentido era ‘manter, nas unidades de combate, o efetivo e o material num nível constante’”. Os primeiros traços da manutenção como a conhecemos hoje vieram surgir somente após a Segunda Guerra Mundial, onde foi necessário desenvolver técnicas de organização, planejamento e controle para tomadas de decisão (VIANA, 2002).

O aparecimento do termo “manutenção” no contexto industrial ocorreu na década de 1950 nos Estados Unidos, seguido no mesmo período pela Europa, onde era mais comum a palavra “conservação” (MONCHY, 1989). Desde então, a manutenção passou por uma série de transformações e está em constante evolução, sempre surgindo novas subáreas e aprimorando técnicas já conhecidas (VIANA, 2002).

Para Kardec e Nascif (2009) a partir de 1930, a evolução da manutenção pode ser dividida em quatro gerações, conforme Quadro 1: a primeira geração abrange o período antes da Segunda Guerra Mundial, caracterizada principalmente por limpeza, lubrificação e reparo após a quebra, sendo fundamentalmente reativa; a segunda geração ocorre entre os anos 50 e 70 e é marcada pelo surgimento do conceito de manutenção preventiva, com intervenções nos equipamentos feitas em intervalos fixos, surgindo também os primeiros sinais de Planejamento e Controle da Manutenção (PCM).

Quadro 1 – Evolução da Manutenção.

	Primeira Geração	Segunda Geração	Terceira Geração	Quarta Geração
Ano	1940 – 1950	1960 – 1970	1980 – 1990	2000 – 2010
Aumento das expectativas em relação à Manutenção	• Conserto após a falha	• Disponibilidade crescente • Maior vida útil do equipamento	• Maior confiabilidade • Maior disponibilidade • Melhor relação custo-benefício • Preservação do meio ambiente	• Maior confiabilidade • Maior disponibilidade • Preservação do meio ambiente • Segurança • Influir nos resultados do negócio • Gerenciar os ativos
Visão quanto à falha do equipamento	• Todos os equipamentos se desgastam com a idade e, por isso, falham	• Todos os equipamentos se comportam de acordo com a curva da banheira	• Existência de 6 padrões de falhas (MOUBRAY, 2000; NOWLAN; HEAP, 1978)	• Reduzir drasticamente falhas prematuras dos padrões A e F. (MOUBRAY, 2000; NOWLAN; HEAP, 1978)
Mudança nas técnicas de Manutenção	• Habilidades voltadas para o reparo	• Planejamento manual da manutenção • Computadores grandes e lentos • Manutenção Preventiva (por tempo)	• Monitoramento da condição • Manutenção Preditiva • Análise de risco • Computadores pequenos e rápidos • Softwares potentes • Grupos de trabalho multidisciplinares • Projetos voltados para a confiabilidade • Contratação por mão de obra e serviços	• Aumento da Manutenção Preditiva e Monitoramento da Condição • Minimização nas Manutenções Preventiva e Corretiva não Planejada • Análise de Falhas • Técnicas de confiabilidade • Manutenibilidade • Engenharia de Manutenção • Projetos voltados para confiabilidade, manutenibilidade e Custo do Ciclo de Vida. • Contratação por resultados

Fonte: Adaptado de Kardec e Nascif (2009).

A partir da década de 1970, a terceira geração da manutenção consolidou a manutenção preditiva, o uso de *softwares* de planejamento e a Manutenção Centrada em Confiabilidade (MCC) ou *Reliability Centered Maintenance* (RCM). Essa evolução foi impulsionada sobretudo pela expansão global do Toyotismo (KARDEC; NASCIF, 2009).


A quarta geração dá-se desde os anos 2000 e consolida as expectativas existentes na terceira geração, a disponibilidade passa a ser a medida de performance mais importante da manutenção, a análise de falha se torna uma prática consagrada na indústria, é reforçado a manutenção preditiva e monitoramento das condições dos equipamentos, ao mesmo passo em que diminui a aplicação de manutenção preventiva e programada para não paralisar os processos, o mesmo ocorre com a manutenção corretiva não planejada, que se torna um indicador de ineficácia da manutenção (KARDEC; NASCIF, 2009).

Apesar de parecer paradoxal, no contexto moderno, a manutenção existe para que não haja manutenção, isso se refere a manutenção corretiva não planejada. Essa conclusão ganha sentido principalmente porque o trabalho da manutenção está sendo cada vez mais enobrecido, onde o pessoal da área precisa estar em constante qualificação para evitar falhas e não para corrigi-las (KARDEC; NASCIF, 2009).

No cenário da Indústria 4.0, a manutenção transcendeu sua função tradicional de reparar falhas para se tornar um setor estratégico baseado em dados, essencial para a eficiência operacional, segurança e competitividade das empresas (ALMEIDA; FABRO, 2019). Essas transformações podem ser justificadas com o grande aumento no número de itens físicos (instalações, equipamentos e construções) que precisam ser mantidos em todo o mundo, além do aumento da complexidade dos projetos com o crescimento da automação dos processos (MOUBRAY, 2000).

Em sistemas de engenharia modernos a manutenção se utiliza de diferentes estratégias para garantir a eficiência, segurança e longevidade de equipamentos e ativos, com destaque para as quatro principais, sendo elas: manutenção corretiva, preventiva, preditiva e detectiva, conforme a Figura 1 (KARDEC; NASCIF, 2009). Neste trabalho será abordado brevemente as três primeiras, mas com ênfase na manutenção preditiva, por meio da técnica de análise de vibração aplicada ao diagnóstico de falhas em rolamentos.

Figura 1 – Tipos de Manutenção.



Fonte: Adaptado de Kardec e Nascif (2009).

2.1.1 Manutenção Corretiva

A manutenção corretiva ocorre quando é necessário intervir em um equipamento que apresenta uma falha ou que está com desempenho abaixo do esperado, não sendo, em todos os casos, uma manutenção emergencial. Dessa forma, a manutenção corretiva tem como ação principal, corrigir ou restaurar as condições de funcionamento do equipamento ou sistema, o que nos permite dividi-la em duas classes, manutenção corretiva planejada e não planejada (KARDEC; NASCIF, 2009).

A manutenção corretiva não planejada caracteriza-se pela correção de uma falha que ocorreu de maneira aleatória, sendo uma situação indesejada que demonstra ineficácia nas outras estratégias de manutenção, esse cenário implica em altos custos com perda de produção, perda de qualidade do produto, além do próprio custo da manutenção. Apesar dos avanços na área, esse tipo de manutenção, infelizmente, ainda é mais comum do que deveria nas empresas (KARDEC; NASCIF, 2009).

A manutenção corretiva planejada é uma intervenção no equipamento que está com desempenho abaixo do esperado ou uma correção por decisão gerencial, que geralmente se baseia em anomalias nos parâmetros observados pela manutenção preditiva. Esse tipo de manutenção é preferível, uma vez que intervenções planejadas são, em geral, mais econômicas, ágeis e seguras, permitindo à equipe tempo hábil para a preparação de todos os recursos necessários, assegurando qualidade na execução (KARDEC; NASCIF, 2009).

2.1.2 Manutenção Preventiva

A manutenção preventiva é caracterizada por intervenções realizadas de acordo com um plano previamente estabelecido, respeitando intervalos definidos de tempo, cujo objetivo é reduzir ou evitar falhas e a degradação do desempenho dos equipamentos (KARDEC; NASCIF, 2009). Esse tipo de manutenção planejada oferece uma série de benefícios ao organismo fabril, pois proporciona maior estabilidade operacional, condição essencial para o correto desenvolvimento das atividades produtivas (VIANA, 2002).

A manutenção preventiva é, na maioria das empresas, a atividade principal de manutenção, pois ela envolve tarefas sistemáticas, como inspeções, reformas e troca de peças, principalmente. Essas atribuições acabam tornando-a mais cara em relação a manutenção corretiva, isso somente do ponto de vista do custo com manutenção, pois peças precisam ser trocadas e componentes têm que ser reformados antes de atingirem seus limites de vida (XENOS, 1998).

Embora apresente um custo inicial mais elevado, a manutenção preventiva reduz significativamente a frequência de falhas, aumenta a disponibilidade dos equipamentos e minimiza as interrupções inesperadas no processo produtivo. Esse maior controle sobre as paradas contribui para a redução do custo total de operação, uma vez que a produção

deixa de estar sujeita a paralisações imprevistas causadas por falhas nos equipamentos. Dessa forma, a implementação da manutenção preventiva, a longo prazo, deve resultar em custos inferiores aos da manutenção corretiva (XENOS, 1998).

Um dos aspectos mais importantes na elaboração de um plano de manutenção preventiva é a periodicidade das inspeções e substituições, porém nem sempre os fabricantes fornecem informações precisas para tal implementação. Portanto, deve-se estipular a cadência de cada item do plano, baseando-se no histórico de falhas ou em plantas similares operando sob as mesmas condições, pois a expectativa de degradação dos equipamentos são sensíveis às condições operacionais e ambientais (KARDEC; NASCIF, 2009).

Apesar da manutenção preventiva já ser bastante popular, muitas empresas ainda enfrentam dificuldades no cumprimento dos planos de manutenção, pois o tempo reservado para realizá-lo acaba sendo usado para trabalhar em falhas que surgem no cotidiano da produção. Com isso, sem uma boa manutenção preventiva, as falhas tendem a aumentar e consumir todo o tempo dos mantenedores, o que gera um círculo vicioso (XENOS, 1998).

Mesmo que a manutenção preventiva esteja sendo cumprida de maneira sistemática, pode acontecer das falhas não diminuírem, quando isso ocorre, provavelmente está ligado tanto à falta de padrões e procedimentos de manutenção, quanto ao conhecimento e habilidades insuficientes dos técnicos de manutenção e operadores da produção (XENOS, 1998). Além disso, vale destacar que a manutenção preventiva também tem seus pontos negativos, como a retirada do equipamento ou sistema de operação para executar os serviços programados, ou a possibilidade de introduzir defeitos não existentes no equipamento durante os procedimentos (KARDEC; NASCIF, 2009).

2.1.3 Manutenção Preditiva

A manutenção preditiva tem como objetivo antever falhas nos equipamentos ou sistemas através do monitoramento sistemático de parâmetros de condição ou desempenho, o que possibilita a atuação mais precisa com base em anomalias encontradas nessas variáveis (KARDEC; NASCIF, 2009). Dessa forma, ela se destaca das demais, pois possibilita prever a proximidade da ocorrência de falhas, determinar o momento adequado para a intervenção, evitar desmontagens desnecessárias para inspeção e utilizar o componente até o limite máximo de sua vida útil (VIANA, 2002).

Dentre as várias técnicas utilizadas pela manutenção preditiva, quatro são mais usadas na indústria, são elas: Ensaio por ultra-som; Análise de vibrações mecânicas; Análise de óleos lubrificantes; e Termografia (VIANA, 2002). Por meio dessas técnicas, é possível otimizar a substituição de peças ou a recuperação de componentes e ampliar os intervalos de manutenção, uma vez que permitem prever quando peças ou componentes estão próximos de falhar (XENOS, 1998).

A principal vantagem de utilizar técnicas preditivas é que elas permitem a operação contínua do equipamento pelo maior tempo possível, pois é feito o monitoramento da condição e a ação de correção, quando necessária, é realizada através de uma manutenção corretiva planejada. Dessa forma, a manutenção preditiva contribui para o aumento da disponibilidade dos equipamentos, uma vez que as medições e aferições são realizadas com os equipamentos em operação (KARDEC; NASCIF, 2009).

Para que a manutenção preditiva possa desempenhar bem, devem ser previamente estabelecidos limites, com base na literatura científica ou recomendação do fabricante, para os parâmetros de monitoramento do grau de degradação dos equipamentos, de modo que, ao se aproximarem ou atingirem esses limites, seja tomada a decisão de intervenção. O acompanhamento desses parâmetros possibilita a preparação prévia do serviço, além de outras decisões relacionadas com a produção, o que torna a manutenção preditiva uma forte aliada da manutenção corretiva planejada (KARDEC; NASCIF, 2009).

Um dos principais desafios das empresas ao implementar a manutenção preditiva está na capacitação dos profissionais responsáveis pela análise e diagnóstico, pois, embora a medição dos parâmetros seja relativamente simples, muitas vezes realizada pelos próprios operadores, a interpretação dos resultados e a formulação de diagnósticos precisos podem ser bastante complexas. Por isso, não é incomum encontrar, em algumas empresas, sistemas de coleta de informações que não produzem planos de ação com a qualidade equivalente aos dados registrados. Como estratégia para superar isso, muitas empresas optam pela terceirização das atividades de análise e diagnóstico (KARDEC; NASCIF, 2009).

O avanço tecnológico possibilitou o desenvolvimento de diversas técnicas de manutenção preditiva, como o monitoramento de vibrações mecânicas, principal objeto de estudo deste trabalho, e a análise de óleo, que permitem prever o momento adequado para a substituição ou reforma de componentes mecânicos. Entretanto, ainda existem limitações quanto à aplicação dessas tecnologias, não sendo possível adotar a manutenção preditiva para todos os tipos de componentes ou peças de um equipamento. Nesses casos, a substituição baseada no tempo de uso mostra-se mais viável (XENOS, 1998).


Devido ao uso de tecnologias mais avançadas que as demais, a manutenção preditiva costuma ser tratada de forma diferenciada dentro das empresas, em muitos casos com equipes independentes ou técnicos altamente especializados. Porém, vale ressaltar que a manutenção preditiva é um dos elementos da manutenção preventiva, e suas tarefas devem fazer parte do planejamento da Engenharia de Manutenção, de forma colaborativa com os demais setores conforme Figura 1, pois por mais sofisticada que seja, não deixa de ser mais uma maneira de inspecionar os equipamentos (XENOS, 1998).

2.2 Rolamentos

Os rolamentos são componentes mecânicos cuja função é suportar cargas e reduzir o atrito entre peças móveis, permitindo o movimento relativo entre dois elementos de uma máquina. Existe uma grande variedade de rolamentos que utilizam diferentes elementos rolantes, com construções específicas para resistir a cargas radiais, axiais ou a uma combinação de ambas. A aplicação mais frequente dos rolamentos é a sustentação de eixos em movimento rotativo, o que os torna componentes essenciais em mancais; entretanto, há também rolamentos específicos para movimento linear (MOTT; VAVREK; WANG, 2017).

Com elevada precisão e baixo atrito, os rolamentos possibilitam a transferência de cargas entre componentes de máquinas operando em altas velocidades de rotação, ao mesmo tempo em que reduzem o ruído, a geração de calor, o consumo de energia e o desgaste. Essas características os tornam elementos economicamente vantajosos e facilmente substituíveis, uma vez que suas dimensões seguem padrões estabelecidos por normas nacionais e internacionais. De modo geral, os rolamentos distinguem-se quanto ao tipo de elemento rolante, sendo classificados em rolamentos de esferas ou de rolos cilíndricos, conforme ilustrado na Figura 2 (SKF, 2020c).

Figura 2 – Diferença entre rolamentos radiais de esferas e rolos cilíndricos.




Fonte: SKF (2020c).

Nos rolamentos radiais de esferas, o contato entre as esferas e as pistas ocorre inicialmente de forma pontual, conforme ilustrado na Figura 2a, passando a assumir uma área elíptica quando submetido a cargas mais elevadas (SKF, 2020c). A pequena área de contato resulta em baixo atrito rolante, o que os tornam mais adequados para aplicações com altas velocidades de rotação; contudo, apresentam dimensões reduzidas e capacidade limitada de cargas radiais e axiais, a depender do projeto construtivo (NORTON, 2013).

Os rolamentos radiais de rolos cilíndricos apresentam um contato linear entre o rolo e a pista, conforme ilustrado na Figura 2b, o qual assume uma forma retangular à medida que os componentes se deformam sob carga. Em razão da maior área de contato e, conseqüentemente, do maior atrito, esses rolamentos possuem elevada capacidade de carga radial e operam a velocidades inferiores quando comparados aos rolamentos de esferas; apesar disso, são incapazes de suportar cargas axiais (MOTT; VAVREK; WANG, 2017).

Conforme ilustrado na Figura 3, a estrutura típica dos rolamentos envolve uma pista interna, uma pista externa, os elementos rolantes, um separador (ou gaiola) e em alguns casos a vedação ou blindagem, as quais possibilitam a sua aplicação em ambientes agressivos, com sujeira, poeira e umidade. Os elementos rolantes ficam retidos entre as pistas, enquanto que a gaiola garante que estes não entrem em contato entre si durante a operação. Sua construção é patronizada quase que universalmente pela *American Bearing Manufacturers Association* (ABMA), *American National Standards Institute* (ANSI) e *International Organization for Standardization* (ISO) (COLLINS; BUSBY; STAAB, 2019).

Figura 3 – Estrutura típica de um rolamento radial de esferas.




Fonte: SKF (2020a).

A maioria dos rolamentos de esferas modernos são fabricados com aço classificado pela *American Iron and Steel Institute* (AISI) de numeração 52100 e endurecido a um alto grau, de forma inteira ou somente na superfície. Essa é uma liga de alto carbono e cromo, reconhecida pela sua excelente resistência ao desgaste, alta dureza e tenacidade. Já os rolamentos de rolos cilíndricos são frequentemente fabricados com liga de aço endurecíveis AISI 3310, 4620 e 8620, reconhecidos por suas altas resistências nos núcleos. Os rolamentos feitos com esses aços mostram vida útil mais extensa e confiabilidade (NORTON, 2013).

Para assegurar a vida útil projetada dos rolamentos, a lubrificação é essencial, pois reduz o atrito, protege contra corrosão e atua no resfriamento, o que evita falhas prematuras por desgaste ou fadiga. A película lubrificante, formada entre os elementos rolantes e as pistas, deve evitar o contato metálico entre ambos. A lubrificação pode ser feita por óleo ou graxa: o óleo é indicado para altas cargas, elevadas rotações e altas temperaturas; já a graxa é preferível para baixas velocidades, longos períodos sem manutenção ou proteção em ambientes agressivos (ALMEIDA; LIMA; BARBIERI, 2017).

As superfícies dos elementos rolantes em contato com as pistas apresentam um movimento relativo composto por rolamento e deslizamento (BUDYNAS; NISBETT, 2016). Dependendo das condições operacionais, podem ocorrer três regimes de lubrificação: filme completo, filme misto e lubrificação de contorno. A lubrificação de filme completo é a ideal; no entanto, essa condição só é atingida se a velocidade for suficientemente alta para manter a película, conforme ilustrado na Curva de Stribeck (Figura 4) (NORTON, 2013).

Figura 4 – Curva de Stribeck




Fonte: Adaptado de Norton (2013, p. 629).

Ao selecionar um rolamento para um projeto, o engenheiro deve considerar não apenas o diâmetro do furo, mas também a natureza das cargas atuantes, os requisitos de vida útil, os fatores de segurança e a viabilidade econômica. Os rolamentos podem ser dimensionados para suportar cargas estáticas (sem rotação ou abaixo de 10 rpm) ou dinâmicas. Na prática, a maioria dos rolamentos está submetida a carregamentos dinâmicos, com velocidades e torques constantes ou variáveis (ALMEIDA; LIMA; BARBIERI, 2017).

Os rolamentos podem ser classificados em radiais ou axiais com base na direção da carga que acomodam. Os rolamentos radiais são indicados para esforços predominantemente perpendiculares ao eixo, enquanto os axiais são projetados para suportar cargas paralelas a ele. Quando o sistema apresenta esforços simultâneos em ambas as direções, utilizam-se rolamentos de carga combinada, como os de rolos cônicos ou de esferas de contato angular. Esses diferentes regimes de carregamento estão ilustrados na Figura 5 (SKF, 2020c).


Figura 5 – Rolamentos radiais, axiais e de carga combinada.



Fonte: SKF (2020c).

Os rolamentos são componentes críticos em motores elétricos. Em geral, o eixo do rotor é sustentado por um rolamento em cada extremidade (Figura 6), os quais fornecem um suporte rígido ao eixo de saída. Embora os motores possam ser fabricados com diferentes tipos de rolamentos, a maioria dos modelos modernos utiliza rolamentos blindados. Estes dispensam a lubrificação regular, mas devem ser inspecionados periodicamente via inspeção visual ou análise de vibração para determinar a necessidade de substituição. Os rolamentos de esferas são os mais comuns em motores elétricos, mas motores de grande porte podem utilizar rolamentos de rolos cilíndricos por suportarem maior carga (PETRUZELLA, 2013).


Figura 6 – Vista em corte de um motor de indução com rotor de gaiola de esquilo.



Fonte: Adaptado de Chapman (2013, p. 309).

Os rolamentos apresentam uma folga interna definida pela distância total que a pista externa pode se mover em relação à pista interna (ou vice-versa), tanto na direção radial quanto na axial (Figura 7) (SKF, 2020b). Essa folga é crucial para o desempenho, a distribuição de carga e a vida útil do componente, pois acomoda a expansão térmica e a camada de lubrificação, com impacto direto nos níveis de ruído e vibração. Em geral, os fabricantes seguem a norma ISO 5753-1 para classificar o grau de folga através dos códigos “C”, divididos em cinco grupos de C1 a C5 (do menor para o maior). Motores elétricos, por exemplo, utilizam tipicamente rolamentos com folga radial C3 (SALUNKHE et al., 2024).


Figura 7 – Representação das folgas internas radial e axial em rolamentos.



Fonte: SKF (2020b).

Quando submetidos a uma carga, os rolamentos tendem a acomodá-la de modo que as forças radiais e axiais sejam transmitidas através dos elementos rolantes entre os anéis interno e externo. Isso gera uma zona de carregamento com diferentes tipos de distribuição, conforme ilustrado na Figura 8 para uma carga radial. Além do tipo de carga, a zona de carregamento está diretamente relacionada à geometria do rolamento, ao material utilizado na confecção de seus elementos, ao tipo de montagem (com ou sem pré-carga), à espessura dos anéis, à folga interna e às características do lubrificante adotado (BEZERRA, 2004).

Figura 8 – Formas de carregamentos radiais em um rolamento rígido de esferas.



Fonte: Adaptado de Bezerra (2004, p. 11).

Durante a operação de um rolamento, mesmo em perfeito estado, é possível detectar vibrações à medida que os elementos rolantes entram e saem da zona de carregamento. Isso gera um sinal ruidoso característico e bem visível quando observado no domínio do tempo. Com o tempo, é natural que os rolamentos sofram desgastes causados por diversos motivos, conforme será discutido mais adiante neste trabalho. Esses desgastes causarão folgas e, desta forma, a zona de carregamento irá reduzir, o que aumentará a amplitude de vibração no rolamento. Isso fará com que as distribuições de carregamento representadas nos itens (a) e (b) da Figura 8 tendam para o mostrado no item (c) (BEZERRA, 2004).

Assim como em Souza (2019), neste trabalho, para as análises e aplicação das técnicas de diagnóstico de falhas, considera-se que a zona de carregamento do rolamento possui uma distribuição estática e que a pista externa é fixa. Dessa forma, ao se deslocarem pela zona de carregamento durante a operação, os elementos rolantes provocam tensões cíclicas de compressão e cisalhamento na camada abaixo da superfície de trabalho da pista.

Baillie e Mathew (1994) afirmam que 90% dos rolamentos falham prematuramente. Isso os consolida como um dos principais modos de falha em máquinas rotativas. Por essa razão, os rolamentos são tratados com maior rigor pela manutenção preventiva, com planos de lubrificação periódica, e pela manutenção preditiva, com técnicas de análise de vibrações. Alguns exemplos de aplicações dos rolamentos são: rodas automotivas, caixas de transmissão, geradores, motores elétricos, eletrodomésticos, turbinas, locomotivas, equipamentos de construção, máquinas agrícolas e industriais, etc (ANTONIOLLI, 1999).


2.2.1 Falhas em Rolamentos

A deterioração e o desgaste com o uso são inevitáveis em qualquer peça ou componente mecânico, inclusive nos rolamentos. Entretanto, por uma série de razões, um rolamento tem alta probabilidade de apresentar falha prematura (NUNES, 1989). Dentre as diversas causas de falhas em rolamentos, Bezerra (2004) destaca as seguintes:

- a) Lubrificação inadequada;
- b) Montagem incorreta;
- c) Retentores inadequados;
- d) Desalinhamento;
- e) Passagem de corrente elétrica;
- f) Vibrações externas;
- g) Defeitos de fabricação;
- h) Fadiga, etc.

Dessas, Harris e Kotzalas (2006) apontam que a principal causa de falha é a lubrificação inadequada, responsável por aproximadamente 43% dos casos, seja pela má seleção do lubrificante, aplicação incorreta, contaminação ou sua degradação. Além disso, destacam-se também a montagem imprópria (29%), vedação deficiente (18%), fadiga subsuperficial (8%) e causas diversas (2%). Esses dados estão ilustrados na Figura 9 e são baseados na devolução de rolamentos com defeitos aos fabricantes.

Figura 9 – Frequência de ocorrência dos modos de falha dos rolamentos.




Fonte: Adaptado de Harris e Kotzalas (2006, v. 1 p. 302).

Mesmo que esteja limpo, com lubrificação adequada, montado corretamente, vedado contra contaminantes e operado a temperaturas razoáveis, um rolamento está sujeito a falhar por fadiga do metal (BUDYNAS; NISBETT, 2016). A fadiga no rolamento ocorre devido à deformação elástica na região de contato dos elementos rolantes com as pistas. As tensões nessa área são denominadas tensões de contato ou tensões de Hertz, e repetem-se na frequência de rotação. As falhas por fadiga sempre têm início com uma pequena trinca, com origem superficial ou subsuperficial, que irá se desenvolver ao longo do tempo devido às deformações cíclicas ao redor das concentrações de tensões (NORTON, 2013).

A fadiga superficial causa trincas que se iniciam na própria superfície, influenciadas principalmente por rugosidade, arranhões, defeitos de usinagem ou lubrificação inadequada (Figura 10a). Em rolamentos bem lubrificados e fabricados corretamente, as trincas geralmente decorrem de fadiga subsuperficial, com origem em microfissuras abaixo da superfície, na região de máxima tensão de cisalhamento (Figura 10b). Normalmente, surgem em pontos de baixa resistência, regiões anisotrópicas ou em locais com inclusões não metálicas. Com o tempo, essas microfissuras propagam-se até emergirem na superfície como microtrincas que evoluem gradualmente (Figura 10c) (HARRIS; KOTZALAS, 2006).


Figura 10 – Lascamentos e microfissuras em rolamentos.



Fonte: Harris e Kotzalas (2006, v. 1 p. 297 e 300; v. 2 p. 200.)

As trincas causadas tanto pela fadiga superficial quanto subsuperficial irão se propagar até ocorrer o desprendimento de pequenos fragmentos de material da superfície, formando pequenas crateras (*pitting*) e/ou lascamentos (*spalling*), conforme a Figura 10 (JUVINALL; MARSHEK, 2020). Na Figura 11, é ilustrado o surgimento de uma falha por fadiga subsuperficial na pista externa de um rolamento. O lascamento por fadiga não é considerado uma falha catastrófica. Dependendo da lubrificação, o rolamento continuará a girar, porém com atrito cada vez maior. Após algum tempo, o rolamento sofrerá vibração excessiva e geração de calor por atrito até seu travamento (HARRIS; KOTZALAS, 2006).

Figura 11 – Surgimento da falha por fadiga subsuperficial em um rolamento.



Fonte: Adaptado de [Bezerra \(2004, p. 18\)](#).


Apesar de não ser considerado uma falha catastrófica imediata, em contextos de manutenção preditiva, o lascamento por fadiga é frequentemente tratado como o fim da vida útil de projeto do rolamento, já que a progressão para o travamento é inevitável e pode causar danos severos ao conjunto mecânico. Por isso, a norma [ISO 281](#), que trata do dimensionamento de rolamentos sob carga dinâmica, adota essa condição como o critério de falha para a estimativa da sua vida útil nominal ([ALMEIDA; LIMA; BARBIERI, 2017](#)).

Em qualquer amostra representativa de rolamentos, observa-se uma variação ampla na vida útil entre seus componentes. A distribuição estatística das falhas não segue uma simetria gaussiana, mas, pelo contrário, se comporta de acordo com a distribuição de Weibull, que é assimétrica. Geralmente, a vida útil é expressa em milhões de revoluções (ou horas de operação, dependendo da rotação). O cálculo baseia-se na vida L_{10} , definida como o número de revoluções que 90% de um grupo de rolamentos idênticos alcançará ou excederá antes que o primeiro sinal de fadiga apareça. Ou seja, pode-se esperar que 10% do lote falhe por fadiga antes que sua vida de projeto seja alcançada ([NORTON, 2013](#)).

Em qualquer projeto, o processo de seleção de rolamentos envolve, em grande parte, o uso deste parâmetro para obter a vida desejada sob o carregamento antecipado e as condições de sobrecarga esperadas em serviço. Em algumas aplicações críticas ou específicas, pode ser necessária uma probabilidade menor de falha, mas a maior parte dos fabricantes padronizou a vida L_{10} como meio de definição da vida característica de um rolamento sob carga. Dessa forma, uma vez que tenha sido escolhido o tipo de rolamento apropriado para a aplicação, a seleção do tamanho adequado depende das magnitudes de carga estática e dinâmica aplicadas e da vida desejada até a fadiga ([NORTON, 2013](#)).

A Figura 12 ilustra uma curva de falha em rolamentos e a porcentagem de sobrevivência como uma função de distribuição acumulada da vida relativa de fadiga. Devido ao equilíbrio entre confiabilidade e custo, a vida L_{10} é a referência padrão. A curva é linear até o ponto de 50% de falhas, onde a vida relativa é cinco vezes maior que a de referência. Ou seja, em um grupo de rolamentos idênticos, deve-se levar cinco vezes mais tempo para que 50% dos componentes falhem, em comparação ao tempo necessário para que 10% falhem. Após esse ponto, a curva torna-se acentuadamente não linear ([NORTON, 2013](#)).

Figura 12 – Distribuição típica da vida de rolamentos.



Fonte: Norton (2013, p. 658).

A fórmula para o cálculo nominal de vida L_{10} em milhões de revoluções é dada por:

$$L_{10} = \left[\frac{C}{P} \right]^b \quad (1)$$

onde o expoente b assume valores de 3 para rolamentos de esferas e $\frac{10}{3}$ para rolamentos de rolos. Nessa mesma equação, P é a carga dinâmica equivalente e C é a capacidade ou classificação de carga dinâmica para o rolamento, esse valor é fornecido pelo fabricante para cada rolamento de seu catálogo (ALMEIDA; LIMA; BARBIERI, 2017). A capacidade de carga dinâmica C é definida como a carga que dará uma vida de 1 milhão de revoluções à pista interna, normalmente muito maior que qualquer carga prática (NORTON, 2013).

Se a velocidade for constante, geralmente é preferível calcular a vida expressa em horas de funcionamento usando:

$$L_{10h} = \frac{10^6}{60 \cdot n} \cdot L_{10} \quad (2)$$

ou

$$L_{10h} = \frac{10^6}{60 \cdot n} \cdot \left[\frac{C}{P} \right]^b \quad (3)$$

onde n é a velocidade de rotação em rpm.

Apesar de a falha por fadiga ser quase inevitável, é importante notar que, para rolamentos levemente carregados, o *pitting* ou *spalling* de uma trinca pode não ocorrer. Isto é verdade desde que as tensões cíclicas de Hertz estejam, efetivamente, abaixo do limite de fadiga da liga metálica do rolamento. Nessas circunstâncias, vidas de operação muito longas podem ser alcançadas, muitas vezes superando a vida do próprio equipamento em que o rolamento está inserido. Para isso, assume-se que a montagem foi correta, e a lubrificação esteja adequada e livre de contaminantes (COLLINS; BUSBY; STAAB, 2019).

Em qualquer aplicação típica de rolamentos, o tempo para o início de uma falha por fadiga em condições ideais é de vários anos. Por essa razão, qualquer sequência prática de testes em laboratório deve ser conduzida sob condições aceleradas. Dos diferentes métodos potenciais para acelerar os testes de resistência, dois se destacam: o aumento do nível de carga aplicada e o aumento da velocidade operacional (HARRIS; KOTZALAS, 2006).

O aumento da carga aplicada é o método mais utilizado, pois pode ser extrapolado com relativa facilidade para outras condições através da relação entre carga e vida útil; no entanto, as tensões geradas devem permanecer dentro do regime elástico. Já o aumento da velocidade de rotação pode alterar uma série de parâmetros, tais como a espessura da película lubrificante, a força centrífuga dos elementos rolantes, a distribuição de carga e a geração de calor. A complexidade para controlar todas essas variáveis e garantir que as falhas ocorram por fadiga torna esse método pouco prático (HARRIS; KOTZALAS, 2006).

Dentre os experimentos já realizados para monitorar as vibrações de rolamentos até o final de sua vida útil, destaca-se o conduzido pelo *Center for Intelligent Maintenance Systems* (IMS) da *University of Cincinnati*. O estudo, que contou com um dataset disponibilizado publicamente pela *National Aeronautics and Space Administration* (NASA), tornou-se uma referência global para a validação de técnicas de prognóstico de falhas (*Prognostics and Health Management* - PHM). A relevância desse conjunto de dados reside na sua capacidade de fornecer sinais de vibração que documentam toda a evolução do defeito, desde a condição de operação normal até a falha catastrófica (LEE et al., 2007).

Há também experimentos que monitoram sinais de vibração de rolamentos com falhas induzidas artificialmente. Neste trabalho, serão analisados os atributos de sinais de vibração de um experimento dessa natureza, de notório reconhecimento, realizado pela *Case Western Reserve University* (CWRU), com falhas obtidas pelo processo de *Electrical Discharge Machining* (EDM). Outro experimento similar foi realizado por Bezerra (2004), que induziu as falhas utilizando uma microrretífica com uma ponta esférica diamantada, conforme ilustrado na Figura 13. Além desses, há experimentos conduzidos sob condições de velocidade de rotação variável no tempo, como o realizado por Huang e Baddour (2018).

Figura 13 – Obtenção de falhas induzidas com uma microrretífica.



Fonte: Bezerra (2004).

Quando um rolamento está em repouso e sob carga, os elementos rolantes tendem a forçar a passagem pelo lubrificante e fazer contato metal-metal com as pistas. Se houver vibração externa, o atrito cria pontos de desgaste tanto nos elementos rolantes quanto nas pistas com espaçamento equivalente às esferas ou rolos (Figura 14). Esse fenômeno é chamado de falso brinelismo (ou *false brinelling*) (HAND, 2011). Se a carga for alta o suficiente para elevar as tensões de contato acima da tensão de escoamento do metal, ocorrerão deformações permanentes. Isso é chamado de brinelismo verdadeiro (ou *true brinelling*). Rolamentos com esses problemas são ruidosos e falham cedo (NORTON, 2013).

Figura 14 – Exemplos de falso brinelismo em diferentes componentes de rolamentos.



Fonte: [NSK \(2017\)](#).

Devido ao *false brinelling*, durante o armazenamento de motores elétricos, seja em almoxarifados ou em estoques para venda, é recomendado que se gire o eixo algumas voltas pelo menos uma vez por mês, ou diariamente em locais com vibração externa. Isso redistribui o lubrificante e reveste a superfície de contato entre os elementos rolantes e as pistas do rolamento. Motores em operação também podem apresentar *false brinelling* se ficarem ociosos por longos períodos em um ambiente vibratório. Girar o eixo ou acionar o motor diariamente minimizará esse problema e prolongará sua vida útil. Além disso, esse fenômeno também pode ocorrer durante o transporte do motor elétrico (HAND, 2011).

Os motores elétricos também podem exibir o *true brinelling*, causado principalmente por impactos durante o manuseio, transporte, montagem ou operação. Nesses casos, o impacto é maior que a resistência do material, que se deforma plasticamente. O dano começa com uma endentação e evolui até a falha precoce do rolamento (ABECOM, 2022). Vale ressaltar que isso também pode ocorrer em qualquer outra aplicação de rolamentos.

A passagem de corrente elétrica pelo rolamento é outra falha comum em motores elétricos. É caracterizada por sulcos uniformes nas pistas e nos elementos rolantes, conforme ilustrado na Figura 15. O problema é causado por uma diferença de potencial entre o eixo e o estator; a corrente em si não causa danos, mas sim o arco elétrico que se forma na folga do rolamento. Os inversores de frequência estão associados a um aumento nesse problema, e a principal solução é revestir a pista externa com um isolante rígido (HAND, 2011).

Figura 15 – Falha em rolamento causada por passagem de corrente elétrica.



Fonte: [Hand](#) (2011, p. 360).

Pelas falhas que foram apresentadas até aqui, fica evidente que os rolamentos são responsáveis por uma alta porcentagem das avarias em motores elétricos. Por isso, uma boa prática é sempre substituí-los se o motor for desmontado por qualquer motivo depois que já estiver em serviço há um ano ou mais. O custo de novos rolamentos é mínimo quando comparado ao custo do tempo de inatividade ou ao custo de substituição ou rebobinagem do motor. Para trocar os rolamentos, todos os componentes do motor, ferramentas e superfícies de trabalho devem estar limpos antes de desembalar os rolamentos novos, pois qualquer grão de areia ou limalha de ferro pode danificá-lo precocemente ([HAND, 2011](#)).

2.3 Vibrações em Rolamentos

Vibrações mecânicas são movimentos oscilatórios de um corpo em torno de sua posição de equilíbrio. Elas estão presentes em todos os lugares e têm grande influência em projetos de engenharia ([INMAN, 2018](#)). Em geral, um sistema vibratório inclui um meio para armazenar energia potencial (mola ou elasticidade), um meio para armazenar energia cinética (massa ou inércia) e um meio de perda gradual de energia (amortecedor). A energia se alterna entre sua forma potencial e cinética, e certa quantidade é dissipada em cada ciclo. A vibração pode ter diferentes graus de liberdade e suas componentes fundamentais incluem a frequência natural, amplitude, fase e amortecimento ([RAO, 2008](#)).

A forma mais comum de mensurar vibrações mecânicas é através de transdutores que produzem um sinal elétrico proporcional à aceleração, chamados de acelerômetros (conforme a Figura 16). De longe, os mais utilizados em monitoramento de condição de máquinas são os acelerômetros piezoelétricos, que estão inseridos em um sistema de medição ([RANDALL, 2021](#)). Segundo [Aguirre \(2013\)](#), “um sistema de medição é um conjunto de dispositivos (sensores, circuitos, cabos, visores, equações, programas de computador, etc.) cujo objetivo é fornecer informações sobre o valor da grandeza física que se deseja medir”.


Figura 16 – Acelerômetros unidirecionais comerciais.



Fonte: Aguirre (2013, p. 226).

Nos últimos anos, houve um número crescente de estudos que buscam modelar as vibrações em rolamentos, como ilustrado na Figura 17 (REHAB et al., 2018; SAWALHI; RANDALL, 2008). O modelo apresenta quatro graus de liberdade (*Degrees of Freedom - DOFs*), os quais descrevem os movimentos do eixo e da carcaça nas direções horizontal e vertical. Além disso, inclui um DOF adicional para representar a saída do sensor de vibração na direção vertical; seus parâmetros podem ser ajustados para diferentes valores, de modo a evidenciar a amplificação das ressonâncias estruturais. O modelo dinâmico é descrito por equações diferenciais não lineares de segunda ordem (WANG et al., 2020).

Figura 17 – Diagrama de corpo livre do sistema eixo-carcaça de um rolamento.



Fonte: Rehab et al. (2018, p. 20).

As vibrações provocadas por um rolamento novo, em condições ideais de instalação e lubrificação, apresentam níveis baixos e são visualizadas como um ruído aleatório. Com o surgimento de falhas, as vibrações começam a se amplificar e a apresentar frequências características. Tais frequências podem indicar em qual componente do rolamento está o defeito, sendo calculadas a partir de sua geometria interna (NUNES, 1989). Segundo Randall (2021), as equações para calcular essas frequências características são dadas por:

$$\text{Ballpass frequency, outer race : BPFO} = \frac{Nf_r}{2} \left\{ 1 - \frac{d}{D} \cos(\alpha) \right\} \quad (4)$$

$$\text{Ballpass frequency, inner race : BPFI} = \frac{Nf_r}{2} \left\{ 1 + \frac{d}{D} \cos(\alpha) \right\} \quad (5)$$

$$\text{Fundamental train frequency (cage speed) : FTF} = \frac{f_r}{2} \left\{ 1 - \frac{d}{D} \cos(\alpha) \right\} \quad (6)$$

$$\text{Ball (roller) spin frequency : BSF} = \frac{f_r D}{2d} \left\{ 1 - \left(\frac{d}{D} \cos(\alpha) \right)^2 \right\} \quad (7)$$

onde,

f_r = velocidade de rotação do eixo (Hz);

N = número de esferas ou rolos;

d = diâmetro da esfera ou rolo (mm);


D = diâmetro entre centro de esferas ou rolos (mm);

α = ângulo de contato (Figura 5d);

O contato de um defeito com outra superfície gera um impacto semelhante a uma pequena martelada no rolamento. Com a rotação, é produzida uma série de impactos periódicos que ressoam em todo o rolamento e se dissipam na estrutura onde está assentado. Cada impacto excita as frequências naturais (ressonâncias) da estrutura, que atua como um amplificador mecânico. Em geral, esses impactos são de curtíssima duração e contêm uma taxa muito alta de energia no espectro de frequência; entretanto, essa energia se concentra mais nas altas frequências (NUNES, 1989). A Figura 18 ilustra esse evento durante a passagem do elemento rolante em um defeito na pista externa do rolamento.

Os impactos produzidos por um defeito podem ocorrer em dois cenários: quando o defeito está localizado em um ponto fixo em relação à zona de carregamento ou quando se localiza em um ponto que se movimenta em relação a essa zona (BEZERRA, 2004). No primeiro caso, a falha está sempre sujeita à carga, resultando em impactos com a mesma amplitude. No segundo caso, como a falha se move, ela nem sempre estará na região de carga, o que causa uma modulação na amplitude do impacto devido à rotação do eixo. Isso dificulta a análise do espectro de vibração do rolamento, exigindo técnicas mais apuradas, como a extração do envelope, para um diagnóstico mais preciso do defeito (NUNES, 1989).

Figura 18 – Impacto do elemento rolante em um defeito na pista externa do rolamento.



Fonte: Adaptado de Souza et al. (2022, p. 3848).

Segundo Braun e Datner (1979), um modelo matemático simplificado pode ser utilizado para simular a vibração de um rolamento com defeito. Este modelo considera que um impulso é gerado a cada impacto; entretanto, assume-se que apenas uma frequência natural ω_k seja significativa, o que caracteriza um sistema com apenas um grau de liberdade. Assume-se também uma velocidade de rotação constante, logo, os impulsos são gerados em intervalos regulares T_k . Além disso, a duração transitória de cada modo vibratório depende de um fator de amortecimento apropriado. Dessa forma, a resposta do sistema ao impulso devido ao impacto do defeito k , ilustrada na Figura 19, pode ser modelada como:

$$x_k(t) = \sum_{i=1}^{\infty} g_k(t - iT_k)U(t - iT_k) \quad (8)$$

onde:

$$g_k(t) = A_k e^{-\alpha_k t} \sin(\omega_k t) \quad (9)$$

$$U(t) = \begin{cases} 0, & \text{para } t < 0 \\ 1, & \text{para } t \geq 0 \end{cases} \quad (10)$$

$$T_k = \frac{1}{f_k} \quad (11)$$


Apesar de simples, as expressões acima descrevem bem a assinatura vibratória de um rolamento com defeito fixo em relação à distribuição de carga, onde α_k é o amortecimento da estrutura para o modo de frequência ω_k , e f_k é a frequência característica do defeito.

No caso em que o defeito se movimenta em relação à zona de carga, a resposta vibratória $x_k(t)$ será modulada em amplitude de forma proporcional à distribuição de carga $q(t)$. Segundo [Bezerra \(2004\)](#), a distribuição de carga é expressa da seguinte forma:

$$q(t) = \begin{cases} q_0 \left[1 - \frac{1}{2\varepsilon} (1 - \cos \psi) \right]^m, & \text{para } \psi_{min} \leq \psi \leq \psi_{max} \\ 0, & \text{para região fora da faixa} \end{cases} \quad (12)$$

onde q_0 é a intensidade máxima da carga, ε é o fator de distribuição de carga, ψ é o intervalo de posição angular onde a carga está distribuída, e o expoente m será $3/2$ para rolamentos de esferas ou $10/9$ para rolamentos de rolos ([MCFADDEN; SMITH, 1984](#)). A modulação pode ser obtida multiplicando $x_k(t)$ por $q(t)$, conforme ilustrado na Figura 19.

Figura 19 – Simulação de defeito em um rolamento de esferas pelas Equações 8 e 12.



Fonte: O autor (2026).

A resposta impulsiva da estrutura onde o rolamento está assentado modifica o sinal característico de cada defeito. Assim, para z defeitos, o sinal medido $y(t)$ é definido por:


$$y(t) = \left\{ \sum_{k=1}^z \sum_{i=1}^{\infty} A_k e^{-\alpha_k(t-iT_k)} \sin [\omega_k(t-iT_k)] U(t-iT_k) \right\} * h(t) \quad (13)$$

onde $h(t)$ é a resposta impulsiva do caminho de transmissão entre o ponto dos impactos e o ponto de medição. O símbolo $*$ é o produto de convolução ([BRAUN; DATNER, 1979](#)).

Na prática, o sinal medido em um rolamento com defeitos é a soma do sinal descrito pela Equação 13 com um ruído aleatório de banda larga, gerado pelo contato das superfícies em boas condições. Dessa forma, a série temporal obtida durante a medição é bastante complexa, o que torna difícil um diagnóstico exato acerca da condição do rolamento. Em geral, até é possível indicar que o rolamento possui algum defeito, mas é bastante complicado estimar sua extensão, localização e acompanhar sua evolução de forma precisa. Para contornar isso e obter uma diagnose mais apurada, é preferível que a análise seja feita no domínio da frequência através da transformada de Fourier (ANTONIOOLI, 1999).

Segundo Gernes e Nunes (1996 apud ANTONIOOLI, 1999, p. 52), a técnica do envelope é uma das mais poderosas para detectar falhas em rolamentos. Ela consiste na demodulação das frequências de defeitos moduladas nas altas frequências de ressonância. Em geral, o sinal bruto é filtrado com um filtro passa-banda centrado na frequência de ressonância, em seguida o envelope é obtido pela transformada de Hilbert e, por último, é realizada a transformada de Fourier para analisar o espectro. A escolha da banda do filtro pode ser feita através da curtose espectral ou curtograma (RANDALL; ANTONI, 2011). Randall (2021) ilustra a diferença entre os sinais de defeitos e seus envelopes na Figura 20.

Figura 20 – Sinais típicos de defeitos e seus envelopes em um rolamento de esferas.



Fonte: Randall (2021, p. 48).

2.3.1 Técnicas de Identificação de Falhas em Rolamentos por Sinal de Vibração no Domínio do Tempo

As técnicas no domínio da frequência ou tempo-frequência são as mais robustas para o diagnóstico de defeitos em rolamentos; contudo, este trabalho focará em atributos do domínio do tempo. Tais métodos são mais simples e englobam diversos procedimentos que identificam o surgimento e a progressão da avaria, embora não permitam diferenciar sua localização exata (KOKIL et al., 2014). Os atributos utilizados serão: Nível Global RMS, Fator de Crista, Fator K, Assimetria e Curtose. Quando analisados em conjunto através de técnicas de aprendizado de máquina, esses atributos se mostram eficientes para distinguir a localização e a severidade dos defeitos, como demonstrado por Souza (2019).

2.3.1.1 Nível Global RMS


O *Root Mean Square* (RMS), mais conhecido como Nível Global RMS, é um dos indicadores mais comuns no monitoramento de vibração. Seu valor pode indicar a existência de um problema e é sensível a diferentes tipos de defeitos, como lubrificação inadequada e afrouxamento (LAISSAOUI et al., 2018). O nível RMS fornece uma estimativa do conteúdo de energia do sinal vibratório e seu valor aumenta com o desenvolvimento do defeito (SIKORA, 2016). Em geral, ele é calculado e depois comparado com valores de tabela para determinar a condição de um rolamento (KOKIL et al., 2014). Segundo Bezerra (2004), para um sinal discreto $x(n)$ com N amostras, o valor RMS é dado por:

$$X_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x(n)^2}. \quad (14)$$

2.3.1.2 Fator de Crista

O fator de crista é definido como a razão entre o pico de aceleração e o valor RMS, conforme a Equação 15. Este método parte do princípio de que quando o rolamento sofre um dano, o nível de X_{pico} aumenta mais rapidamente do que o de X_{rms} ; como consequência, o valor de F_{cr} sofre uma elevação quando o defeito ainda é incipiente (SOUZA, 2019). Em estágios avançados de desgaste do material, o dano ao rolamento se propaga, o X_{rms} aumenta e F_{cr} diminui, não sendo um bom indicador de falhas em fase madura. O valor de F_{cr} para um rolamento em bom estado é de cerca de cinco (KOKIL et al., 2014). Segundo Laissaoui et al. (2018), X_{pico} é definido como o valor máximo de $|x(n)|$. A Figura 21 apresenta o comportamento de X_{pico} , X_{rms} e F_{cr} para diferentes condições do rolamento.

$$F_{cr} = \frac{X_{pico}}{X_{rms}} \quad (15)$$


Figura 21 – Tendência de X_{pico} , X_{rms} e F_{cr} para diferentes condições do rolamento.

Fonte: Adaptado de Bezerra (2004, p. 29).

2.3.1.3 Fator K

O fator K é definido como o produto entre X_{pico} e X_{rms} , conforme a Equação 16. Seu objetivo é contornar a limitação do fator de crista para defeitos em estágio avançado, pois seu valor é diretamente proporcional à progressão do dano (BEZERRA, 2004). A Figura 22 apresenta o comportamento de F_k para diferentes fases do defeito no rolamento.

$$F_k = X_{pico} \cdot X_{rms} \quad (16)$$

Figura 22 – Comportamento de F_k para diferentes condições do rolamento.

Fonte: Adaptado de Bezerra (2004, p. 30).

2.3.1.4 Assimetria

O índice de assimetria, ou *skewness*, mede o grau de distorção do sinal de vibração. Ele indica o nível de desvio da função densidade de probabilidade em relação à distribuição normal, refletindo a assimetria da amplitude do sinal em comparação com sua média (GAO; WU; FU, 2018). Formalmente, a assimetria é o terceiro momento estatístico central normalizado pelo cubo do desvio padrão, conforme descreve a Equação 17 (SOUZA, 2019).


Em rolamentos sem defeito, o sinal de aceleração tem uma distribuição gaussiana, ou seja, o valor de assimetria tende a zero (BEZERRA, 2004). Se houver atrito ou impactos em uma determinada direção do rolamento, a forma de onda do sinal de vibração será assimétrica, aumentando o índice de assimetria (ZHOU et al., 2021). O valor da assimetria é negativo quando a distribuição é assimétrica à esquerda, e positivo quando a distribuição é assimétrica à direita, conforme ilustrado na Figura 23 (HONARVAR; MARTIN, 1997).

Sendo assim, a equação para o cálculo da assimetria é expressa da seguinte forma:

$$S = \frac{\frac{1}{N} \sum_{n=1}^N [x(n) - \bar{x}]^3}{\sigma^3}, \quad (17)$$

onde $x(n)$ é o sinal discreto de vibração analisado, N refere-se ao número total de amostras da janela de observação, σ é o desvio padrão e $\bar{x}$ é o valor médio do sinal (SOUZA, 2019).

Figura 23 – Comportamento da distribuição para três condições de assimetria.



Fonte: Adaptado de Honarvar e Martin (1997, p. 426).

Vale ressaltar que alguns autores, como Honarvar e Martin (1997) e Niu, Zhu e Ding (2005), afirmam que, devido à simetria das distribuições, os momentos ímpares tendem a zero para as assinaturas de vibração tanto de rolamentos saudáveis quanto danificados. Para contornar isso, Honarvar e Martin (1997) propõem que a assimetria seja calculada para o sinal retificado, pois a simetria da distribuição é eliminada. Com isso, os momentos ímpares se mostraram tão eficazes quanto os momentos pares no monitoramento da condição do rolamento. No entanto, esse método não será explorado neste trabalho.


2.3.1.5 Curtose

A curtose (ou *kurtosis*) é o quarto momento estatístico central, normalizado pela quarta potência do desvio padrão, conforme a Equação 18. Seu valor indica o grau de achatamento da função densidade de probabilidade em relação à distribuição gaussiana (FINOTTI; CURY; BARBOSA, 2019). O valor da curtose de uma distribuição normal é igual a três. Se essa razão for maior do que três, a distribuição em questão é mais alta (afunilada) e concentrada do que a distribuição normal; se for menor do que três, a função de distribuição é mais achatada em relação à normal, conforme ilustrado na Figura 24 (HONARVAR; MARTIN, 1997). Sendo assim, a curtose é expressa da seguinte forma:

$$K = \frac{\frac{1}{N} \sum_{n=1}^N [x(n) - \bar{x}]^4}{\sigma^4}, \quad (18)$$

onde os parâmetros são os mesmo da Equação 17.

Figura 24 – Comportamento da distribuição para três condições de curtose.



Fonte: Adaptado de Honarvar e Martin (1997, p. 427).

Dyer e Stewart (1978) foram os primeiros a sugerir o uso do quarto momento estatístico central normalizado, a curtose, para a detecção de defeitos em rolamentos. Eles identificaram que a curtose permanece constante para um rolamento em bom estado, independentemente da carga e da velocidade, mas varia com a ocorrência de danos, sendo particularmente sensível ao sinal de impulso dos impactos. Portanto, a curtose é bastante adequada para detectar falhas incipientes por *pitting* na superfície (GAO; WU; FU, 2018).

Para um rolamento íntegro, em que o sinal de aceleração segue uma distribuição gaussiana, a curtose aproxima-se de três. Um valor superior a este é considerado, por si só, um indicativo de falha iminente, prescindindo de histórico prévio. No entanto, à medida que o defeito se propaga pela superfície, a curtose decresce, retornando aos níveis de um componente em boas condições (TANDON; CHOUDHURY, 1999). Esse comportamento é bastante similar ao do fator de crista, ilustrado na Figura 21 (LAISSAOUI et al., 2018).

2.4 Aprendizado de Máquina

O Aprendizado de Máquina (*Machine Learning* - ML), subcampo da Inteligência Artificial (IA), estuda e desenvolve algoritmos que permitem aos computadores aprenderem com dados e reconhecerem padrões para fins preditivos ou decisórios (SOUZA, 2019). Essa é uma área multidisciplinar, cuja base teórica integra resultados de IA, probabilidade e estatística, teoria da complexidade computacional, teoria de controle, teoria da informação, filosofia, psicologia, neurobiologia e outras áreas (MITCHELL, 1997).

Uma perspectiva útil sobre ML é que ele envolve a busca em um vasto espaço de hipóteses possíveis para determinar aquela que melhor se ajusta aos dados observados. Para isso, existem diversos algoritmos que pesquisam em um espaço de hipóteses definido por alguma representação subjacente, por exemplo: funções lineares, descrições lógicas, árvores de decisão, redes neurais artificiais, entre outras. Essas diferentes representações de hipóteses são apropriadas para o aprendizado de diferentes tipos de funções-alvo, em que o algoritmo de aprendizado correspondente aproveita uma estrutura subjacente diferente para organizar a busca no espaço de hipóteses (MITCHELL, 1997).

Boa parte do processo de aprendizagem envolve a aquisição de conceitos gerais a partir de exemplos de treinamento específicos. O ser humano, por exemplo, aprende continuamente conceitos ou categorias gerais, como “pássaro”, “carro”, “bola”, etc. Cada conceito pode ser visto como a descrição de um subconjunto de objetos ou eventos definidos sobre um conjunto maior. Portanto, é possível considerar cada conceito como uma função booleana definida sobre esse conjunto maior. Por exemplo, o subconjunto de pássaros pertence ao conjunto dos animais; logo, uma função pode ser definida sobre todos os animais, cujo valor é verdadeiro para pássaros e falso para os demais (MITCHELL, 1997).

Em geral, os dados utilizados para o aprendizado estão organizados em diferentes exemplos, cada um representado por um conjunto de atributos ou características. Por maior que seja a quantidade de exemplos, dificilmente será esgotado todo o universo de possibilidades. Por isso, o ML é baseado no aprendizado indutivo, no qual os algoritmos podem, no melhor dos casos, garantir que a hipótese de saída se ajuste ao conceito alvo nos dados de treinamento. Dessa forma, a melhor hipótese para instâncias não observadas é aquela que melhor se ajusta aos dados previamente observados (MITCHELL, 1997).

O ML geralmente é dividido em três paradigmas principais: aprendizado supervisionado, não supervisionado e por reforço (MURPHY, 2022). Cada paradigma pode ser mais adequado para uma situação ou problema diferente. De modo geral, o aprendizado supervisionado envolve a construção de um modelo matemático para prever, ou estimar, uma saída com base em uma ou mais entradas. Ou seja, para cada exemplo dos dados, existe uma medida de resposta associada; portanto, deseja-se ajustar um modelo que relacione cada resposta ao conjunto de atributos correspondente (JAMES et al., 2023).

No aprendizado não supervisionado existem entradas, mas nenhuma resposta ou saída supervisora; mesmo assim, um modelo pode ser treinado para aprender relações e estruturas a partir desses dados. Esse paradigma costuma ser mais desafiador, pois não existe uma variável alvo que possa orientar a análise. O problema tende a ser mais subjetivo e não há um propósito simples e direto, como a previsão de uma resposta. Por isso, o aprendizado não supervisionado é frequentemente realizado como parte de uma análise exploratória de dados. Além disso, pode ser difícil avaliar os resultados obtidos, visto que não existe um mecanismo para realizar validação cruzada (JAMES et al., 2023).

No aprendizado por reforço, um sistema ou agente precisa aprender a interagir com seu ambiente. Isso pode ser codificado por meio de uma política que especifica qual ação tomar em resposta a cada possível entrada derivada do estado do ambiente. A diferença em relação ao aprendizado supervisionado é que o sistema não recebe instruções sobre qual é a melhor ação a ser tomada, ou seja, qual saída produzir para uma determinada entrada. Em vez disso, o sistema recebe apenas um sinal ocasional de recompensa ou punição em resposta às ações que realiza. Isso é como aprender com um crítico, que ocasionalmente dá um sinal de aprovação ou reprovação sobre uma ação aleatória tomada (MURPHY, 2022).


Este trabalho irá se concentrar em dois tipos específicos de aprendizado não supervisionado: *Principal Component Analysis*, uma ferramenta usada para visualização ou pré-processamento dos dados antes da aplicação de outras técnicas; e Agrupamento ou *Clustering* Hierárquico Aglomerativo, um método que organiza os dados em uma estrutura de árvore (dendrograma), unindo grupos conforme suas similaridades (MURPHY, 2022).

2.4.1 *Principal Component Analysis* (PCA)

A Análise de Componentes Principais, ou *Principal Component Analysis* (PCA), é uma técnica não supervisionada amplamente utilizada em diversas aplicações, como redução de dimensionalidade, compressão de dados com perda, extração de atributos e visualização de dados (BISHOP, 2006). Ela possibilita resumir um grande conjunto de variáveis correlacionadas em um número reduzido e representativo que, coletivamente, explica a maior parte da variabilidade do conjunto original (JAMES et al., 2023). Ou seja, a PCA combina a essência dos atributos e cria um conjunto alternativo menor de variáveis, capaz de revelar relações que não eram suspeitas anteriormente (HAN; PEI; TONG, 2023).


A ideia básica é encontrar uma projeção linear e ortogonal dos dados de alta dimensionalidade $\mathbf{x} \in \mathbb{R}^D$ para um subespaço de baixa dimensionalidade $\mathbf{z} \in \mathbb{R}^L$, onde $L < D$, de modo que a representação de baixa dimensionalidade carregue o máximo de informação dos dados originais (MURPHY, 2022). Portanto, os componentes principais são uma sequência de projeções dos dados, mutuamente não correlacionadas, que estão ordenadas de forma decrescente pelas direções de máxima variância, conforme ilustrado na Figura 25 para um conjunto de dados 2D (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Figura 25 – Direções das projeções do primeiro e segundo componentes principais.



Fonte: Adaptado de [James et al. \(2023, p. 254\)](#).

Em geral, existem duas perspectivas para definir a PCA que dão origem ao mesmo algoritmo. A primeira define a PCA como a projeção ortogonal dos dados em um espaço linear de dimensão inferior, conhecido como subespaço principal, de forma que a variância dos dados projetados seja maximizada. Equivalentemente, a segunda a define como a projeção linear que minimiza o custo médio de projeção, definido como a distância quadrática média entre os dados e suas projeções ([BISHOP, 2006](#)). O processo de projeção ortogonal é ilustrado na Figura 26. Neste trabalho, será demonstrada a primeira definição.

Figura 26 – Projeção ortogonal de $\mathbf{x}_n$ no subespaço principal na direção de ϕ_1 .

Fonte: Adaptado de [Bishop \(2006, p. 561\)](#).

Dado um conjunto de observações $\{\mathbf{x}_n\}$ onde $n = 1, 2, 3, \dots, N$, sendo $\mathbf{x}_n$ um vetor com D dimensões, em que cada dimensão é um atributo mensurado, ou seja, $\mathbf{x}_n = (x_{1n} \ x_{2n} \ \dots \ x_{Dn})^T$. O objetivo da PCA é projetar $\mathbf{x}_n$ em um espaço de dimensão $L < D$, maximizando a variância dos dados projetados. De início, será considerado a projeção para um espaço unidimensional ($L = 1$). A direção desse espaço pode ser definida por uma vetor ϕ_1 de dimensão D , ou seja, $\phi_1 = (\phi_{11} \ \phi_{21} \ \dots \ \phi_{D1})^T$ ([BISHOP, 2006](#)).

Seguindo essa lógica, a primeira componente principal de $\mathbf{x}_n$ é uma combinação linear normalizada dos atributos, definida pelo seguinte produto escalar

$$z_1 = \boldsymbol{\phi}_1^T \mathbf{x}_n = \phi_{11}x_{1n} + \phi_{21}x_{2n} + \cdots + \phi_{D1}x_{Dn}, \quad (19)$$

onde, por conveniência, $\boldsymbol{\phi}_1$ é um vetor unitário, de modo que $\|\boldsymbol{\phi}_1\|^2 = 1$ ou $\boldsymbol{\phi}_1^T \boldsymbol{\phi}_1 = 1$, visto que o interesse é somente na direção definida por $\boldsymbol{\phi}_1$, e não em sua magnitude. Cada vetor $\mathbf{x}_n$ é então projetado em um valor escalar $\boldsymbol{\phi}_1^T \mathbf{x}_n$, conforme ilustrado na Figura 26. Dessa forma, o problema em questão pode ser resumido em encontrar a direção de $\boldsymbol{\phi}_1$ que, ao projetar os dados, maximize a variância retida na nova representação (BISHOP, 2006).

A média dos dados projetados é $\boldsymbol{\phi}_1^T \bar{\mathbf{x}}$, onde $\bar{\mathbf{x}}$ é a média das observações dada por

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n, \quad (20)$$

logo, a variância dos dados projetados pode ser formulada como

$$\text{Var}(\boldsymbol{\phi}_1^T \mathbf{x}_n) = \frac{1}{N} \sum_{n=1}^N [\boldsymbol{\phi}_1^T \mathbf{x}_n - \boldsymbol{\phi}_1^T \bar{\mathbf{x}}]^2 = \boldsymbol{\phi}_1^T \boldsymbol{\Sigma} \boldsymbol{\phi}_1, \quad (21)$$

onde $\boldsymbol{\Sigma}$ é a matriz de covariância dos dados no espaço original definida por

$$\boldsymbol{\Sigma} = \frac{1}{N} \sum_{n=1}^N (\mathbf{x}_n - \bar{\mathbf{x}})(\mathbf{x}_n - \bar{\mathbf{x}})^T. \quad (22)$$

A partir disso, é possível modelar um problema de otimização para maximizar a variância projetada $\boldsymbol{\phi}_1^T \boldsymbol{\Sigma} \boldsymbol{\phi}_1$ em relação a $\boldsymbol{\phi}_1$. Para evitar que $\|\boldsymbol{\phi}_1\| \rightarrow \infty$, esta deve ser uma maximização restrita. A restrição apropriada vem da condição de normalização $\boldsymbol{\phi}_1^T \boldsymbol{\phi}_1 = 1$ (BISHOP, 2006). Em resumo, o problema consiste em resolver:

$$\underset{\boldsymbol{\phi}_1}{\text{argmax}} \left\{ \boldsymbol{\phi}_1^T \boldsymbol{\Sigma} \boldsymbol{\phi}_1 \right\}, \quad \text{sujeito a: } \boldsymbol{\phi}_1^T \boldsymbol{\phi}_1 = 1, \boldsymbol{\phi}_1 \in \mathbb{R}^D \quad (23)$$

Trata-se, portanto, de um problema de otimização com restrições de igualdade. É sabido que a ferramenta matemática mais adequada para esse tipo de problema são os multiplicadores de Lagrange, utilizados para criar a função Lagrangiana, que incorpora as restrições diretamente na função objetivo (MURPHY, 2022). Esse método permite encontrar extremos (máximos e mínimos) de uma função $f(x, y)$ sujeita as restrições $g(x, y) = c$, combinando ambas através de uma nova variável λ , chamada de multiplicador de Lagrange, utilizada para definir a função Lagrangiana, dada por

$$L(x, y, \lambda) = f(x, y) - \lambda(g(x, y) - c), \quad (24)$$

de modo que, para múltiplas restrições no problema, a generalização é definida como

$$L(x, y, \lambda_1, \lambda_2, \dots, \lambda_m) = f(x, y) - \sum_{i=1}^m \lambda_i(g_i(x, y) - c_i). \quad (25)$$

Ao aplicar o multiplicador de Lagrange λ_1 na função objetivo da Equação 23, é encontrada a seguinte função Lagrangiana

$$L(\phi_1, \lambda_1) = \phi_1^T \Sigma \phi_1 + \lambda_1(1 - \phi_1^T \phi_1), \quad (26)$$

para encontrar o valor máximo é necessário derivar $L(\phi_1, \lambda_1)$ em relação a ϕ_1 e igualar a zero, ou seja,

$$\frac{\partial L(\phi_1, \lambda_1)}{\partial \phi_1} = 2\Sigma\phi_1 - 2\lambda_1\phi_1 = 0, \quad (27)$$

logo, um ponto estacionário é encontrado em

$$\Sigma\phi_1 = \lambda_1\phi_1, \quad (28)$$

o que significa que ϕ_1 deve ser um autovetor de Σ , ou seja, a direção ótima na qual deve-se projetar os dados é um autovetor da matriz de covariância (MURPHY, 2022). Se multiplicar à esquerda por ϕ_1^T e substituir $\phi_1^T \phi_1 = 1$, ao comparar com a Equação 21, descobre-se que λ_1 é a variância, dada por

$$\phi_1^T \Sigma \phi_1 = \lambda_1, \quad (29)$$

e, portanto, para maximizar a variância, deve-se escolher o autovetor ϕ_1 correspondente ao maior autovalor λ_1 , obtendo-se, assim, a primeira componente principal (BISHOP, 2006).

É possível definir componentes principais adicionais de forma incremental. Cada nova direção, além de maximizar a variância projetada, também deve ser ortogonal às já consideradas. No caso geral de um espaço de projeção de dimensão L , a projeção linear ótima para a qual a variância dos dados projetados é maximizada é agora definida pelos L autovetores $\phi_1, \dots, \phi_L$ da matriz de covariância dos dados Σ correspondentes aos L maiores autovalores $\lambda_1, \dots, \lambda_L$. Isso pode ser demonstrado por indução (BISHOP, 2006).

Segunda Murphy (2022), para o caso geral, a Equação 28 pode ser generalizada para todos os autovetores e autovalores simultaneamente como

$$\Sigma\Phi = \Phi\Lambda, \quad (30)$$

onde as colunas de Φ são os autovetores de Σ e Λ é uma matriz diagonal cuja as entradas são os autovalores de Σ , ou seja,

$$\Phi = \begin{bmatrix} | & | & & | \\ \phi_1 & \phi_2 & \dots & \phi_D \\ | & | & & | \end{bmatrix}, \quad \Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_D \end{bmatrix}, \quad (31)$$

como os autovetores de Σ são linearmente independentes, então a matriz Φ pode ser invertível, logo,

$$\Sigma = \Phi\Lambda\Phi^{-1}. \quad (32)$$

Uma matriz que pode ser escrita dessa forma é chamada de matriz diagonalizável. Porém, sabe-se que a matriz de covariância Σ é real e simétrica, consequentemente, seus autovalores são reais, e os autovetores são ortogonais. Isso significa que $\Phi^{-1} = \Phi^T$, ou seja, $\Phi^T \Phi = \Phi \Phi^T = \mathbf{I}$, onde $\mathbf{I}$ é a matriz identidade (MURPHY, 2022). Portanto, a Equação 32 pode ser reescrita como

$$\Sigma = \Phi \Lambda \Phi^T. \quad (33)$$

Essa fatoração é conhecida como decomposição espectral, ou *eigendecomposition*, e facilita aplicar operações em Σ . Ela demonstra que a matriz de covariância Σ pode ser interpretada como uma transformação linear composta por uma matriz de rotação Φ^T , uma matriz de escala Λ , seguida por uma rotação inversa Φ . Portanto, a PCA pode ser definida como uma transformação linear ortogonal na base canônica, onde os eixos do novo sistema de coordenadas são os autovetores da matriz de covariância (MURPHY, 2022).

Segundo Murphy (2022), os autovalores podem ser determinado através da equação característica da matriz de covariância. Para isso, a Equação 30 pode ser reescrita como,

$$\begin{aligned} \Sigma \Phi &= \Lambda \mathbf{I} \Phi, \\ \Sigma \Phi - \Lambda \mathbf{I} \Phi &= 0, \\ (\Sigma - \Lambda \mathbf{I}) \Phi &= 0, \end{aligned} \quad (34)$$

onde λ é um vetor com todos os autovalores de Σ , e $\mathbf{I}$ é a matriz identidade. Logo, a equação característica da matriz de covariância é dada por,

$$\det(\Sigma - \lambda \mathbf{I}) = 0. \quad (35)$$

Existe uma forma de quantificar a informação perdida ao projetar as observações nos primeiros componentes principais. Ou seja, quantificar a variância dos dados que não está contida na nova representação. De modo geral, este método fornece a fração da variância explicada por cada componente principal (JAMES et al., 2023). Segundo Murphy (2022), essa fração é dada por

$$F_L = \frac{\sum_{j=1}^L \lambda_j}{\sum_{j'=1}^D \lambda_{j'}}, \quad (36)$$

onde o numerador é a soma das variâncias das componentes principais, e o denominador é a variância total do conjunto de dados. Ainda segundo o autor, o traço de uma matriz quadrada é igual à soma de seus autovalores, ou seja,

$$\text{tr}(\Sigma) = \sum_{j'=1}^D \lambda_{j'}, \quad (37)$$


logo, a Equação 36 pode ser reescrita como

$$F_L = \frac{\sum_{j=1}^L \lambda_j}{\text{tr}(\Sigma)}. \quad (38)$$

2.4.2 Clustering Hierárquico

O *Clustering* ou Agrupamento Hierárquico é um método de Aprendizado de Máquina não supervisionado que organiza dados em uma estrutura de árvore, dividindo ou unindo grupos com base em sua similaridade. Ele é amplamente utilizado em análise exploratória, segmentação e classificação de dados. Ao contrário de técnicas de agrupamento particionais como o K-means, o agrupamento hierárquico não exige que um número pré-definido de *clusters* seja escolhido. Outra vantagem é a visualização, pois resulta em uma representação atraente das observações em forma de árvore, chamada dendrograma (JAMES et al., 2023).

Existem duas técnicas hierárquicas: as aglomerativas e as divisivas. Elas constroem hierarquias em direções opostas, como ilustra a Figura 27 para um conjunto de cinco amostras. Os métodos aglomerativos (seta superior) iniciam com cada amostra em seu próprio *cluster* e, a cada etapa, mesclam os dois mais próximos até restar apenas um. Já os métodos divisivos (seta inferior) começam com todas as amostras em um único *cluster* e, sucessivamente, dividem-no até que cada amostra volte a ser um *cluster* individual. Neste exemplo, as hierárquias aglomerativa e divisiva coincidem os *clusters* formados, mas geralmente cada método produz resultados diferentes (KAUFMAN; ROUSSEEUW, 1990).




Cada nível da hierarquia representa um agrupamento específico dos dados em *clusters* disjuntos de observações. A hierarquia completa representa uma sequência ordenada desses agrupamentos. Cabe ao usuário decidir qual nível (se houver) representa, de fato, um agrupamento “natural”, no sentido de que as observações dentro de cada um de seus grupos são suficientemente mais semelhantes entre si do que às observações atribuídas a grupos diferentes nesse nível (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Tanto os métodos divisivos quanto aglomerativos podem ser representados por uma árvore binária enraizada. Cada nó ou galho da árvore representa um grupo formado. O nó raiz representa o conjunto de dados completo. Os nós terminais representam cada uma das observações individuais (*clusters singleton*). Cada nó não terminal (“pai”) possui dois nós filhos. Para o agrupamento divisivo, os dois filhos representam os dois grupos resultantes da divisão do pai; para o agrupamento aglomerativo, os filhos representam os dois grupos que foram fundidos para formar o pai (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Todos os métodos aglomerativos e alguns métodos divisivos, quando vistos de baixo para cima, possuem uma propriedade de monotonicidade. Ou seja, a dissimilaridade entre os *clusters* fundidos aumenta monotonicamente com o nível de fusão. Assim, a árvore pode ser plotada de forma que a altura de cada nó seja proporcional ao valor da dissimilaridade intergrupar entre seus dois filhos. Os nós terminais que representam observações individuais são todos plotados com altura zero. Esse tipo de representação gráfica é chamado de dendrograma (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Um dendrograma fornece uma descrição completa e altamente interpretável do *Clustering* Hierárquico em formato de gráfico. Esta é uma das principais razões da popularidade desse método (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). A Figura 28 ilustra um dendrograma resultante de um agrupamento hierárquico aglomerativo com ligação média. Neste trabalho será dado ênfase ao método aglomerativo, que será discutido com mais detalhes posteriormente nesta seção.

Figura 28 – Dendrograma obtido por meio de agrupamento hierárquico aglomerativo com *average linkage* utilizando dados de microarranjos de tumores humanos.



Fonte: Hastie, Tibshirani e Friedman (2009, p. 522).

Ao realizar um corte horizontal no dendrograma em uma determinada altura, será particionado os dados em *clusters* disjuntos representados pelas linhas verticais que cruzarem o corte. Esses são os *clusters* que seriam produzidos ao encerrar o procedimento quando a dissimilaridade intergrupar ideal exceder o valor limite de corte. Grupos que se fudem em valores altos, em relação aos valores de fusão dos subgrupos contidos neles em níveis inferiores da árvore, são candidatos a *clusters* naturais. Isso pode ocorrer em vários níveis diferentes, indicando uma hierarquia de agrupamento, com *clusters* aninhados dentro de *clusters* (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

2.4.2.1 Clustering Hierárquico Aglomerativo

Os algoritmos de agrupamento aglomerativo começam com cada observação representando um *cluster* único. Para um conjunto de dados com N observações, o algoritmo terá $N - 1$ passos. A cada um dos passos, os dois *clusters* mais próximos (menos dissimilares) são fundidos em um único *cluster*, produzindo um *cluster* a menos no nível superior seguinte. Portanto, uma medida de dissimilaridade entre dois *clusters* (grupos de observações) deve ser definida (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Três medidas amplamente utilizadas para distância entre *clusters* são as seguintes,

$$\text{Single linkage : } \text{dist}_{\min}(C_i, C_j) = \min_{\mathbf{p} \in C_i, \mathbf{p}' \in C_j} \{\|\mathbf{p} - \mathbf{p}'\|\} , \quad (39)$$

$$\text{Complete linkage : } \text{dist}_{\max}(C_i, C_j) = \max_{\mathbf{p} \in C_i, \mathbf{p}' \in C_j} \{\|\mathbf{p} - \mathbf{p}'\|\} , \quad (40)$$

$$\text{Average linkage : } \text{dist}_{\text{avg}}(C_i, C_j) = \frac{1}{n_i n_j} \sum_{\mathbf{p} \in C_i} \sum_{\mathbf{p}' \in C_j} \|\mathbf{p} - \mathbf{p}'\| , \quad (41)$$


onde $\|\mathbf{p} - \mathbf{p}'\|$ é a distância entre dois pontos ou observações, $\mathbf{p}$ e $\mathbf{p}'$; C_i e C_j são *clusters*; e n_i e n_j são os números de pontos de C_i e C_j respectivamente (HAN; PEI; TONG, 2023).

O método *single linkage* requer apenas que uma única dissimilaridade entre $\mathbf{p}$ e $\mathbf{p}'$ seja pequena para que dois grupos C_i e C_j sejam considerados próximos, independentemente das outras dissimilaridades de observações entre os grupos. Portanto, haverá uma tendência a combinar, em limiares relativamente baixos, observações ligadas por uma série de observações intermediárias próximas. Esse fenômeno, denominado encadeamento, é muitas vezes considerado uma falha do método (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

O método *complete linkage* representa o extremo oposto. Dois grupos C_i e C_j são considerados próximos apenas se todas as observações em sua união forem relativamente semelhantes. Isso tenderá a produzir aglomerados compactos com pequenos diâmetros. No entanto, pode produzir aglomerados que violam a propriedade de “proximidade”. Ou seja, observações atribuídas a um *cluster* podem estar mais próximas de pontos de outros *clusters* do que de pontos do seu próprio (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Os métodos *single linkage* e *complete linkage* são bastante sensíveis a *outliers*. O uso do *average linkage* representa um equilíbrio entre as distâncias mínima e máxima, superando o problema da sensibilidade a *outliers* (HAN; PEI; TONG, 2023). Ele tenta produzir agrupamentos relativamente compactos e relativamente distantes entre si. No entanto, seus resultados dependem da escala numérica na qual as dissimilaridades são medidas (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). A Figura 29 ilustra os dedrogramas produzidos para cada método de ligação a partir dos mesmos dados da Figura 28.

Figura 29 – Dendrogramas obtidos a partir do agrupamento hierárquico aglomerativo utilizando dados de microarranjos de tumores humanos.



Fonte: Hastie, Tibshirani e Friedman (2009, p. 524).

Embora esses três métodos sejam clássicos, neste trabalho será utilizado o método *ward linkage*. Esse método foi desenvolvido por J.H. Ward em 1963, e consiste em utilizar a soma dos erros quadráticos, isto é, a variância acumulada por grupo para orientar a seleção dos *clusters* a serem mesclados. A dissimilaridade entre dois *clusters* baseia-se na distância euclidiana entre seus centroides multiplicada por um fator, logo,

$$W(C_i, C_j) = \frac{n_i n_j}{n_i + n_j} \|\mathbf{m}_i - \mathbf{m}_j\|^2, \quad (42)$$

onde, C_i e C_j são dois *clusters* disjuntos que serão fundidos; n_i e n_j são os números de pontos de C_i e C_j respectivamente; e $\mathbf{m}_i$ e $\mathbf{m}_j$ são as médias dos *clusters* C_i e C_j respectivamente (HAN; PEI; TONG, 2023).

O método *ward linkage* estabelece uma conexão entre o agrupamento hierárquico aglomerativo e os métodos de particionamento, tendo em vista que os métodos de particionamento também utilizam a soma dos erros quadráticos para medir a compactidade e a qualidade de um possível agrupamento (HAN; PEI; TONG, 2023).

3 MATERIAIS E MÉTODOS

Este capítulo apresenta os materiais e métodos utilizados neste trabalho. De início, é apresentada a bancada de teste de onde foi obtido os sinais de vibração analisados, também é explicado o experimento e como os sinais foram coletados e armazenados para construir o *dataset*. Em seguida, é abordada a linguagem de programação Python junto ao ambiente de desenvolvimento Jupyter Notebook, também foram introduzidas as principais bibliotecas utilizadas neste trabalho. Além disso, foi explicado as etapas de processamento dos sinais, desde o janelamento e os critérios para a escolha do tamanho das janelas, até a extração de atributos. Por fim, foi esclarecido o processamento dos atributos, desde a padronização e aplicação do PCA, até o *Clustering* e análise dos grupos formados.

3.1 Bancada de Teste

Assim como em [Souza \(2019\)](#), este trabalho também utilizou-se do banco de dados disponibilizado pela *Case Western Reserve University (CWRU)*, onde são obtidos sinais de vibração de rolamentos de esferas rígidas de um motor em uma bancada. Os sinais foram obtidos em diferentes condições: rolamento sem defeito, com defeitos na pista interna, pista externa e na esfera. Para cada condição, uma única amostra de sinal foi coletada.


A bancada consiste em um motor de 2 hp *Reliance Electric*, acoplado a um dinamômetro e um transdutor de torque, conforme ilustrado na Figura 30. O motor tem seus rolamentos do lado do acionamento e ventoinha substituídos diversas vezes por outros em condições normais ou com diferentes tipos de defeitos. Para cada rolamento o motor era submetido a diferentes níveis de cargas, variando de 0 a 3 hp ([CWRU, 2002](#)).

Foram instalados dois acelerômetros na posição vertical (12h) na carcaça do motor, que coletaram simultaneamente uma amostra de sinal para cada ensaio, o primeiro foi instalado no rolamento do lado do acionamento, e o segundo no rolamento do lado da ventoinha. Durante alguns experimentos, um acelerômetro também foi acoplado à base que sustenta o motor. Os sinais de vibração eram coletados usando um gravador *Digital Audio Tape* (DAT) de 16 canais e eram pós-processados em um ambiente Matlab. Foram utilizadas taxas de amostragem de 12 e 48 KHz ([CWRU, 2002](#)).

Segundo [Akhter \(2024\)](#), os sinais coletados estão divididos em 4 grupos, são eles:

- a) 48 KHz - Rolamentos Normais;
- b) 48 KHz - Rolamentos Anômalos do Lado do Acionamento;
- c) 12 KHz - Rolamentos Anômalos do Lado do Acionamentos;
- d) 12 KHz - Rolamentos Anômalos do Lado da Ventoinha.

Figura 30 – Bancada de teste da CWRU onde foram coletados os sinais de vibração.



Fonte: Adaptado de [CWRU \(2002\)](#).

Falhas de ponto único foram induzidas nos rolamentos de teste, que sustentam o eixo do motor. Os defeitos foram introduzidos artificialmente através de um processo chamado *Electrical Discharge Machining* (EDM), variando o diâmetro da falha entre 0,007” até 0,040”, e profundidade variando entre 0,011” e 0,15”. As anomalias foram posicionadas de maneira estratégica, de modo que cada diâmetro de falha fosse inserido separadamente na pista interna, pista externa e nas esferas dos rolamentos ([CWRU, 2002](#)).

A pista externa do rolamento é fixa em relação ao eixo do motor, ou seja, as falhas nessa posição são estacionárias. Dessa forma, a posição da falha em relação a zona de carga do rolamento tem um impacto significativo na resposta vibratória do sistema. A fim de quantificar esse efeito, foram realizados experimentos com falhas na pista externa localizadas às 6h (diretamente na zona de carga), às 3h (ortogonal à zona de carga) e às 12h (oposto à zona de carga) ([CWRU, 2002](#)).

O motor foi submetido a quatro níveis de carga, variando de 0 a 3 hp. Devido ao escorregamento, a velocidade de rotação do eixo do motor varia diretamente com a carga aplicada ([CHAPMAN, 2013](#)). Por isso, durante o experimento, a velocidade de rotação de cada ensaio também foi coletada, pois pode influenciar diretamente na análise dos sinais, principalmente no domínio da frequência. Dessa forma, considerando que o motor é de 2 hp, suas condições de operação podem ser classificadas conforme a Tabela 1.

Tabela 1 – Condições de operação do motor durante o experimento.

Carga (hp)	Velocidade (rpm)	Condição
0	1797	Motor a vazio
1	1772	Carga leve (metade da potência nominal)
2	1750	Motor a plena carga (exatamente a potência nominal)
3	1730	Motor em sobrecarga (acima da potência nominal)

Fonte: Elaborado pelo autor com base em [CWRU \(2002\)](#).

Segundo Akhter (2024), o *dataset* possui no total 161 sinais gravados. Porém, neste trabalho serão considerados para análise somente: os sinais coletados a 48 KHz, devido a quantidade maior de amostras; os defeitos no rolamento do lado do acionamento; os sinais do acelerômetro posicionado do lado do acionamento; as falhas com diâmetro de 0,007” e 0,021” com profundidade de 0,0011”; a carga de 0 hp aplicada ao motor (motor a vazio); os defeitos na pista externa na posição de 6h (centrado na zona de carga); além do sinal para o rolamento sem defeito. Foram escolhidas sete amostras de sinais, para cada sinal foi atribuído um rótulo com o intuito de distinguir as classes, conforme a Tabela 2.

Tabela 2 – Condições e rótulos dos rolamentos analisados.

Rótulo	Condição
SD	Sem defeito
PI7	Com defeito de 0,007” na pista interna
ESF7	Com defeito de 0,007” na esfera
PE7	Com defeito de 0,007” na pista externa
PI21	Com defeito de 0,021” na pista interna
ESF21	Com defeito de 0,021” na esfera
PE21	Com defeito de 0,021” na pista externa

Fonte: Elaborado pelo autor com base em CWRU (2002).

O rolamento rígido de esferas utilizado no experimento foi o 6205-2RS JEM SKF, cuja as especificações estão na Tabela 3 (CWRU, 2002).

Tabela 3 – Especificações do rolamento 6205-2RS JEM SKF.

Especificação	Valor
Diâmetro interno (mm)	25
Diâmetro externo (mm)	52
Espessura (mm)	15
Diâmetro das esferas (mm)	7,94
Diâmetro Primitivo (mm)	39
Número de esferas	9
Ângulo de contato (°)	0

Fonte: Elaborado pelo autor com base em Souza (2019).

O *dataset* também disponibiliza as frequências características de falhas do rolamento na forma de um multiplicador da velocidade de rotação em Hertz (Hz). Para a condição escolhida de motor a vazio, a velocidade do eixo é de 1797 rpm ou 29,95 Hz, conforme a Tabela 1. Logo, as frequências características foram calculadas conforme a Tabela 4.

Tabela 4 – Frequências características de falhas para condição de motor a vazio (1797 rpm).

	BPFI	BPFO	FTF	BSF
Multiplicador	5,4152	3,5848	0,39828	4,7135
Frequência de Falha (Hz)	162,18524	107,36476	11,928486	141,169325

Fonte: Elaborado pelo autor com base em CWRU (2002).

3.2 Ambiente de Desenvolvimento Python

Python é uma das linguagens de programação mais populares, versáteis e fáceis de aprender do mundo. Seu código é limpo e intuitivo, o que a torna a escolha ideal tanto para iniciantes quanto para especialistas. Ela pode ser utilizada em diversas áreas, como análise de dados, inteligência artificial, desenvolvimento de jogos, automação, entre outras. Uma das principais vantagens dessa linguagem é a variedade de bibliotecas disponíveis com uma vasta coleção de módulos de terceiros criados por sua comunidade global que ajudam a revolver problemas complexos com facilidade.

Entre as linguagens interpretadas, Python se destaca por sua grande e ativa comunidade de computação científica. A adoção de Python para computação científica, tanto em aplicações industriais quando em pesquisa acadêmica, aumentou significativamente desde o início dos anos 2000. Para análise de dados, computação exploratória interativa e visualização de dados, o Python inevitavelmente será comparado a muitas outras linguagens e ferramentas de programação comerciais e de código aberto, amplamente utilizadas em domínios específicos, como R, Matlab, SAS, Stata, entre outras ([WES, 2012](#)).

Nos últimos anos, o suporte aprimorado de bibliotecas do Python (principalmente o *pandas*) o tornou uma forte alternativa para tarefas de manipulação de dados. Combinado com a robustez do Python em programação de propósito geral, ele se torna uma excelente escolha como linguagem única para o desenvolvimento de aplicações centradas em dados ([WES, 2012](#)). Por isso, utilizar Python foi uma escolha natural para o desenvolvimento deste trabalho, tendo em vista a variedade de bibliotecas para manipular dados, além das bibliotecas especializadas em aprendizado de máquina.


Para este trabalho foi utilizado o Python versão 3.12.3, compilado no sistema operacional Windows 11, utilizando o editor gratuito Visual Studio Code (VS Code). Além disso, optou-se em utilizar a plataforma de computação interativa Jupyter Notebook. O programa foi compilado localmente em um Laptop com processador 12th Gen Intel(R) Core(TM) i7-1255U, memória RAM de 16GB e memória de armazenamento de 256GB.

3.2.1 Jupyter Notebook

O Jupyter Notebook é uma aplicação web de código aberto que permite aos usuários criar e compartilhar documentos contendo código executável, equações, visualizações e texto explicativo. Esta aplicação recebe seu nome das principais linguagens que suporta: Julia, Python e R. Seu propósito é desenvolver “cadernos computacionais” ou *notebooks* computacionais. Ele foi desenvolvido pela *Project Jupyter*, uma organização sem fins lucrativos fundada por Fernando Pérez. Foi criado com o objetivo de desenvolver *software* de código aberto e fornecer serviços que permitam a interação entre várias linguagens para uma computação eficiente ([SILAPARASETTY, 2020](#)).

Notebooks estendem a abordagem baseada em console para computação interativa em uma direção qualitativamente nova, fornecendo uma aplicação baseada na web adequada para todo o processo computacional: desenvolvimento, documentação e execução do código. Uma das principais vantagens de utilizar um *notebook* é sua facilidade de uso, visto que ele pode ser executado em um navegador web através de um *host* local, conforme ilustrado na Figura 31. Além disso, ele fornece um ambiente interativo rápido para prototipagem e explicação de código, com descrições em linguagem natural e visualizações ricas como modelos 3D, gráficos, equações LaTeX, figuras e controles interativos (JUPYTER, 2015).

Figura 31 – Ambiente do Jupyter Notebook em um navegador web.



Fonte: O autor (2026).

O *notebook* consiste em uma sequência de células. Uma célula é um campo de entrada de texto com várias linhas. O comportamento de execução de uma célula é determinado pelo seu tipo. Existem três tipos de células: células de códigos, células Markdown e células brutas. Quando uma célula de código é executada, o código que ela contém é enviado ao *kernel* associado ao *notebook*, e o *kernel* padrão (IPython) executa código Python. Os resultados retornados dessa computação são então exibidos no *notebook* como a saída da célula. A saída não se limita a texto, sendo possíveis diversas formas de saída, incluindo figuras e tabelas HTML (JUPYTER, 2015).

As células Markdown são utilizadas para documentar o processo computacional de forma escrita. Markdown é uma linguagem de marcação leve e popular que oferece uma maneira simples de marcar o texto, ou seja, especificar quais parte do texto devem ser enfatizadas em itálico ou negrito, formar listas, tabelas, etc. O Markdown também pode ser utilizado para estruturar o documento através de cabeçalhos. Dentro das células Markdown, também pode ser incluída fórmulas matemáticas de forma direta, usando a notação LaTeX padrão. Por fim, as células brutas fornecem um espaço para escrever a saída diretamente, não sendo avaliadas pelo *notebook* (JUPYTER, 2015).

O Jupyter Notebook possui uma execução interativa que permite executar o código célula por célula e ver o resultado imediatamente abaixo dela. Se precisar corrigir um erro, não precisa rodar o programa inteiro, basta ajustar a célula com problema e executá-la novamente. Por isso, ele é amplamente utilizado por cientistas de dados, pesquisadores e estudantes para análise de dados e aprendizado de máquina ([SILAPARASETTY, 2020](#)). Portanto, esse ambiente foi escolhido para o desenvolvimento do código deste trabalho.

3.2.2 Bibliotecas Python

Bibliotecas Python são coleções de códigos e funções reutilizáveis criadas para realizar tarefas específicas, poupando os desenvolvedores de construir tudo do zero. Elas abrangem desde automação e web até inteligência artificial, e podem ser instaladas via terminal usando o gerenciador de pacotes `pip`. Em geral, essas bibliotecas são criadas e mantidas por uma vasta comunidade global de desenvolvedores, empresas de tecnologia e instituições científicas. Elas são desenvolvidas de forma colaborativa e *open-source* (código aberto), o que significa que qualquer programador pode contribuir, criar e compartilhar suas próprias ferramentas. Neste trabalho as principais bibliotecas utilizadas foram: NumPy, Matplotlib, Pandas, SciPy e Scikit-Learn.

3.2.2.1 NumPy

NumPy, abreviação de *Numerical Python*, é o pacote essencial para computação científica e análise de dados em Python. Sua principal característica é o `ndarray` (abreviação de *N-dimensional array*), um objeto de matriz multidimensional poderoso e de alto desempenho que permite operações matemáticas rápidas, álgebra linear e *broadcasting* sem a necessidade de *loops* lentos e que consomem muita memória em Python ([WES, 2012](#)).

Além dos recursos de processamento de arrays rápidos que o NumPy adiciona ao Python, um de seus principais propósitos em relação à análise de dados é servir como o principal contêiner para dados a serem passados entre algoritmos. Para dados numéricos, os arrays NumPy são uma maneira muito mais eficiente de armazenar e manipular dados do que as outras estruturas de dados nativas do Python ([WES, 2012](#)).

3.2.2.2 Matplotlib

O Matplotlib é a principal biblioteca de visualização de dados da linguagem Python. Criada em 2003, ela é amplamente utilizada por cientistas e analistas para transformar números em gráficos e figuras de alta qualidade para publicação. Foi originalmente criado por John D. Hunter e agora é mantido por uma grande equipe de desenvolvedores. É ideal para criar gráficos adequados para publicação científica. Suporta a criação de visualizações tanto em 2D quanto em 3D. Integra-se bem com o Jupyter Notebook, proporcionando um ambiente interativo e confortável para plotar e explorar dados ([WES, 2012](#)).

3.2.2.3 Pandas

O Pandas é a principal biblioteca do Python voltada para manipulação, tratamento e análise de dados. De forma simples, ela traz o poder e a flexibilidade das planilhas para dentro do Python, permitindo organizar informações em linhas e colunas de forma rápida e eficiente. Ela é um dos ingredientes essenciais que fazem o Python um ambiente poderoso e produtivo para análise de dados. O principal objeto do pandas é o **DataFrame**, uma estrutura de dados tabular bidimensional, orientada a colunas, com rótulos tanto para as linhas quanto para colunas, conforme ilustrado na Figura 32 (WES, 2012).

Figura 32 – Exemplo de um **DataFrame** do Pandas.

```
>>> frame
   total_bill  tip  sex  smoker  day  time  size
1    16.99    1.01 Female    No   Sun  Dinner    2
2    10.34    1.66  Male    No   Sun  Dinner    3
3    21.01    3.5  Male    No   Sun  Dinner    3
4    23.68    3.31  Male    No   Sun  Dinner    2
5    24.59    3.61 Female    No   Sun  Dinner    4
6    25.29    4.71  Male    No   Sun  Dinner    4
7     8.77     2    Male    No   Sun  Dinner    2
8    26.88    3.12  Male    No   Sun  Dinner    4
9    15.04    1.96  Male    No   Sun  Dinner    2
10   14.78    3.23  Male    No   Sun  Dinner    2
```

Fonte: Wes (2012, p. 4).

O pandas combina os recursos de computação de *arrays* de alto desempenho do NumPy com a flexibilidade de manipulação de dados de planilhas e bancos de dados relacionais (como SQL). Ele oferece funcionalidades sofisticadas de indexação para facilitar a remodelação, o fatiamento e a segmentação, a realização de agregações e a seleção de subconjuntos de dados (WES, 2012).

3.2.2.4 SciPy

O SciPy é uma poderosa biblioteca Python voltada para matemática, ciência e engenharia. Construída sobre os arrays do NumPy, ela fornece algoritmos altamente otimizados para álgebra linear, otimização, integração, equações diferenciais, estatística, etc. (WES, 2012). Ela é dividida em módulos ou pacotes otimizados para cada área específica, alguns exemplos são:

- **scipy.cluster**: Algoritmos de agrupamento (*Clustering*), abrangendo tanto os métodos particionais quanto os hierárquicos;
- **scipy.stats**: Estatística e probabilidades. Fornece uma vasta gama de distribuições de probabilidade (contínuas e discretas), testes de hipóteses e estatísticas descritivas;
- **scipy.optimize**: Otimização de funções e busca por raízes. Crucial para encontrar mínimos e máximos locais de funções ou ajustar curvas a dados experimentais;

- **scipy.linalg**: Álgebra linear. Oferece operações avançadas com matrizes, como autovalores, autovetores, determinantes e decomposição de matrizes;
- **scipy.signal**: Pacote de ferramentas para processamento de sinais. Inclui *design* e aplicação de filtros, análise espectral, convolução, reamostragem de sinais, etc.;
- **scipy.fft**: Transformadas Rápidas de Fourier. Muito utilizado no processamento de sinais e imagens para conversão entre o domínio do tempo e da frequência.

Em conjunto, NumPy e SciPy formam uma alternativa computacional razoavelmente completa para grande parte do Matlab, juntamente com algumas de suas ferramentas complementares (WES, 2012).

3.2.2.5 Scikit-Learn

O Scikit-Learn (ou **sklearn**) é umas das bibliotecas mais populares do Python para aprendizado de máquina e mineração de dados. Criado como parte do SciKits (*SciPy Toolkits*), o Scikit-learn é o núcleo das operações de ciência de dados em Python. Ele oferece tudo que é necessário em termos de pré-processamento de dados, aprendizado supervisionado e não supervisionado, seleção de modelos, validação e métricas de erro. O Scikit-Learn foi iniciado em 2007 como um projeto do *Google Summer of Code* por David Cournapeau. Desde 2013, ele está sob a responsabilidade do *French Institute for Research in Computer Science and Automation* (INRA) (BOSCHETTI; MASSARON, 2016).


Além disso, o Scikit-Learn incorpora conjuntos de dados de teste que podem ser carregados diretamente no Python, sem necessidade de *download* de qualquer repositório externo. Alguns exemplos desse tipo de conjunto de dados são os *datasets* Iris, Boston e Digits, para citar os principais mencionados em publicações e livros, além de alguns outros conjuntos clássicos para classificação e regressão. Outra vantagem é que o **sklearn** é construído em cima de pacotes científicos consolidados do Python, o que garante alta performance e integração com outras bibliotecas como NumPy, SciPy, Matplotlib e Pandas (BOSCHETTI; MASSARON, 2016).

3.3 Processamento dos Sinais

Os sinais do *dataset* são disponibilizados no formato **.mat**, uma extensão de arquivo binário nativo do *software* Matlab. Para poder abrir os arquivos no Python foi utilizado a função **loadmat** do pacote **scipy.io**, módulo especializado em leitura e gravação de dados em uma ampla variedade de formatos. Essa função converte os arquivos em uma estrutura de dados Python do tipo dicionário, onde os nomes das variáveis são as chaves e as matrizes são carregadas como valores. Cada arquivo possui dois sinais, um referente ao sensor do lado do acionamento e o outro do sensor do lado da ventoinha.

Neste trabalho será analisado somente o rolamento do lado do acionamento, logo, também será considerado somente o sinal do sensor do mesmo lado. Os sinais escolhidos possuem em média 240000 pontos, dado a taxa de amostragem de 48 KHz, isso implica que cada sinal foi coletado por aproximadamente cinco segundos. A Figura 33 ilustra os sinais brutos no domínio do tempo para cada condição do rolamento escolhido.

Figura 33 – Sinais no domínio do tempo para cada condição do rolamento.




Fonte: Elaborado pelo autor com base em [CWRU \(2002\)](#).

3.3.1 Janelamento

Durante o experimento, foi coletado apenas uma amostra de sinal para cada condição do rolamento, o que torna a análise estatística bastante limitada. Para contornar isso, os sinais foram divididos em várias partes ou “janelas” antes da extração dos atributos. Com o janelamento dos sinais, é obtido um conjunto significativo de amostras para cada classe, o que possibilita a aplicação de métodos para identificação de padrões nos dados.

O janelamento consiste em dividir o sinal contínuo em pedaços menores, com tamanhos fixos, denominados janelas, conforme ilustrado na Figura 34. Cada janela representa um período curto de vibração, permitindo uma visualização mais detalhada do sinal. Encontrar o tamanho ideal da janela é o ponto crucial para a qualidade da análise dos dados. Janelas muito pequenas podem conter pouca informação, por outro lado, se for muito grande, podem conter informações redundantes. Outro fator vinculado ao janelamento é o passo de deslocamento, definido como a distância de uma janela para outra. Passos muito pequenos causam sobreposição excessiva de janelas, gerando dados redundantes, em contrapartida, passos muito grandes podem levar à perda de informação.

Figura 34 – Processo de janelamento dos sinais com sobreposição de janelas.



Fonte: Elaborado pelo autor com base em [CWRU \(2002\)](#).

O tamanho da janela é um intervalo de tempo que pode ser convertido em um número de pontos de dados para facilitar o fatiamento do sinal. Em geral, a escolha do tamanho da janela e do passo ocorre de forma empírica seguida de testes e ajustes, como a análise feita por [Souza \(2019\)](#). Neste trabalho, será utilizada as frequências características de falhas do rolamento como critério para determinar esses parâmetros.

As frequências características de falhas, conforme abordado na Seção 2.3, podem indicar o intervalo de tempo teórico em que ocorrem os impactos dos defeitos em cada componente do rolamento. Sabe-se também, que os impactos na pista interna e nas esferas são modulados pela distribuição de carga do rolamento. Os impactos na pista interna (BPFI) são modulados no período de rotação do eixo ($1/f_r$), enquanto que os impactos nas esferas (BSF) são modulados no período de rotação da gaiola ($1/FTF$), conforme ilustrado na Figura 20. Com isso, pode-se deduzir o tamanho de janela mínimo que ainda vai conter informação dos impactos dos defeitos em cada componente do rolamento.

Portanto, o tamanho de janela mínimo varia conforme a localização do defeito. Para defeitos na pista externa, o tamanho da janela mínimo é $1/\text{BPFO}$, devido não ser modulado pela distribuição de carga. Para defeitos na pista interna, o tamanho de janela mínimo é $1/f_r$ e nas esferas é $1/\text{FTF}$. Porém, todos os sinais devem ser janelados com o mesmo tamanho de janela, para garantir consistência e padronização no processamento. Por isso, neste trabalho será considerado o maior período entre estes, ou seja, $1/\text{FTF}$, tendo em vista que esse intervalo de tempo é o suficiente para a janela conter impactos dos defeitos nas três localizações possíveis do rolamento.

O janelamento foi feito através do fatiamento do *array* contendo o sinal em Python. Para isso, foi convertido o intervalo de tempo da janela em números de pontos de dados. A partir da Tabela 4, sabe-se que o valor de FTF é $\approx 11,93$ Hz para o rolamento utilizado no experimento, logo, o tamanho da janela deve ser $\approx 0,084$ s. Portanto, considerando a taxa de amostragem de 48 KHz, é possível calcular quantos pontos tem a janela através de uma regra de três simples, que será ≈ 4024 pontos de dados, conforme a Equação 43.

$$\frac{1}{\text{FTF}} \cdot (\text{Taxa de Amostragem}) = \frac{1}{11,93} \cdot 48000 \approx 4024 \quad (43)$$

O passo foi definido como metade do tamanho da janela, ou seja, 2012 pontos de dados. Inicialmente, o passo seria do mesmo tamanho da janela, para não haver sobreposição. Entretanto, para aumentar a quantidade de amostras de cada classe, foi necessário diminuí-lo, sendo escolhido um valor intermediário. Neste trabalho, o janelamento será a primeira e única etapa de pré-processamento dos sinais, não sendo utilizados filtros ou normalização antes de extrair os atributos.

3.3.2 Extração de Atributos

A extração de atributos é o processo de identificar, isolar e coletar características específicas, dados ou informações relevantes a partir de um conjunto de dados brutos, nesse caso, dos sinais de vibração. O objetivo é transformar os dados coletados em informações mais discriminativas para auxiliar na identificação de padrões por modelos de aprendizado de máquina. Diversas técnicas são utilizadas para extrair atributos de sinais de vibração, dentre elas os cálculos de medidas de estatísticas como a média, valor mínimo, valor máximo, desvio padrão, entropia, curtose, dentre outros.

Neste trabalho, foram calculados os seguintes atributos estatísticos: Nível Global RMS, Fator de Crista, Fator K, Assimetria e Curtose, conforme as equações 14, 15, 16, 17 e 18. Os atributos foram calculados para cada janela, ao todo foram 841 observações, com uma média de 120 amostras por classe. Eles foram organizados em um *ndarray* onde cada coluna é um atributo, e cada linha uma observação. Como será utilizado apenas técnicas de *Clustering* Hierárquico, os atributos não foram divididos em dados de treino e de teste.

3.4 Processamento dos Atributos

Após a extração e organização dos atributos em uma matriz, a primeira etapa foi realizar diferentes tipos de visualizações desses dados para auxiliar na identificação de padrões. As visualizações foram: diagrama de caixa ou *boxplot*, histograma, *pairplot* e a matriz de correlação entre os atributos. Analisados em conjunto, esses gráficos conseguem fornecer uma percepção sobre a qualidade dos atributos para diferenciar as condições do rolamento. Esses gráficos serão apresentados e analisados em detalhes no Capítulo 4.

Uma etapa de pré-processamento antes do PCA é fundamental, pois o algoritmo é altamente sensível à escala e à distribuição dos dados. Sem os ajustes corretos, variáveis com grandezas maiores dominarão o cálculo da variância, distorcendo os resultados. Por isso, uma etapa de padronização foi implementada antes do PCA. A padronização, também conhecida por *z-score*, é uma técnica estatística que transforma dados brutos para uma escala onde a média é 0 e o desvio padrão é 1. O cálculo é feito subtraindo a média (μ) do valor observado (x) e dividindo o resultado pelo desvio padrão (σ), conforme a Equação 44. Foi utilizada a função `StandardScaler` do pacote `sklearn.preprocessing` para implementar essa etapa em Python.

$$z = \frac{x - \mu}{\sigma} \quad (44)$$

Em seguida, os atributos padronizados foram submetidos ao algoritmo PCA. O objetivo principal de aplicar o PCA foi a redução de dimensionalidade dos dados, pois facilita a visualização dos padrões através do gráfico de espalhamento, ou *scatter plot*. Além disso, o PCA elimina as redundâncias, mantendo as informações essenciais para identificar os padrões principais. Também vale ressaltar, que menos dimensões exigem menos recursos computacionais e memória na etapa seguinte de *Clustering* Hierárquico. Portanto, optou-se por utilizar as duas primeiras componentes principais, pois a soma da variância explicada das duas superou 80%, além de possibilitar a visualização bidimensional. Para implementação em Python, foi utilizado a função `PCA` do pacote `sklearn.decomposition`.

Após o PCA, os dois primeiros componentes principais seguiram para a etapa do *Clustering* Hierárquico Aglomerativo. Nesta etapa, foi utilizado a função `linkage` do pacote `scipy.cluster.hierarchy` em Python. Os parâmetros da função foram configurados para aplicar o método *ward linkage* no cálculo da matriz de dissimilaridades. Esta função recebe os atributos, nesse caso as componentes principais, e retorna uma matriz chamada matriz de *linkage*, também conhecida como matriz Z. Essa matriz armazena as etapas em que os dados são agrupados, registrando quais grupos se uniram, a distância entre eles e o tamanho final do cluster. A matriz Z é uma tabela com dimensão $(n - 1) \times 4$, onde n é o número de amostras originais. As colunas detalham as operações em ordem cronológica:

- **Coluna 1:** O índice do primeiro *cluster* ou dado agrupado;
- **Coluna 2:** O índice do segundo *cluster* ou dado agrupado;
- **Coluna 3:** A distância ou dissimilaridade entre os dois *clusters* que se uniram;
- **Coluna 4:** O número total de amostras contidas no *cluster* recém-formado.

Em seguida, a matriz *Z* foi utilizada para gerar o dendrograma, ilustrando o arranjo de grupos formados no processo de *clustering* anterior. Para isso, foi utilizado função `dendrogram` do mesmo pacote `scipy.cluster.hierarchy` em Python, que gera o dendrograma a partir da matriz *Z*. Para simplificar a análise e obter uma melhor visualização, optou-se por limitar o dendrograma em até 10 *clusters*. O dendrograma será apresentado e analisado com mais detalhes no Capítulo 4.


Por último, a matriz *Z* foi utilizada para rastrear as amostras de cada *cluster* formado, ou seja, identificar as amostras presentes em cada nó ou galho do dendrograma, também se limitando a até 10 *clusters*. Cada nó do dendrograma recebeu um índice de identificação para uma melhor compreensão, o primeiro nó pai contendo todas as amostras recebeu o índice 1, o nó filho da esquerda recebeu o índice 1.1, enquanto o da direita recebeu o índice 1.2, os índices seguem descendo o dendrograma até a base, com os nós filhos da esquerda sempre recebendo um índice .1, e da direita .2.

As amostras de cada *cluster* formado foram confrontadas com suas classes reais, com o intuito de explicar os padrões encontrados, e entender a estrutura hierárquica desses padrões. Para essa etapa foi desenvolvida uma função própria no Python. Essa função recebe três informações: a matriz *Z*; os rótulos originais de cada classe, também conhecidos como *labels*; e o nível máximo de número de *clusters* do dendrograma que se deseja explorar, nesse caso 10. A função retorna um `DataFrame`, onde cada linha representa um *cluster* formado, com uma coluna de índices, e uma coluna para cada classe contendo a quantidade de amostras daquela respectiva classe presente naquele *cluster*.

3.4.1 Fluxograma

Para resumir o processamento completo, foi elaborado um fluxograma, conforme ilustrado na Figura 35. Um fluxograma é uma representação visual que ilustra as etapas, decisões e ações de um processo. Em resumo, foi escolhido os sinais de vibração a partir do *dataset* da CWRU, esses sinais foram janelados e extraído os atributos de cada uma das janelas, a partir dos atributos foram construídas várias visualizações. Em seguida, os atributos foram padronizados, realizado o PCA e elaborado o gráfico de espalhamento das componentes principais. Na sequência, foi realizado o *Clustering* Hierárquico com as componentes principais. Com a matriz *Z* foi elaborado o dendrograma, e rastreado as classes das amostras de cada *cluster*, resumindo tudo em uma tabela do tipo `DataFrame`.

Figura 35 – Fluxograma do processamento dos sinais de vibração e dos atributos.



Fonte: O autor (2026).

4 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados e discutidos os resultados obtidos neste trabalho. Primeiramente, foram analisados os atributos por meio de gráficos de *boxplot*, histograma, *pairplot* e da matriz de correlação. Em seguida, foi abordada a aplicação do PCA nos atributos padronizados, detalhando a variância explicada e os coeficientes da transformação linear de cada componente. Também foram analisados os gráficos de espalhamento e *boxplot* das componentes principais. Por fim, foi discutida a aplicação do *Clustering* Hierárquico nas componentes principais, exibindo o dendrograma e uma tabela identificando as classes presentes nos *clusters* encontrados.

4.1 Análise dos Atributos

4.1.1 Boxplot


A partir dos atributos foram elaborados os diagramas de caixas, mais conhecidos como *boxplot*, utilizando a função `boxplot` do pacote `matplotlib.pyplot` em Python, conforme ilustrado na Figura 36. A Figura apresenta um *boxplot* para cada uma das sete classes estabelecidas na Tabela 2, separados por atributo para uma melhor visualização. O *boxplot* é uma ferramenta gráfica e estatística usada para resumir conjuntos de dados numéricos. Ele exhibe visualmente a distribuição, a dispersão, a assimetria e a presença de valores discrepantes (*outliers*), sendo estruturado com base em seis medidas estatísticas:

- **Mínimo:** O menor valor do conjunto de dados, sem contar os *outliers*;
- **Primeiro Quartil (Q1):** Representa 25% dos dados que possuem valor inferior ou igual a ele. Corresponde à base inferior da caixa;
- **Mediana (Q2):** O valor central que divide o conjunto de dados exatamente na metade. É representado por uma linha no meio da caixa;
- **Terceiro Quartil (Q3):** Representa 75% dos dados que possuem valor inferior ou igual a ele. Corresponde ao topo da caixa;
- **Máximo:** O maior valor do conjunto de dados, excluindo os *outliers*;
- **Outliers:** Valores extremos e atípicos que se distanciam muito do padrão dos dados, representados visualmente por pontos ou asteriscos fora das hastes (os “bigodes”).

A distância entre o Primeiro Quartil (Q1) e o Terceiro Quartil (Q3) é chamada de Amplitude Interquartil ($AIQ = Q3 - Q1$), e a área dentro da caixa agrupa 50% dos dados centrais da amostra.

Ao analisar os *boxplots*, observa-se que o atributo que mais diferenciou as classes foi o Nível Global RMS. Através das medianas é possível perceber que o seu valor varia consideravelmente quando o rolamento sai da condição normal, mas não permite distinguir entre alguns defeitos. Por exemplo, as medianas das classes PI7 e PI21 estão muito próximas, isso torna difícil diferenciá-las apenas por este atributo. Com isso, pode-se concluir que o Nível Global RMS não diferenciou os tamanhos de defeitos na pista interna, mas ainda é possível indicar que há um defeito no rolamento.


Figura 36 – *Boxplot* dos atributos calculados.



Fonte: O autor (2026).

Além disso, há uma expectativa que os defeitos com diâmetro de 0,021”, por serem maiores, tenham um Valor RMS também maior que os de 0,007”, mas apenas os defeitos nas esferas seguiram essa lógica, inclusive o defeito de 0,007” na pista externa teve a mediana bem superior ao de 0,021”. Para entender melhor essa situação foi comparada uma janela de PE7 com outra de PE21, conforme ilustrado na Figura 37. O sinal de PE7 possui os impactos do defeito bem definidos no período de BPFO, porém o mesmo não ocorre com PE21. Alguns impactos de PE21 estão suprimidos, com amplitude menor, logo em média o sinal está com menos energia, diminuindo o Valor RMS.

Figura 37 – Comparação entre duas janelas das classes PE7 e PE21.



Fonte: O autor (2026).

O Fator de Crista permite diferenciar algumas classes, porém não tão bem quanto o Valor RMS, com destaque para o PE21 com mediana mais afastada dos demais. Conforme explicado na Seção 2.3.1.2, espera-se valores elevados do Fator de Crista para defeitos incipientes, porém a única classe que ficou com mediana elevada foi PE21. Além disso, verifica-se que a orientação geral de que o defeito pode ser constatado a partir do limiar de cinco nem sempre é válida, pois essa condição não é satisfeita para alguns defeitos.

Ao analisar o Fator K e sua dispersão de dados, observa-se uma semelhança com o Valor RMS. Isso ocorre principalmente pelo Fator K ser diretamente proporcional ao Valor RMS, conforme Equação 16. Também é possível diferenciar algumas classes, porém observa-se que o rolamento SD está bem próximo do defeito ESF7. Esse caso é particularmente problemático pois pode causar um diagnóstico falso negativo, quando o rolamento é diagnosticado sem defeito, mas ele está presente.

A Assimetria foi o atributo que mais apresentou ambiguidade entre as classes, sendo o pior para distingui-las. Porém, conforme explicado na Seção 2.3.1.4, momentos estatísticos ímpares podem tender a zero para as assinaturas de vibração tanto de rolamentos saudáveis quanto com defeitos, e foi exatamente o que ocorreu. Porém, destaca-se a classe PE21, que apresentou uma variância significativamente maior em relação as demais classes.


A Curtose, embora consiga diferenciar as classe um pouco mais que a Assimetria, também apresentou bastante ambiguidades. Conforme explicado na Seção 2.3.1.5, espera-se que os defeitos tenham valores acima de três, mas ao analisar a dispersão dos valores, os defeitos nas esferas não ficam evidentes. Porém, o defeito PE21 apresentou uma mediana bastante elevada, o que é característico de defeitos incipientes.

A partir desta análise é possível concluir que, isoladamente, os atributos não permitem diferenciar de forma inequívoca entre todos os defeitos propostos. Apesar disso, se usados simultaneamente, eles podem compensar as ambiguidades uns dos outros em uma análise multivariada. Isto, portanto, justifica uma abordagem baseada em aprendizado de máquina para reconhecer padrões através do PCA e *Clustering* Hierárquico.

4.1.2 Histograma

Em complemento aos *boxplots*, também foi criado um histograma para cada atributo, separando as classes por cores, conforme ilustrado na Figura 38. Para isso, foi utilizada a função `hist` do pacote `matplotlib.pyplot` em Python. Ao observar os histogramas, fica mais evidente as percepções concluídas a partir dos *boxplots*. Por exemplo, a capacidade superior do Valor RMS em distinguir as classes, nota-se que é possível escolher um valor limiar para separar rolamentos saudáveis de defeituosos somente com este atributo. Também fica mais evidente a dificuldade em discernir as classes através da Assimetria.

Figura 38 – Histograma dos atributos calculados.




Fonte: O autor (2026).

4.1.3 Pairplot

Um *pairplot* (ou gráfico de pares) é um recurso visual de análise de dados que exhibe as relações entre todas as variáveis numéricas de um conjunto de dados de uma só vez. Ele cria uma matriz de gráficos onde é possível identificar correlações, padrões e distribuições rapidamente. Na diagonal principal é exibido os histogramas das variáveis, enquanto que fora dela encontra-se os gráficos de espalhamentos (ou *scatter plots*) de duas variáveis diferentes. Dessa forma, foi elaborada essa visualização dos atributos com o intuito de agregar na análise, conforme ilustrado na Figura 39. Para isso, foi utilizado a função *pairplot* da biblioteca Seaborn em Python.

Figura 39 – *Pairplot* dos atributos calculados.



Fonte: O autor (2026).

Ao analisar o *pairplot*, percebe-se que, dependendo dos atributos, há uma separação linear entre algumas classes. A classe que mais se destacou das demais foi PE7, ficando distante em quase todos os gráficos de espalhamento. Nota-se também que o melhor par de atributos foi a Curtose com o Valor RMS, onde é possível identificar uma clara separação linear em até quatro grupos. Além disso, é perceptível uma forte correlação entre o Fator K e o Valor RMS, e entre o Fator de Crista e a Curtose. Conforme foi explicado na Seção 2.3.1.5, é esperado que o Fator de Crista e Curtose se comportem de forma similar.

A partir do *pairplot* já é possível identificar alguns padrões nos atributos. Por exemplo, nota-se que o defeito mais similar ao rolamento normal é o ESF7, pois está próximo de SD em quase todos os gráficos de espalhamento. Percebe-se também uma proximidade entre PI7, PI21 e ESF21. Além disso, é possível evidenciar que os defeitos na pista externa são os que mais se destacam das demais classes, com PE7 contendo pouca variabilidade entre suas amostras, enquanto PE21 possui amostras mais esparsas. Isso indica que PE7 apresenta o sinal de vibração mais constante e invariável ao longo do tempo, enquanto PE21 pode variar consideravelmente de uma janela para outra.

4.1.4 Matriz de Correlação


Uma matriz de correlação é uma tabela que exibe os coeficientes de correlação entre várias variáveis. Ela mede a força e a direção da relação linear entre pares de dados, ajudando a identificar padrões ocultos. Os valores variam em uma escala de -1 a 1:

- **1:** Correlação positiva perfeita. Quando uma variável aumenta, a outra aumenta na mesma proporção;
- **0:** Nenhuma relação linear entre as variáveis;
- **-1:** Correlação negativa perfeita. Quando uma variável aumenta, a outra diminui.

Dessa forma, foi elaborada a matriz de correlação para entender melhor a relação entre os atributos, conforme ilustrado na Figura 40. Durante a implementação em Python, foi utilizado a função `corrcoef` da biblioteca NumPy para calcular os coeficientes, e a função `heatmap` da biblioteca Seaborn para a visualização da matriz.

Ao examinar a matriz de correlação, observa-se uma forte correlação positiva entre o Fator K e o Valor RMS, e entre o Fator de Crista e a Curtose, reforçando o que já havia sido observado no *pairplot*. Também nota-se que a maioria dos atributos possuem correlação positiva entre si, havendo correlação negativa apenas entre a Assimetria e o Fator de Crista, e entre a Assimetria e a Curtose. Essa forte correlação entre os atributos justifica o uso do PCA, pois conforme abordado na Seção 2.4.1, o PCA combina a essência dos atributos e cria um conjunto alternativo menor de variáveis mutuamente não correlacionadas, reduzindo ao máximo a ambiguidade entre os atributos.

Figura 40 – Matriz de correlação dos atributos calculados.



Fonte: O autor (2026).

4.2 Aplicação do PCA

Após a aplicação do PCA é possível verificar os coeficientes e montar a equação da transformação linear de cada componente principal, conforme as equações 45 e 46. Seguindo o que foi abordado na Seção 3.4, foram calculadas somente as duas primeiras componentes principais. A primeira componente apresentou uma variância explicada de aproximadamente 56%, enquanto que a segunda apresentou aproximadamente 32%, ou seja, juntas as componentes apresentaram uma variância explicada acumulada de 88%. Isso significa que o PCA conseguiu capturar a maior parte da variância dos dados originais, ou seja, a informação principal de cada atributo. Vale ressaltar que os dados foram padronizados antes de realizar o PCA, conforme o fluxograma da Figura 35.


$$\begin{aligned}
 PC_1 = & 0.44400852 \cdot (\text{Valor RMS}) + 0.52608274 \cdot (\text{Fator de Crista}) \\
 & + 0.47763276 \cdot (\text{Fator K}) - 0.17063438 \cdot (\text{Assimetria}) \\
 & + 0.51850192 \cdot (\text{Curtose})
 \end{aligned} \quad (45)$$

$$\begin{aligned}
 PC_2 = & 0.48126134 \cdot (\text{Valor RMS}) - 0.30001844 \cdot (\text{Fator de Crista}) \\
 & + 0.43759285 \cdot (\text{Fator K}) + 0.62800058 \cdot (\text{Assimetria}) \\
 & - 0.30414508 \cdot (\text{Curtose})
 \end{aligned} \quad (46)$$

4.2.1 Gráfico de Espalhamento das Componentes Principais

A partir das componentes principais foi elaborado o gráfico de espalhamento, conforme ilustrado na Figura 41. Para isso, foi utilizado a função `scatter` do pacote `matplotlib.pyplot` em Python. É possível observar que as componentes principais conseguiram condensar as informações necessárias para distinguir ao máximo as classes. Nota-se também que alguns padrões já percebidos nos atributos continuam presentes nas componentes principais. Por exemplo, as classe mais distantes ainda são PE7 e PE21, ESF7 ainda é o defeito mais próximo de SD, e as classes PI7, PI21 e ESF21 continuam próximas. Isso demonstra que o PCA foi eficiente em manter os padrões dos atributos originais, eliminando as ambiguidades e informações desnecessárias.

Figura 41 – Gráfico de espalhamento das componentes principais.




Fonte: O autor (2026).

4.2.2 *Boxplot* das Componentes Principais

A partir das componentes principais também foram elaborados os *boxplots*, conforme ilustrado na Figura 42. Nota-se que a primeira componente principal foi mais eficiente em distinguir as classes do que qualquer atributo original presente na Figura 36, o que é esperado, tendo em vista que ela sozinha representa 56,11% da variância explicada. Já a segunda componente principal não diferenciou tão bem algumas classes, mas foi bastante eficiente em evidenciar os defeitos na pista externa. Dessa forma, as componentes principais se mostraram promissoras como novos atributos para reconhecer padrões utilizando *Clustering* Hierárquico, ou até mesmo treinar classificadores.

Figura 42 – *Borplot* das componentes principais.




Fonte: O autor (2026).

4.3 Aplicação do *Clustering* Hierárquico

4.3.1 Dendrograma

Figura 43 – Dendrograma das componentes principais.



Fonte: O autor (2026).

Conforme já explicado na Seção 3.4, após ser aplicado o algoritmo de *Clustering* Hierárquico nas componentes principais, foi elaborado um dendrograma truncado em 10 *clusters*, conforme ilustrado na Figura 43. Um índice foi atribuído para cada *cluster* encontrado para uma melhor identificação. Nota-se que somente através do dendrograma não é possível rastrear as amostras presentes em cada grupo. Dessa forma, justifica-se a criação de uma tabela que identifique as classes presentes em cada índice do dendrograma.

Ao examinar o dendrograma, pela dissimilaridade fica evidente pelo menos três *clusters*, identificados pelos índices 1.1, 1.2.1 e 1.2.2. Ao comparar com o gráfico de espalhamento da Figura 41, é possível deduzir que um grupo é formado por PE7, outro por PE21, e um pelas demais classes. Além disso, dois desses *clusters* possuem o mesmo nó pai (o índice 1.2), ou seja, esse grupos possuem um padrão em comum, que neste caso são defeitos na pista externa. Essas deduções podem ser confirmadas rastreando as amostras presentes em cada *cluster*, conforme será feito a seguir.

4.3.2 *Clusters* Encontrados

A partir do dendrograma foi elaborada uma tabela resumindo a quantidade de amostras de cada classe presente nos *clusters* encontrados, conforme o Quadro 2. Para sua construção foi desenvolvido uma função em Python que recebe a matriz Z e os rótulos originais dos dados, e rastreia as amostras presentes em cada *cluster* do dendrograma.

Quadro 2 – Principais *clusters* encontrados.

<i>Cluster</i>	SD	PI7	ESF7	PE7	PI21	ESF21	PE21	TOTAL
1	120	120	120	120	120	120	121	841
1.1	120	120	120	0	120	120	0	600
1.2	0	0	0	120	0	0	121	241
1.2.1	0	0	0	120	0	0	0	120
1.2.2	0	0	0	0	0	0	121	121
1.1.1	0	120	0	0	119	7	0	246
1.1.2	120	0	120	0	1	113	0	354
1.2.2.1	0	0	0	0	0	0	44	44
1.2.2.2	0	0	0	0	0	0	77	77
1.2.2.2.1	0	0	0	0	0	0	22	22
1.2.2.2.2	0	0	0	0	0	0	55	55
1.1.2.1	0	0	0	0	1	113	0	114
1.1.2.2	120	0	120	0	0	0	0	240
1.2.2.2.2.1	0	0	0	0	0	0	11	11
1.2.2.2.2.2	0	0	0	0	0	0	44	44
1.1.1.1	0	0	0	0	106	7	0	113
1.1.1.2	0	120	0	0	13	0	0	133
1.2.2.1.1	0	0	0	0	0	0	9	9
1.2.2.1.2	0	0	0	0	0	0	35	35

Fonte: O autor (2026).

Através do Quadro 2 é possível obter uma conjectura de como as classes estão organizadas hierarquicamente, sendo possível identificar desde os padrões mais evidentes até os mais sutis. No nível mais alto do dendrograma, há uma divisão de dois *cluster* com índices 1.1 e 1.2. Nota-se que essa primeira divisão separou os defeitos na pista externa das demais classes. Com isso, é possível deduzir que o padrão mais evidente presente nos atributos são os defeitos que estão fixos em relação a zona de carregamento.

Além disso, os rolamentos saudáveis apresentaram uma maior similaridade com os defeitos que se movimentam em relação a zona de carregamento, ou seja, os sinais SD possuem características mais próximas dos sinais de defeitos modulados pela distribuição de carga. Portanto, conclui-se que os defeitos fixos são mais fáceis de serem diagnosticados, e um classificador treinado com esses atributos terá mais dificuldade de detectar rolamentos com defeitos que se movimentam.

Na sequência, o *cluster* 1.2, contendo as classes PE7 e PE21, é dividido em outros dois subgrupos de índices 1.2.1 e 1.2.2, onde cada um recebeu uma dessas classes. O subgrupo 1.2.1, contendo PE7, não se dividiu mais até o final exibido do dendrograma, demonstrando ser o *cluster* mais consistente encontrado. Por outro lado, o subgrupo 1.2.2, contendo PE21, se dividiu em diversos outros subgrupos. Essas divisões podem ser explicadas pela alta variabilidade das amostras de PE21, conforme observado no gráfico de espalhamento na Figura 41. Com isso, conclui-se que o sinal de PE21 foi o mais variável ao longo do tempo, apresentando os atributos mais distintos de uma janela para outra.


Observa-se no dendrograma que o *cluster* 1.1 foi construído a partir dos subgrupos 1.1.1 e 1.1.2. Através do Quadro 2, nota-se que o subgrupo 1.1.1 é constituído principalmente pelas classes PI7 e PI21, ou seja, defeitos na pista interna do rolamento. Por sua vez, o subgrupo 1.1.2 é formado sobretudo pelas classes SD, ESF7 e ESF21. Dessa forma, percebe-se que entre os defeitos que se movimentam em relação a distribuição de carga, os defeitos de pista interna se mostraram mais evidentes em relação aos defeitos nas esferas. Logo, um classificador treinado com esses atributos terá mais dificuldade de diagnosticar rolamentos com defeito nas esferas.

Em seguida o *cluster* 1.1.1 é dividido nos subgrupos 1.1.1.1 e 1.1.1.2, separando os defeitos PI7 e PI21 em cada um deles, ou seja, defeitos de tamanhos diferentes na pista interna. Já o *cluster* 1.1.2 foi dividido nos subgrupos 1.1.2.1, contendo a classe ESF21, e 1.1.2.2, contendo as classes SD e ESF7. Com isso, é possível concluir que o sinal de vibração do rolamento com defeito mais similar a vibração de um rolamento normal foi ESF7. Além disso, o tamanho do defeito se demonstrou um padrão mais sutil, pois as separações de tamanhos ficaram em níveis menores de dissimilaridade no dendrograma, sendo mais fácil identificar a localização do defeito. Até o nível analisado a classe SD não se separou de ESF7 em *clusters* diferentes, mas provavelmente em níveis mais baixo essa divisão deve ocorrer.

4.3.3 Estrutura Hierárquica das Classes

Com a identificação das classes reais presentes em cada *cluster*, é possível inferir como os atributos estruturam hierarquicamente os sinais de vibração, conforme ilustrado na Figura 44. Ao analisar a estrutura, nota-se que os sinais de defeitos fixos são os mais evidentes, enquanto os sinais do rolamento saudável estão no final da hierarquia. Isso indica que os atributos tendem a mascarar os demais defeitos diante da condição saudável, o que pode comprometer a implementação de um classificador ao ocasionar diagnósticos falsos negativos. Na prática, o ideal é que os atributos tornem as características dos rolamentos saudáveis mais evidentes, evitando-se esse problema. Dessa forma, para a construção de um modelo mais eficiente em distinguir rolamentos defeituosos de saudáveis, recomenda-se a análise de outros tipos de atributos, como os do domínio da frequência.

Figura 44 – Estrutura hierárquica dos sinais de vibração analisados.



Fonte: O autor (2026).

5 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho analisou os atributos de sinais de vibração para o diagnóstico de falhas em rolamentos utilizando as ferramentas de Aprendizado de Máquina não supervisionado PCA e *Clustering* Hierárquico. Para isso, foi elaborado um programa em Python que implementou todo o processamento e análise dos sinais. Nesse programa, foi calculado os atributos de Nível Global RMS, Fator de Crista, Fator K, Curtose e Assimetria. Com esses atributos, foram feitos os gráficos de *boxplot*, histograma, *pairplot* e matriz de correlação.

Nesse programa também foi implementada a técnica de PCA nos atributos, onde foi obtido as duas primeiras componentes principais. Essas componentes foram utilizadas como novos atributos no algoritmo de *Clustering* Hierárquico, e com isso elaborado o dendrograma. Por fim, foi implementada uma função em Python para rastrear as classes das amostras presentes em cada *cluster*, e resumir tudo em uma tabela do tipo **DataFrame**.

Com os resultados obtidos, é possível concluir que:

- Os atributos no domínio do tempo são eficazes para distinguir algumas condições do rolamento, desde de que utilizados em conjunto em uma análise multivariada;
- O Nível Global RMS foi o atributo mais eficaz para evidenciar que o rolamento está com defeito, mas não permite distinguir alguns defeitos uns dos outros;
- Tamanhos de defeitos maiores, não necessariamente produzem um valor RMS maior, as vezes ocorre o oposto, conforme foi abordado sobre PE7 e PE21;
- Nem todos os defeitos apresentam um Fator de Crista maior que cinco e Curtose maior que três;
- A Assimetria foi o atributo menos eficaz para evidenciar um rolamento com defeito;
- O PCA conseguiu capturar a maior parte da variância dos dados, compensando as ambiguidades dos atributos e compactando a maior parte da informação nas componentes principais;
- A primeira componente principal é mais eficiente em discernir as diferentes condições do rolamento do que qualquer atributo original;
- Os defeitos na pista externa são mais evidentes que os defeitos na pista interna e esferas, ou seja, defeitos fixos em relação a distribuição de carga são mais evidentes;
- Os atributos no domínio do tempo tendem a mascarar os defeitos que se movimentam junto à condição saudável do rolamento;

- Os defeitos nas esferas são os mais difíceis de serem detectados.

Os resultados demonstram a viabilidade de se utilizar técnicas de Aprendizado de Máquina não supervisionado na análise de atributos para o diagnóstico de falhas em rolamentos. A combinação entre PCA e *Clustering* Hierárquico se mostrou promissora na identificação de padrões nos sinais de vibração, possibilitando analisar a estrutura hierárquica desses sinais. Entretanto, vale ressaltar que esses resultados foram obtidos a partir de um recorte dos dados disponível no *dataset*, e para uma melhor generalização é importante expandir a investigação para analisar a influência de mais circunstâncias, como a carga aplicada ao motor, e outros diâmetros de defeito. Além disso, os atributos no domínio do tempo fornecem uma visão limitada dos sinais, sendo recomendado adicionar também atributos no domínio da frequência.

5.1 Trabalhos Futuros

Visando a continuidade das análises realizadas neste trabalho, propõem-se as seguintes sugestões para pesquisas futuras:

- Treinar um modelo supervisionado de classificação utilizando as componentes principais como atributos;
- Testar novos atributos no domínio do tempo, como os coeficientes de modelos autorregressivos (AR) de diferentes ordens;
- Testar atributos no domínio da frequência, como a magnitude das frequência características de falhas utilizando a técnica do envelope;
- Construir uma árvore de classificação binária a partir dos padrões encontrados no dendrograma;
- Aplicar o *Clustering* Hierárquico direto nos atributos, sem utilizar o PCA;
- Explorar mais níveis do dendrograma e analisar subgrupos formados por amostras da mesma classe;
- Analisar a influência de mais circunstâncias nos resultados, como a carga aplicada ao motor e outros diâmetros de defeitos.

Referências

- ABECOM. *Confira 8 tipos de falhas em rolamentos de motores elétricos*. 2022. Disponível em: [Abecom](#). Acesso em: 24 fev. 2026. Citado na página 36.
- AGUIRRE, L. A. *Fundamentos de Instrumentação*. São Paulo: Pearson Education do Brasil, 2013. ISBN 978-85-8143-183-3. Citado 2 vezes nas páginas 37 e 38.
- AKHTER, M. N. *All you need to know about CWRU dataset*. 2024. Disponível em: [Medium: All you need to know about CWRU dataset](#). Acesso em: 02 jun. 2026. Citado 2 vezes nas páginas 57 e 59.
- ALMEIDA, B. G.; FABRO, E. Indústria 4.0 como ferramenta na engenharia de manutenção com base na metodologia TPM. *Scientia cum Industria*, Caxias do Sul, v. 7, n. 2, p. 23–39, 2019. Disponível em: <http://dx.doi.org/10.18226/23185279.v7iss2p23>. Acesso em: 08 jan. 2026. Citado na página 22.
- ALMEIDA, J. C. d.; LIMA, K. F. d.; BARBIERI, R. *Elementos de Máquinas: Projeto de sistemas mecânicos*. 1. ed. Rio de Janeiro: Elsevier Editora Ltda., 2017. ISBN 978-85-352-5231-6. Citado 4 vezes nas páginas 27, 28, 33 e 34.
- ANTONIOLLI, E. B. *Estudo comparativo de técnicas de medição e análise de vibrações para a manutenção preditiva em mancais de rolamentos*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Programa de Pós Graduação em Engenharia Mecânica, Florianópolis, SC, 04 1999. Disponível em: [Repositório UFSC](#). Acesso em: 12 fev. 2026. Citado 2 vezes nas páginas 30 e 42.
- BAILLIE, D.; MATHEW, J. Diagnosing rolling element bearing faults with artificial neural networks. *Acoustics Australia*, v. 22, p. 79–79, 1994. Citado 2 vezes nas páginas 18 e 30.
- BEZERRA, R. d. A. *Detecção de Falhas em Rolamentos por Análise de Vibração*. 150 p. Tese (Doutorado) — Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Comissão de Pós-Graduação em Engenharia Mecânica, Departamento de Projeto Mecânico, Campinas, SP, 07 2004. Disponível em: [Repositório UNICAMP](#). Acesso em: 11 fev. 2026. Citado 9 vezes nas páginas 30, 31, 33, 35, 39, 41, 43, 44 e 45.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. ISBN 978-0387-31073-2. Citado 4 vezes nas páginas 48, 49, 50 e 51.
- BOSCHETTI, A.; MASSARON, L. *Python Data Science Essentials: Become an efficient data science practitioner by understanding python's key concepts*. 2th. ed. Birmingham, UK: Packt Publishing Ltd, 2016. ISBN 978-1-78646-213-8. Citado na página 64.
- BRAUN, S.; DATNER, B. Analysis of roller/ball bearing vibrations. *Journal of Mechanical Design*, v. 101, n. 1, p. 118–125, 01 1979. ISSN 0161-8458. Disponível em: [<https://doi.org/10.1115/1.3454009>](https://doi.org/10.1115/1.3454009). Acesso em: 17 mar. 2026. Citado 2 vezes nas páginas 40 e 41.

BUDYNAS, R. G.; NISBETT, J. K. *Elementos de Máquinas de Shigley*. 10. ed. Porto Alegre: AMGH Editora Ltda., 2016. ISBN 978-85-8055-555-4. Citado 2 vezes nas páginas 27 e 31.

CAMPOS, R. C. et al. Uma análise comparativa do desempenho de algoritmos de classificação no diagnóstico de falhas em rolamentos de motores elétricos a partir de sinais de vibração. In: *Congresso Brasileiro de Automática-CBA*. Sociedade Brasileira de Automática (SBA), 2022. v. 3, n. 1, p. 0376–0383. ISSN 2525-8311. Disponível em: <<https://doi.org/10.20906/CBA2022/3227>>. Acesso em: 30 jun. 2026. Citado na página 18.

CASE WESTERN RESERVE UNIVERSITY. *Bearing Data Center*. 2002. Disponível em: [CWRU: Bearing Data Center](#). Acesso em: 04 mar. 2026. Citado 6 vezes nas páginas 35, 57, 58, 59, 65 e 66.

CHAPMAN, S. J. *Fundamentos de Máquinas Elétricas*. 5. ed. Porto Alegre: AMGH Editora Ltda., 2013. ISBN 978-85-8055-207-2. Citado 2 vezes nas páginas 29 e 58.

COLLINS, J. A.; BUSBY, H. R.; STAAB, G. H. *Projeto Mecânico de Elementos de Máquinas: Uma perspectiva de prevenção da falha*. 2. ed. Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora Ltda., 2019. ISBN 978-85-216-3623-6. Citado 2 vezes nas páginas 27 e 34.

DYER, D.; STEWART, R. M. Detection of rolling element bearing damage by statistical vibration analysis. *Journal of Mechanical Design*, v. 100, n. 2, p. 229–235, 04 1978. ISSN 0161-8458. Disponível em: <<https://doi.org/10.1115/1.3453905>>. Acesso em: 29 mar. 2026. Citado na página 46.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. d. S. An shm approach using machine learning and statistical indicators extracted from raw dynamic measurements. *Latin American Journal of Solids and Structures*, SciELO Brasil, v. 16, n. 2, p. e165, 2019. ISSN 1679-7825. Disponível em: <<https://doi.org/10.1590/1679-78254942>>. Acesso em: 30 mar. 2026. Citado na página 46.

GAO, C.; WU, T.; FU, Z. Advanced rolling bearing fault diagnosis using ensemble empirical mode decomposition, principal component analysis and probabilistic neural network. *Journal of Robotics, Networking and Artificial Life*, v. 5, n. 1, p. 10–14, June 2018. Disponível em: <<https://doi.org/10.2991/jrnal.2018.5.1.3>>. Acesso em: 23 mar. 2026. Citado 2 vezes nas páginas 45 e 46.

GERNES, S. N. Y.; NUNES, M. A. C. Detecção de falhas em rolamentos através de medição do envelope de vibrações. In: *VII Congresso Nacional de Ingenieria Mecanica*. Valdivia: Universidad Austral de Chile, 1996. Citado na página 42.

HAN, J.; PEI, J.; TONG, H. *Data Mining: Concepts and techniques*. 4th. ed. Cambridge, MA: Morgan Kaufmann (Elsevier), 2023. ISBN 978-0-12-811760-6. Citado 3 vezes nas páginas 48, 55 e 56.

HAND, A. *Electric Motor Maintenance and Troubleshooting*. 2nd. ed. New York: McGraw Hill, 2011. ISBN 978-0-07-176395-0. Citado 2 vezes nas páginas 36 e 37.

HARRIS, T. A.; KOTZALAS, M. N. *Rolling Bearing Analysis - 2 Volume Set*. 5th. ed. Boca Raton, FL: CRC Press / Taylor & Francis Group, 2006. ISBN 978-0-8493-8167-6. Citado 3 vezes nas páginas 31, 32 e 35.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data mining, inference, and prediction*. 2th. ed. New York, NY: Springer New York, 2009. ISBN 978-0-387-84858-7. Disponível em: <<https://doi.org/10.1007/978-0-387-84858-7>>. Acesso em: 15 abr. 2026. Citado 5 vezes nas páginas 48, 53, 54, 55 e 56.

HONARVAR, F.; MARTIN, H. R. New statistical moments for diagnostics of rolling element bearings. *Journal of Manufacturing Science and Engineering*, v. 119, n. 3, p. 425–432, 08 1997. ISSN 1087-1357. Disponível em: <<https://doi.org/10.1115/1.2831123>>. Acesso em: 24 mar. 2026. Citado 2 vezes nas páginas 45 e 46.

HUANG, H.; BADDOUR, N. Bearing vibration data collected under time-varying rotational speed conditions. *Data in Brief*, v. 21, p. 1745–1749, 2018. ISSN 2352-3409. Disponível em: <<https://doi.org/10.1016/j.dib.2018.11.019>>. Acesso em: 04 mar. 2026. Citado na página 35.

INMAN, D. J. *Vibrações Mecânicas*: Tradução da 4ª edição. Rio de Janeiro: Elsevier Editora Ltda., 2018. ISBN 978-85-352-8889-6. Citado na página 37.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *ISO 281*: Rolling bearings — Dynamic load ratings and rating life. Geneva, CH, 2007. 5 p. Disponível em: [ISO:281](#). Acesso em: 20 fev. 2026. Citado na página 33.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *ISO 5753-1*: Rolling bearings – Internal clearance – Part 1: Radial internal clearance for radial bearings. Geneva, CH, 2009. 5 p. Disponível em: [ISO:5753-1](#). Acesso em: 19 fev. 2026. Citado na página 29.

JAMES, G. et al. *An Introduction to Statistical Learning: with applications in python*. Cham: Springer, 2023. (Springer Texts in Statistics). ISBN 978-3-031-38746-3. Disponível em: <<https://dx.doi.org/10.1007/978-3-031-38747-0>>. Acesso em: 05 abr. 2026. Citado 5 vezes nas páginas 47, 48, 49, 52 e 53.

JUPYTER. *The Jupyter Notebook*. 2015. Disponível em: [The Jupyter Notebook](#). Acesso em: 05 jun. 2026. Citado na página 61.

JUVINALL, R. C.; MARSHEK, K. M. *Fundamentals of Machine Component Design*. 7th. ed. Hoboken, NJ: John Wiley & Sons, 2020. ISBN 978-1-119-49377-8. Citado na página 32.

KARDEC, A.; NASCIF, J. *Manutenção: Função Estratégica*. 3. ed. Rio de Janeiro: Qualitymark Editora Ltda, 2009. ISBN 978-85-7303-898-9. Citado 6 vezes nas páginas 20, 21, 22, 23, 24 e 25.

KAUFMAN, L.; ROUSSEEUW, P. J. *Finding Groups in Data: An introduction to cluster analysis*. Hoboken, NJ: John Wiley & Sons, 1990. ISBN 978-0-47031680-1. Disponível em: <<https://doi.org/10.1002/9780470316801>>. Acesso em: 27 mai. 2026. Citado na página 53.

- KOKIL, S. et al. Detection of fault in rolling element bearing using condition monitoring by experimental approach. *International journal of engineering research and technology*, v. 03, August 2014. ISSN 2278-0181. Disponível em: [10.17577/IJERTV3IS080767](https://doi.org/10.17577/IJERTV3IS080767). Acesso em: 21 mar. 2026. Citado na página 43.
- LAISSAOUI, A. et al. Perceptive analysis of bearing defects (contribution to vibration monitoring). *Applied Acoustics*, v. 140, p. 248–255, 2018. ISSN 0003-682X. Disponível em: <https://doi.org/10.1016/j.apacoust.2018.06.004>. Acesso em: 21 mar. 2026. Citado 2 vezes nas páginas 43 e 46.
- LEE, J. et al. Bearing data set. *IMS, University of Cincinnati, NASA Prognostics Data Repository, Rexnord Technical Services*, NASA Ames Research Center, Moffett Field, CA, USA, 2007. Disponível em: [IMS.zip](#). Acesso em: 04 mar. 2026. Citado na página 35.
- 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. Disponível em: [https://doi.org/10.1016/0022-460X\(84\)90595-9](https://doi.org/10.1016/0022-460X(84)90595-9). Acesso em: 19 mar. 2026. Citado na página 41.
- MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997. ISBN 978-0070428072. Citado na página 47.
- MONCHY, F. *A Função Manutenção: Formação para a gerência da manutenção industrial*. São Paulo: Editora DURBAN Ltda. / EBRAS Editora Brasileira Ltda., 1989. Citado na página 20.
- MOTT, R. L.; VAVREK, E. M.; WANG, J. *Machine Elements in Mechanical Design*. 6th. ed. New York: Pearson, 2017. ISBN 978-0-13-444118-4. Citado na página 26.
- MOUBRAY, J. *RCMII—Manutenção Centrada em Confiabilidade. Edição Brasileira*. Lutterworth. Inglaterra: Aladon Ltda., 2000. Citado 2 vezes nas páginas 21 e 22.
- MURPHY, K. P. *Probabilistic Machine Learning: An introduction*. Cambridge, Massachusetts: The MIT press, 2022. ISBN 978-0262046824. Citado 5 vezes nas páginas 47, 48, 50, 51 e 52.
- NIU, X.; ZHU, L.; DING, H. New statistical moments for the detection of defects in rolling element bearings. *The International Journal of Advanced Manufacturing Technology*, v. 26, n. 11-12, p. 1268–1274, 2005. ISSN 1433-3015. Disponível em: <https://doi.org/10.1007/s00170-004-2109-4>. Acesso em: 24 mar. 2026. Citado na página 45.
- NORTON, R. L. *Projeto de Máquinas: Uma abordagem integrada*. 4. ed. Porto Alegre: Bookman, 2013. ISBN 978-85-8260-023-8. Citado 7 vezes nas páginas 26, 27, 28, 31, 33, 34 e 36.
- NOWLAN, F. S.; HEAP, H. F. Reliability-centered maintenance. *United Airlines / National Technical Information Service (NTIS)*, San Francisco, California, 1978. Disponível em: [DTIC](#). Acesso em: 30 jan. 2026. Citado na página 21.
- NSK. *Falso Brinelling*. 2017. Disponível em: [NSK: Falso Brinelling](#). Acesso em: 23 fev. 2026. Citado na página 36.

- NUNES, M. A. d. C. *Diagnóstico de defeitos em rolamentos pela técnica do envelope*. 110 p. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Curso de Pós-Graduação em Engenharia Mecânica, Florianópolis, SC, 07 1989. Disponível em: [Repositório UFSC](#). Acesso em: 14 fev. 2026. Citado 2 vezes nas páginas 31 e 39.
- PETRUZELLA, F. D. *Motores Elétricos e Acionamentos: Série Tekne*. Porto Alegre: AMGH Editora Ltda., 2013. ISBN 978-85-8055-258-4. Citado na página 29.
- PINTO, L. A.; CUADROS, M. A. de S. L.; SOARES, L. de O. Uma arquitetura de sistema embarcado utilizando técnicas de deep learning e sinais de vibração para diagnóstico de falhas em rolamentos de motores elétricos. In: *Simpósio Brasileiro de Automação Inteligente-SBAI*. Sociedade Brasileira de Automática (SBA), 2021. v. 1, n. 1, p. 1316–1321. ISSN 2175-8905. Disponível em: <https://doi.org/10.20906/sbai.v1i1.2738>. Acesso em: 30 jun. 2026. Citado na página 18.
- RANDALL, R. B. *Vibration-based Condition Monitoring: Industrial, automotive and aerospace applications*. Hoboken, NJ: John Wiley & Sons, 2021. ISBN 978-11-194-7755-6. Citado 3 vezes nas páginas 37, 39 e 42.
- RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics—a tutorial. *Mechanical Systems and Signal Processing*, v. 25, n. 2, p. 485–520, 2011. ISSN 0888-3270. Disponível em: <https://doi.org/10.1016/j.ymssp.2010.07.017>. Acesso em: 20 mar. 2026. Citado na página 42.
- RAO, S. S. *Vibrações Mecânicas*. 4. ed. São Paulo: Pearson Prentice Hall, 2008. ISBN 978-85-7605-200-5. Citado na página 37.
- REHAB, I. et al. The influence of rolling bearing clearances on diagnostic signatures based on a numerical simulation and experimental evaluation. *International Journal of Hydromechatronics*, v. 1, n. 1, p. 16–46, 2018. Disponível em: <https://doi.org/10.1504/IJHM.2018.090304>. Acesso em: 10 mar. 2026. Citado na página 38.
- SALUNKHE, V. G. et al. Identification of bearing clearance in sugar centrifuge using dimension theory and support vector machine on vibration measurement. *Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems*, v. 7, n. 2, p. 021003, 02 2024. ISSN 2572-3901. Disponível em: <https://doi.org/10.1115/1.4064613>. Acesso em: 10 fev. 2026. Citado na página 29.
- SANTOS, W. F. M. dos; ARAÚJO, F. M. U. de. Detecção e diagnóstico de falhas em rolamentos, sob diferentes cargas e velocidades, utilizando redes neurais convolucionais. *Brazilian Journal of Development*, v. 9, n. 8, p. 24682–24700, Aug. 2023. Disponível em: <https://doi.org/10.34117/bjdv9n8-098>. Acesso em: 30 jun. 2026. Citado na página 18.
- SAWALHI, N.; RANDALL, R. Simulating gear and bearing interactions in the presence of faults: Part i. the combined gear bearing dynamic model and the simulation of localised bearing faults. *Mechanical Systems and Signal Processing*, v. 22, n. 8, p. 1924–1951, 2008. ISSN 0888-3270. Disponível em: <https://doi.org/10.1016/j.ymssp.2007.12.001>. Acesso em: 10 mar. 2026. Citado na página 38.
- SIKORA, E. A. Detection of bearing damage by statistic vibration analysis. *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, v. 124, n. 1, p.

012167, apr 2016. Disponível em: <<https://doi.org/10.1088/1757-899X/124/1/012167>>. Acesso em: 21 mar. 2026. Citado na página 43.

SILAPARASETTY, N. *Machine Learning Concepts with Python and the Jupyter Notebook Environment*: Using tensorflow 2.0. Berkeley, CA: Apress, 2020. ISBN 978-1-4842-5967-2. Disponível em: <<https://doi.org/10.1007/978-1-4842-5967-2>>. Acesso em: 05 jun. 2026. Citado 2 vezes nas páginas 60 e 62.

SKF. *Componentes e materiais*. 2020. Disponível em: [SKF: Componentes e materiais](#). Acesso em: 30 jan. 2026. Citado na página 27.

SKF. *Folga interna*. 2020. Disponível em: [SKF: Folga interna](#). Acesso em: 10 fev. 2026. Citado na página 29.

SKF. *Noções básicas sobre rolamentos*. 2020. Disponível em: [SKF: Noções básicas sobre rolamentos](#). Acesso em: 02 fev. 2026. Citado 2 vezes nas páginas 26 e 28.

SMITH, W. A.; RANDALL, R. B. Rolling element bearing diagnostics using the case western reserve university data: A benchmark study. *Mechanical Systems and Signal Processing*, v. 64-65, p. 100–131, 2015. ISSN 0888-3270. Disponível em: <<https://doi.org/10.1016/j.ymssp.2015.04.021>>. Acesso em: 30 jun. 2026. Citado na página 18.

SOUZA, J. d. S. *Análise de atributos de classificação para o diagnóstico de falhas em rolamentos baseado em SVM*. 89 p. Dissertação (Mestrado em Engenharia de Infraestrutura e Desenvolvimento Energético) — Núcleo de Desenvolvimento Amazônico em Engenharia, Universidade Federal do Pará, Tucuruí, PA, 08 2019. Orientador: Alexandre Luiz Amarante Mesquita; Coorientador: Rafael Suzuki Bayma. Disponível em: [Repositório UFPA](#). Acesso em: 12 fev. 2026. Citado 8 vezes nas páginas 18, 30, 43, 45, 47, 57, 59 e 66.

SOUZA, R. F. S. et al. Uma abordagem eficiente para classificação de falhas em rolamentos de motores elétricos. In: *Congresso Brasileiro de Automática-CBA*. Sociedade Brasileira de Automática (SBA), 2022. v. 3, n. 1, p. 3847–3852. ISSN 2525-8311. Disponível em: <<https://doi.org/10.20906/CBA2022/3699>>. Acesso em: 13 mar. 2026. Citado 2 vezes nas páginas 18 e 40.

TANDON, N.; CHOUDHURY, A. A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings. *Tribology International*, v. 32, n. 8, p. 469–480, 1999. ISSN 0301-679X. Disponível em: <[https://doi.org/10.1016/S0301-679X\(99\)00077-8](https://doi.org/10.1016/S0301-679X(99)00077-8)>. Acesso em: 30 mar. 2026. Citado na página 46.

VIANA, H. R. G. *PCM - Planejamento e Controle da Manutenção*. 1. ed. Rio de Janeiro: Qualitymark Editora Ltda, 2002. ISBN 85-7303-370-3. Citado 4 vezes nas páginas 18, 20, 23 e 24.

WANG, J. et al. Online bearing clearance monitoring based on an accurate vibration analysis. *Energies*, v. 13, n. 2, 2020. ISSN 1996-1073. Disponível em: <<https://doi.org/10.3390/en13020389>>. Acesso em: 10 mar. 2026. Citado na página 38.

WES, M. *Python for data analysis*. Sebastopol, CA: O'Reilly Media, Inc., 2012. Citado 4 vezes nas páginas 60, 62, 63 e 64.

XENOS, H. G. D. *Gerenciando a Manutenção Produtiva*: O caminho para eliminar falhas nos equipamentos e aumentar a produtividade. 1. ed. Belo Horizonte: EDG - Editora de Desenvolvimento Gerencial, 1998. Citado 3 vezes nas páginas 23, 24 e 25.

ZHOU, Y. et al. Rolling bearing fault diagnosis using transient-extracting transform and linear discriminant analysis. *Measurement*, v. 178, p. 109298, 2021. ISSN 0263-2241. Disponível em: <<https://doi.org/10.1016/j.measurement.2021.109298>>. Acesso em: 23 mar. 2026. Citado na página 45.

Apêndices

APÊNDICE A – Repositório no GitHub

O Jupyter Notebook utilizado no desenvolvimento deste trabalho está disponível em: https://github.com/felipe-piano/TCC_Felipe_Public.