

**UNIVERSIDADE NOVE DE JULHO – UNINOVE  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO  
CONHECIMENTO**

**LEONARDO CARVALHO ANTONIO DOS SANTOS**

**DETECÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO  
TRIFÁSICOS POR MEIO DA ANÁLISE DE SINAIS DE VIBRAÇÃO USANDO A  
DECOMPOSIÇÃO EM MODO EMPÍRICO**

São Paulo

2025

**UNIVERSIDADE NOVE DE JULHO – UNINOVE**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO**  
**CONHECIMENTO**

**DETECÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO**  
**TRIFÁSICOS POR MEIO DA ANÁLISE DE SINAIS DE VIBRAÇÃO USANDO A**  
**DECOMPOSIÇÃO EM MODO EMPÍRICO**

Texto para defesa de mestrado  
apresentado ao Programa de Pós-  
Graduação em Informática e Gestão do  
Conhecimento (PPGI) da Universidade  
Nove de Julho – Uninove, como requisito  
para obtenção do grau de Mestre em  
Informática e Gestão do Conhecimento.

Orientador: Prof. Dr. Cleber Gustavo Dias

São Paulo

2025

Santos, Leonardo Carvalho Antonio dos.

Detecção de falhas em rolamentos de motores de indução trifásicos por meio da análise de sinais de vibração usando a decomposição em modo empírico. / Leonardo Carvalho Antonio dos Santos. 2025.

154 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2025.

Orientador (a): Prof. Dr. Cleber Gustavo Dias.

1. EMD. 2. Rolamentos. 3. Motor. 4. Falha e vibração.

I. Dias, Cleber Gustavo. II. Título.

CDU 004

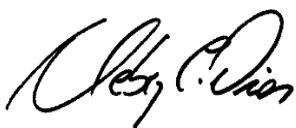
**PARECER – EXAME DE DEFESA**

Parecer da Comissão Examinadora designada para o exame de defesa do Programa de Pós-Graduação em Informática e Gestão do Conhecimento a qual se submeteu o aluno Leonardo Carvalho Antonio dos Santos.

Tendo examinado o trabalho apresentado para obtenção do título de “Mestre em Informática e Gestão Do Conhecimento”, com Dissertação intitulada Detecção de falhas em rolamentos de motores de indução trifásicos por meio da análise de sinais de vibração usando a decomposição em modo empírico, a Comissão Examinadora considerou o trabalho:

- ☒ **Aprovado**  
☐ **Aprovado condicionalmente**  
☐ **Reprovado com direito a novo exame**  
☐ **Reprovado**

**Examinadores**



---

Prof. Dr. Cleber Gustavo Dias



---

Prof. Dr. Fabio Henrique Pereira



---

Prof. Dr. Luiz Carlos da Silva

Segunda-feira, 28 de abril de 2025.

## **AGRADECIMENTOS**

Agradeço a minha família, meu alicerce e fonte inesgotável de apoio.

Ao meu orientador, Dr. Cleber Gustavo Dias, pela orientação, dedicação e pelas valiosas contribuições que enriqueceram este trabalho.

Ao Programa de Pós-Graduação em Informática e gestão do conhecimento

(PPGI) da UNINOVE, que proporcionou a estrutura e o ambiente acadêmico necessários para o desenvolvimento desta pesquisa.

Por fim, agradeço à CAPES pelo apoio financeiro, que foi fundamental para a realização deste trabalho.

“Muitos dos fracassos da vida ocorrem com as pessoas que não reconheceram o quão próximas elas estavam do sucesso quando desistiram.”

Thomas Edison

## RESUMO

Os motores de indução trifásicos desempenham um papel central na indústria, absorvendo parcela significativa da capacidade elétrica de uma Nação industrializada. Inovações como materiais avançados e algoritmos de controle, estão moldando o setor, impulsionando a eficiência e a confiabilidade. O mercado de motores elétricos está em constante expansão, com previsão de atingir 169 bilhões de dólares até 2026. Embora reconhecidos por sua confiabilidade, os motores elétricos enfrentam desafios, como falhas nos rolamentos, o que torna a manutenção essencial para garantir eficiência e longevidade. Nesse contexto, a classificação de potenciais avarias nos rolamentos de motores de indução trifásicos se torna fundamental para a eficiência industrial e a sustentabilidade. Esta pesquisa propõe abordagem para a detecção de falhas em rolamentos, utilizando a análise de vibração combinada com a Decomposição em Modo Empírico (EMD) para a extração de características do sinal de vibração e aplicação em classificadores de Machine Learning. Para realizar a análise, o estudo considera duas bases de dados principais: composta por sinais de rolamentos saudáveis e outra por sinais de rolamentos defeituosos. A importância da detecção de falhas é destacada como essencial para evitar paradas não programadas e reduzir custos operacionais. O estudo busca responder à questão de como aprimorar a análise de vibração para a detecção de anomalias em rolamentos, contribuindo para a redução de custos de paralisação, além de melhorar a confiabilidade operacional dos motores elétricos e avançar na análise de falhas, oferecendo solução integrada que abrange desde o desenvolvimento e treinamento de modelos até a avaliação de seu desempenho em comparação com métodos existentes. O estudo utiliza técnica de análise de sinais de vibração para a identificação de falhas em rolamentos de motores elétricos. Os sinais são obtidos por meio de sensores sob diferentes condições e submetidos à Decomposição em Modo Empírico (EMD), que permite separar o sinal em modos intrínsecos de diferentes componentes de frequência. Para cada modo extraído, são calculadas estatísticas descritivas, como média, desvio padrão, assimetria, variância curtose e cruzamentos por zero, com objetivo de caracterizar o comportamento vibracional. Os parâmetros são utilizados para comparar o desempenho de rolamentos em condições saudáveis e com defeitos, considerando diferentes velocidades de rotação.

**Palavras-chave:** EMD, Rolamentos, Motor, Falha e Vibração

## **ABSTRACT**

Three-phase induction motors play a central role in industry, absorbing a significant portion of the electrical capacity of an industrialized nation. Innovations such as advanced materials and control algorithms are shaping the sector, driving efficiency and reliability. The electric motor market is constantly expanding, expected to reach 169 billion dollars by 2026. Although recognized for their reliability, electric motors face challenges such as bearing failures, which makes maintenance essential to ensure efficiency and longevity. In this context, classifying potential failures in the bearings of three-phase induction motors becomes fundamental for industrial efficiency and sustainability. This research proposes an approach for detecting bearing failures, using vibration analysis combined with Empirical Mode Decomposition (EMD) to extract features from the vibration signal and apply it to Machine Learning classifiers. To perform the analysis, the study considers two main databases: one composed of signals from healthy bearings, and another composed of signals from defective bearings. The importance of fault detection is highlighted as essential to avoid unscheduled shutdowns and reduce operating costs. The study seeks to answer the question of how to improve vibration analysis for detecting anomalies in bearings, contributing to reducing downtime costs, in addition to improving the operational reliability of electric motors and advancing fault analysis, offering an integrated solution that ranges from model development and training to evaluating their performance in comparison with existing methods. The study uses a vibration signal analysis technique to identify faults in electric motor bearings. The signals are obtained by means of sensors under different conditions and subjected to Empirical Mode Decomposition (EMD), which allows separating the signal into intrinsic modes of different frequency components. For each extracted mode, descriptive statistics are calculated, such as mean, standard deviation, asymmetry, variance, kurtosis and zero crossings, with the aim of characterizing the vibrational behavior. The parameters are used to compare the performance of bearings in healthy and defective conditions, considering different rotation speeds.

**Key words:** EMD, Bearings, Motor, Failure and Vibration



## SUMÁRIO

INTRODUÇÃO .....	16
1.1. CONTEXTUALIZAÇÃO DO TEMA .....	16
1.2. TRABALHOS CORRELATOS .....	22
1.3. OBJETIVOS GERAL E ESPECÍFICOS .....	26
1.3.1. OBJETIVO GERAL .....	26
1.3.2. OBJETIVOS ESPECÍFICOS .....	26
1.4. DELIMITAÇÃO DO TEMA .....	27
1.5. PROBLEMA DE PESQUISA .....	28
1.6. JUSTIFICATIVA DA PESQUISA .....	29
1.7. HIPÓTESES DE RESOLUÇÃO DO PROBLEMA .....	30
2. FUNDAMENTAÇÃO TEÓRICA .....	31
2.1. APLICAÇÃO DA DECOMPOSIÇÃO EM MODO EMPÍRICO .....	33
2.1.1. IDENTIFICAÇÃO DE MÁXIMOS E MÍNIMOS .....	33
2.1.2. SINAL DE TESTE COM FREQUÊNCIA DE 1 HZ .....	34
2.1.3. SINAL DE TESTE COM FREQUÊNCIA DE 5 HZ .....	35
2.1.4. SINAL COMBINADO DE 1 HZ E 5 HZ .....	35
2.1.5. SINAL COMBINADO COM IDENTIFICAÇÃO DE EXTREMOS LOCAIS ...	36
2.1.6. CONSTRUÇÃO DOS ENVELOPES SUPERIOR E INFERIOR .....	37
2.1.7. INTERPOLAÇÃO DOS ENVELOPES PARA CÁLCULO DA MÉDIA .....	37
2.1.8. PRIMEIRA FUNÇÃO DE MODO INTRÍNSECO EXTRAÍDA .....	38
2.1.9. SEGUNDA FUNÇÃO DE MODO INTRÍNSECO EXTRAÍDA .....	39
2.1.10. CONSTRUÇÃO DOS ENVELOPES DA SEGUNDA ITERAÇÃO .....	39
2.1.11. COMPONENTE DE BAIXA FREQUÊNCIA EXTRAÍDA .....	40
2.1.12. CONSTRUÇÃO DOS ENVELOPES DE BAIXA FREQUÊNCIA .....	41
2.1.13. COMPONENTE LINEAR RESIDUAL DO SINAL .....	41
2.2. FUNDAMENTO MATEMÁTICO DA DECOMPOSIÇÃO EM MODO EMPÍRICO	43
2.3. CÁLCULO DAS MÉTRICAS ESTATÍSTICAS .....	45
3. MATERIAIS E MÉTODOS .....	47
3.1. NATUREZA DA PESQUISA .....	47
3.2. APARELHOS E PROCEDIMENTOS .....	47
3.2.1. ESPECIFICAÇÕES DE FALHAS .....	49
3.2.2. COLETA E ORGANIZAÇÃO DE ARQUIVOS DE DADOS .....	50
3.3. FLUXOGRAMA METODOLOGIA PROPOSTA .....	53
3.4. DECOMPOSIÇÃO DO SINAL .....	56
4. RESULTADOS PRELIMINARES OBTIDOS .....	58

4.1. EXTRAÇÃO DA FUNÇÃO DE MODO INTRÍNSECO DE DADOS SAUDÁVEIS	59
4.2. EXTRAÇÃO DA FUNÇÃO DE MODO INTRÍNSECO DE DADOS COM FALHA	68
4.3. COMPARAÇÃO DE MÉTRICAS ESTATÍSTICAS DAS FUNÇÕES DE MODOS INTRÍNSECOS DE DADOS SAUDÁVEIS ENTRE DADOS COM FALHAS EM DIFERENTES FREQUÊNCIAS	78
4.4. COMPARAÇÃO DA PRIMEIRA FUNÇÃO DE MODO INTRÍNSECO ENTRE DADOS SAUDÁVEIS E DADOS COM FALHAS EM DIFERENTES DIÂMETROS	88
4.5. COMPARAÇÃO ENTRE AS FUNÇÕES DE MODO INTRÍNSECO DE ALTA E BAIXA FREQUÊNCIA EM DADOS SAUDÁVEIS E DADOS COM FALHAS	90
4.6. COMPARAÇÃO DAS FUNÇÕES DE MODO INTRÍNSECO COM MESMA FREQUÊNCIA ENTRE DADOS SAUDÁVEIS E DADOS DE FALHAS	94
4.7. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO INNER RACE	97
4.8. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO BALL DATA	107
4.9. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO OUTER RACE CENTRALIZADO	114
4.10. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO OUTER RACE OPOSTO	120
4.11. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO OUTER RACE ORTOGONAL	123
4.12. APLICAÇÃO DE MODELOS DE MACHINE LEARNING PARA DETECÇÃO DE FALHAS EM ROLAMENTOS	127
4.12.1. UTILIZAÇÃO DE SETE MODELOS DE MACHINE LEARNING PARA CLASSIFICAÇÃO DOS DADOS	131
4.12.2. RESULTADOS DE DESEMPENHO DOS MODELOS DE MACHINE LEARNING, PARA CONDIÇÕES SAUDÁVEIS E COM FALHA	132
4.12.3. ANÁLISE DAS CURVAS RECEIVER OPERATING CHARACTERISTIC PARA OS MODELOS DE MACHINE LEARNING	134
4.12.4. ANÁLISE DAS MATRIZES DE CONFUSÃO PARA OS MODELOS DE MACHINE LEARNING	139
4.12.5. ANÁLISE DE DESEMPENHO DOS MODELOS DE MACHINE LEARNING EM CENÁRIOS MULTICLASSE	144
5. CONCLUSÕES	148
5.1. CONTRIBUIÇÃO PARA A ÁREA	150
6. REFERÊNCIAS	151

## LISTA DE FIGURAS

Figura 1. Motor de indução trifásico .....	17
Figura 2. Rolamento de Esfera .....	18
Figura 3. Elementos do rolamento de esfera .....	19
Figura 4. Instalação de rolamento em motor de indução trifásico .....	19
Figura 5. Análise de Vibração .....	21
Figura 6. Falha nos componentes do rolamento .....	22
Figura 7. Identificação de máximos e mínimos locais no sinal .....	34
Figura 8. Sinal de Teste com Frequência de 1 Hz .....	34
Figura 9. Sinal de Teste com Frequência de 5 Hz .....	35
Figura 10. Sinal Combinado de 1 Hz e 5 Hz .....	36
Figura 11. Identificação de máximos e mínimos locais no sinal .....	36
Figura 12. Construção dos Envelopes Superior e Inferior .....	37
Figura 13. Interpolação dos Envelopes para Cálculo da Média .....	38
Figura 14. Primeira Função de Modo Intrínseco extraída .....	38
Figura 15. Segunda Função de Modo Intrínseco extraída .....	39
Figura 16. Construção dos Envelopes da Segunda Iteração .....	40
Figura 17. Componente de Baixa Frequência Extraída .....	40
Figura 18. Construção dos Envelopes do Componente de Baixa Frequência .....	41
Figura 19. Componente Linear Residual do Sinal .....	42
Figura 20. Ensaio Case Western Reserve University .....	48
Figura 21. Fluxograma Metodologia Proposta .....	53
Figura 22. Representação das regiões de coleta de dados em rolamento de esferas .....	54
Figura 23. Sinal Original e as Cinco Primeiras Funções de modo Intrínsecas extraídas de um arquivo em condição de saudável .....	59
Figura 24. Sinal Original - análise arquivo dados saudáveis .....	60
Figura 25. Função de Modo Intrínseco 01 - análise arquivo dados saudáveis .....	61
Figura 26. Função de Modo Intrínseco 02 - análise arquivo dados saudáveis .....	62
Figura 27. Função de Modo Intrínseco 03 - análise arquivo dados saudáveis .....	64
Figura 28. Função de Modo Intrínseco 04 - análise arquivo dados saudáveis .....	65
Figura 29. Função de Modo Intrínseco 05 - análise arquivo dados saudáveis .....	67
Figura 30. Sinal Original e as Cinco Primeiras Funções de modo Intrínsecas extraídas de um arquivo em Condição de Falha com diâmetro de 0.007 polegadas .....	69
Figura 31. Sinal Original - análise arquivo dados com falha .....	70
Figura 32. Função de Modo Intrínseco 01 - análise dados com falha em diâmetro de 0.007 polegadas .....	71
Figura 33. Função de Modo Intrínseco 02 - análise dados com falha em diâmetro de 0.007 polegadas .....	72
Figura 34. Função de Modo Intrínseco 03 - análise dados com falha em diâmetro de 0.007 polegadas .....	74
Figura 35. Função de Modo Intrínseco 04 - análise dados com falha em diâmetro de 0.007 polegadas .....	75
Figura 36. Função de Modo Intrínseco 05 - análise dados com falha em diâmetro de 0.007 polegadas .....	77

Figura 37. Análise comparativa da estatística média entre Funções de Modo Intrínseco em dados saudáveis e com falhas.....	80
Figura 38. Análise comparativa da estatística Desvio Padrão entre Funções de Modo Intrínseco em dados saudáveis e com falhas.....	81
Figura 39. Análise comparativa da estatística Variância entre Funções de Modo Intrínseco em dados saudáveis e com falhas.....	83
Figura 40. Análise comparativa da estatística Assimetria entre Funções de Modo Intrínseco em dados saudáveis e com falhas.....	84
Figura 41. Análise comparativa da estatística Curtose entre Funções de Modo Intrínseco em dados saudáveis e com falhas.....	86
Figura 42. Análise comparativa da estatística Cruzamentos por Zero entre Funções de Modo Intrínseco em dados saudáveis e com falhas .....	88
Figura 43. Sobreposição da Função de Modo Intrínseco 1 entre em Dados saudáveis e com falha em Rolamentos (Diâmetros de 0,007 e 0,028 polegadas) .....	90
Figura 44. Comparação entre função de modo intrínseco 01 e função de modo intrínseco 05 na base de dados saudáveis .....	92
Figura 45. Comparação entre função de modo intrínseco 01 e função de modo intrínseco 05 na base de dados com falhas .....	94
Figura 46. Comparação entre função de modo intrínseco 01 de dados saudáveis e função de modo intrínseco 01 de dados com Falha .....	95
Figura 47. Comparação entre função de modo intrínseco 05 de dados saudáveis e função de modo intrínseco 05 de dados com Falha .....	97
Figura 48. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.007 polegadas .....	99
Figura 49. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.014 polegadas .....	101
Figura 50. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.021 polegadas .....	103
Figura 51. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.028 polegadas .....	104
Figura 52. Comparação entre estatísticas de dados saudáveis e Inner Race, cruzamento por zero .....	106
Figura 53. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.007 polegadas .....	107
Figura 54. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.014 polegadas .....	109
Figura 55. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.021 polegadas .....	110
Figura 56. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.028 polegadas .....	112
Figura 57. Comparação entre estatísticas de dados saudáveis e ball data, cruzamento por zero .....	113
Figura 58. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.007 polegadas .....	115
Figura 59. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.014 polegadas .....	116

Figura 60. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.021 polegadas .....	117
Figura 61. Comparação entre estatísticas de dados saudáveis e outer race centralizado, cruzamento por zero .....	119
Figura 62. Comparação entre estatísticas de dados saudáveis e outer race oposto, diâmetro de falha de 0.007 polegadas .....	120
Figura 63. Comparação entre estatísticas de dados saudáveis e outer race oposto, diâmetro de falha de 0.021 polegadas .....	121
Figura 64. Comparação entre estatísticas de dados saudáveis e outer race oposto, cruzamento por zero .....	122
Figura 65. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, diâmetro de falha de 0.007 polegadas.....	124
Figura 66. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, diâmetro de falha de 0.021 polegadas.....	125
Figura 67. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, cruzamento por zero .....	126
Figura 68. Processamento e classificação de falhas utilizando modelos de Machine Learning.....	130
Figura 69. Curva Receiver Operating Characteristic do modelo Multilayer Perceptron .....	135
Figura 70. Curva Receiver Operating Characteristic do modelo Extreme Gradient Boostin.....	136
Figura 71. Curva Receiver Operating Characteristic do modelo Random Forest....	136
Figura 72. Curva Receiver Operating Characteristic do modelo Logic Regression.	137
Figura 73. Curva Receiver Operating Characteristic do modelo Gradient Boosting	137
Figura 74. Curva Receiver Operating Characteristic do modelo Support Vector Machine (Linear) .....	138
Figura 75. Curva Receiver Operating Characteristic do modelo Support Vector Machine (Radial Basis Function Kernel).....	138
Figura 76. Matriz de Confusão do modelo Multilayer Perceptron .....	139
Figura 77. Matriz de Confusão do modelo Extreme Gradient Boostin .....	140
Figura 78. Matriz de Confusão do modelo Random Forest .....	141
Figura 79. Matriz de Confusão do modelo Logistic Regression .....	141
Figura 80. Matriz de Confusão do modelo Gradient Boosting .....	142
Figura 81. Matriz de Confusão do modelo Support Vector Machine (Linear).....	143
Figura 82. Matriz de Confusão do modelo Support Vector Machine (Radial Basis Function Kernel).....	143
Figura 83. Matriz de Confusão Multiclasse do modelo XGBoost .....	144
Figura 84. Matriz de Confusão Multiclasse do modelo Random Forest.....	145
Figura 85. Matriz de Confusão Multiclasse do modelo Gradient Boosting .....	146

## LISTA DE TABELAS

Tabela 1. Autores seminais para Detecção de Falhas em Rolamentos e Decomposição em modo empírico. ....	26
Tabela 2. Técnicas para Detecção de Falhas em Rolamentos.....	26
Tabela 3. Características das Falhas Detectadas em Rolamentos: Localização, Diâmetro, Profundidade e Fabricante.....	50
Tabela 4. Dados de referência normalizados para diferentes cargas e velocidades de motor.....	51
Tabela 5. Dados de referência para Inner Race e ball (análise com frequência de 12.000 Hz).....	52
Tabela 6. Distribuição das Amostras por Classe antes do balanceamento .....	128
Tabela 7. Distribuição das Amostras por Classe após o balanceamento .....	129
Tabela 8. Desempenho dos modelos de Machine Learning para detecção de falhas em rolamentos .....	133
Tabela 9. Desempenho dos modelos para a classe saudável.....	133
Tabela 10. Desempenho dos modelos para a classe Falha .....	134

## LISTA DE ABREVIATURAS

AUC - Area Under the Curve

CEEMD - Complete Ensemble Empirical Mode Decomposition (Decomposição Empírica em Conjunto Completo de Modos)

CEEMDAN – Decomposição em Modo Empírico Completa com Ruído Adaptativo (Complete Empirical Mode Decomposition with Adaptive Noise)

EEMD – Decomposição em Modo Empírico em Conjunto (Ensemble Empirical Mode Decomposition)

EMD – Decomposição em Modo Empírico (Empirical Mode Decomposition)

FFT – Transformada de Fourier Rápida (Fast Fourier Transform)

HP – Cavalos de Potência (Horse Power)

HHT – Transformada de Hilbert-Huang (Hilbert-Huang Transform)

IMF – Função de Modo Intrínseco (Intrinsic Mode Functions)

MIT – Motor de Indução Trifásico

ML – Machine Learning

MLP - Multilayer Perceptron

PSD - Power Spectral Density (Densidade Espectral de Potência)

ROC - Receiver Operating Characteristic

RPM – Rotações por Minuto

SK – Curtose Espectral (Spectral Kurtosis)

SMOTE - Synthetic Minority Over-sampling Technique

SVM (RBF) - Support Vector Machine (Radial Basis Function Kernel)

SVM (Linear) - Support Vector Machine (Linear Kernel)

SVR – Regressão por Vetor de Suporte (Support Vector Regression)

XGBoost - Extreme Gradient Boostin

## INTRODUÇÃO

### 1.1. CONTEXTUALIZAÇÃO DO TEMA

Os motores de indução trifásicos (Figura 1), são pilares da indústria e representam as máquinas elétricas mais empregadas. Em nação industrializada, é comum que absorva de 40% a 50% da capacidade elétrica total produzida pelo país (THOMSON et al., 2001).

Os motores elétricos são extremamente reconhecidos por sua confiabilidade, especialmente os motores de indução, amplamente adotados na indústria. No entanto, mesmo sendo máquinas notoriamente confiáveis, eles não estão isentos de enfrentar variedade de anomalias. Diversas pesquisas destacaram que falhas nos rolamentos são as comuns entre os motores elétricos. Assim, mesmo com a boa confiabilidade geral dos motores elétricos, é fundamental considerar que a manutenção adequada e a atenção contínua às possíveis falhas são essenciais para garantir a eficiência e a longevidade desses dispositivos em inúmeras aplicações industriais e domésticas (ANTONINO-DAVIU et al., 2020).

A falha de um motor elétrico, elemento essencial no processamento de matérias-primas até o produto para fabricação ininterrupta, tende a causar tempo de inatividade do equipamento, danos aos itens produzidos ou manipulação de sua qualidade, o que, por sua vez, resulta em um aumento dos custos financeiros da empresa. (ZAIETS et al., 2019).

Os motores de corrente alternada podem ser divididos em duas categorias principais: motores síncronos e motores assíncronos, conhecidos como motores de indução. As principais distinções entre esses dois tipos de motores residem nas características de velocidade, partida, operação e aplicações. A escolha entre esses motores depende das necessidades específicas de aplicação, dos requisitos de controle de velocidade, eficiência e potência reativa. Na indústria, o motor amplamente utilizado é o motor assíncrono, devido às suas especificidades, durabilidade e eficiência. Eles são conhecidos pela sua facilidade de operação e manutenção, o que resulta em menor custo operacional. Além disso, esses motores são robustos e têm vida útil longa, tornando-os ideais para ambientes industriais desafiadores (DE LIMA et al., 2022).



Inovações e avanços tecnológicos estão moldando a indústria de motores elétricos, permitindo que esses dispositivos atendam às demandas crescentes de eficiência, e desempenho em um cenário onde a eletrificação se torna predominante. Como resultado, os motores elétricos estão desempenhando um papel fundamental na transformação de diversos setores, incluindo mobilidade, produção e automação residencial (GUO et al., 2023).

Figura 1. Motor de indução trifásico



Fonte: (ABB, 2023)

#### 1.1.1. IMPORTÂNCIA DOS ROLAMENTOS

Os rolamentos de Esfera (Figura 2), desempenham um papel fundamental em diversos setores, sendo peças essenciais de todas as máquinas elétricas. Eles são projetados para transferir energia rotacional com perda mínima, garantindo assim a eficiência dos equipamentos. Esses componentes são indispensáveis para o funcionamento adequado de máquinas e equipamentos de diversos setores, desde a indústria automotiva até a aeroespacial, passando pela produção em geral. Sua capacidade de guiar movimentos de forma precisa e confiável faz com que sejam amplamente utilizados para garantir o desempenho eficiente de máquinas em todo o mundo (NGUYEN-SCHÄFER et al., 2016).

Figura 2. Rolamento de Esfera



Fonte: (Rottel Rolamentos, 2023)


Devido as condições críticas de operação a que os motores elétricos são submetidos, operando, geralmente, em altas velocidades de rotação em ambientes sujeitos ao pó e em contato com outros materiais, os rolamentos são os componentes dos motores sujeitos a falhas de diversas naturezas (CAMPOS, M et al., 2022).

#### 1.1.2. RELEVÂNCIA DOS ROLAMENTOS PARA A CONFIABILIDADE DOS MOTORES

O uso de rolamentos permite a otimização de máquinas e processos, resultando em um menor desperdício de energia e materiais primários. Isso contribui para a sustentabilidade e ajuda a reduzir o impacto ambiental das operações industriais. Em resumo, os rolamentos de esfera, desempenham um papel essencial na indústria moderna, impulsionando a eficiência, a precisão e a sustentabilidade. Eles são um exemplo de como a tecnologia pode ser usada para aprimorar a produtividade industrial (RIAH et al., 2008).

A Figura 3 ilustra os principais elementos que compõem um rolamento de esfera, destacando o anel externo, o anel interno, a gaiola e as esferas. Esses componentes proporcionam movimento rotacional, distribuindo uniformemente as cargas aplicadas e reduzindo o atrito e o desgaste.


Figura 3. Elementos do rolamento de esfera



Fonte: (EL Galvão, 2023)

Nos motores de indução trifásicos, por exemplo, os rolamentos permitem reduzir o atrito entre as partes móveis do motor, garantindo que o eixo gire de forma suave (Figura 4). Adicionalmente, os rolamentos contribuem para a melhor distribuição da carga ao longo do eixo, além de proteger outras partes do motor contra um desgaste prematuro.

Figura 4. Instalação de rolamento em motor de indução trifásico



Fonte: (Mundo da Elétrica, 2023)

### 1.1.3. CLASSIFICAÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS

Dentre os diferentes tipos de falhas em um motor de indução trifásico (MIT), cerca de 52% estão relacionadas a rolamentos. Além disso, essas falhas são

frequentemente acompanhadas de danos irreversíveis, com alto custo de manutenção. Assim, é aconselhável realizar a detecção dessas anomalias em seu estágio inicial, preferencialmente de forma não invasiva e sem interromper a operação da máquina, a fim de evitar sua quebra total (BRUSAMARELLO et al., 2022).

O desenvolvimento e a evolução das falhas de rolamento são causados principalmente por condições operacionais adversas: vibração, carga excessiva, desalinhamento do eixo, excentricidade, corrosão e montagem incorreta do eixo. Além disso, a lubrificação convencional pode levar à contaminação do rolamento, o que é um fator importante de falha. Portanto, o diagnóstico de falhas de rolamento é essencial para aumentar a confiabilidade do processo (GODOY et al., 2020).

Máquinas elétricas sem vibrações em seu ambiente de trabalho é algo praticamente inexistente, em especial no ambiente industrial. Em muitos casos, diversos componentes de um motor de indução trifásico ocasionam vibrações e, conseqüentemente, resulta em interrupções dos equipamentos, provocando, a longo prazo, a falha de alguns subsistemas ou da própria máquina. A análise de vibração é o procedimento predominante para considerar a natureza e o grau de problemas em máquinas, como trincas, erosão e corrosão conforme mostrado na Figura 6. (DIONÍSIO M et al., 2023).

#### 1.1.4. IMPORTÂNCIA NA DETECÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS

Os acionamentos industriais são dominados por motores de indução trifásicos. Devido a isso, o monitoramento de condições e a detecção de falhas em seu estágio inicial tornam-se necessidade essencial, especialmente em aplicações críticas de máquinas de indução (BINDU et al., 2022).

O rolamento é um elemento importante do MIT. A falha imprevista do componente pode levar a consequências negativas, como a paralisação da máquina. Portanto, o diagnóstico de falhas e o monitoramento de condições já ganharam importância razoável e, dia a dia, se tornam valiosos. Existem muitos fatores que podem causar anomalias no rolamento. A maioria deles por má lubrificação ou sobrecarga do MIT. Além disso, a variedade de fatores ambientais e de fabricação

podem ter impacto no rolamento e em sua operação posterior, como fadiga do material, contaminação e colocação incorreta do rolamento durante a instalação (KUDELINA et al., 2021).

Em piores circunstâncias, a vibração pode danificar equipamentos com gravidade, levando à sua interrupção e acarretando elevados prejuízos financeiros. A falha no rolamento pode ocasionar a interrupção de um processo crítico que pode envolver o travamento do eixo do MIT. O ponto positivo está na possibilidade de que se a vibração for medida e analisada corretamente, pode ser usada como indicador da condição da máquina (HOLANDA et al., 2016).

As soluções do estado da arte têm como objetivo desenvolver um método de detecção de falhas em rolamentos de motor de indução trifásico por meio da análise de vibração no domínio de tempo (Figura 5). Os rolamentos desempenham um papel crítico no funcionamento dos MIT, e a detecção de anomalias é essencial para evitar paradas não programadas e reduzir custos de manutenção. Os dados de vibração são coletados no domínio do tempo para identificar padrões específicos de vibração associados a falhas em rolamentos.

Figura 5. Análise de Vibração



Fonte: (Manutenção Predial, 2023)

#### 1.1.5. FALHAS EM COMPONENTES DO ROLAMENTO

As falhas de rolamentos podem acontecer por alguns fatores, dentre eles, pode-se destacar a anomalias mecânicas, como desgaste ou fadiga nos elementos. A seguir são apresentados os componentes passíveis de falhas.

#### a) FALHAS NAS PISTAS EXTERNAS

1. Desgaste: O desgaste nas pistas externas pode ocorrer devido a cargas excessivas, falta de lubrificação adequada ou presença de partículas abrasivas, conforme Figura 6.
2. Corrosão: A corrosão nas pistas externas pode ocorrer devido à exposição a ambientes corrosivos, resultando em perda de material.

#### b) FALHAS NAS PISTAS INTERNAS

1. Fadiga: Fadiga nas pistas internas se dá por cargas cíclicas, resultando em trincas e eventual falha, conforme Figura 6.
2. Desalinhamento: Se o rolamento estiver sujeito a um desalinhamento excessivo, pode ocorrer desgaste irregular nas pistas internas.

#### c) FALHAS NOS ELEMENTOS ROLANTES

1. Esmagamento: O Esmagamento dos elementos rolantes pode ocorrer sob cargas extremas, resultando em deformação e perda de integridade.
2. Desgaste: O desgaste nos elementos rolantes pode ser causado por atrito excessivo ou falta de lubrificação adequada.

Figura 6. Falha nos componentes do rolamento



Fonte: (Dynamox, 2023)

## 1.2. TRABALHOS CORRELATOS

A análise de vibração no domínio do tempo, utilizando a Decomposição em Modo Empírico, tem sido objeto de estudos voltados à detecção de falhas em rolamentos de esferas (ZHU et al., 2019).

Rolamentos são componentes essenciais para a eficiência operacional de máquinas rotativas, e a detecção de anomalias é fundamental para evitar paradas inesperadas e reduzir custos operacionais. A análise de vibração, quando aplicada a sinais de rolamentos, pode permitir a identificação de falhas com maior sensibilidade, contribuindo para a extensão da vida útil dos rolamentos (NARANG et al., 2024).

Estudos realizados por Schoen, Habetler, Kamran e Bartfield (1995) destacam a importância da detecção de falhas em rolamentos de elementos rolantes em máquinas de indução. O monitoramento de vibrações é amplamente utilizado para identificar condições de falha, pois as vibrações mecânicas resultam de variações no entreferro físico da máquina. Essas variações afetam a dinâmica dos rolamentos, gerando frequências características associadas à sua construção física, que podem ser analisadas para detectar anomalias. O estudo revisa os modos de falha nos rolamentos e define as frequências características que indicam esses defeitos, evidenciando a relevância de um monitoramento para prevenir falhas inesperadas e aumentar a confiabilidade operacional.

Pesquisadores Blodt, Granjon, Raison e Rostaing (2008) propuseram novos modelos para analisar a influência de falhas em rolamentos de elementos rolantes em motor de indução trifásico, destacando a importância da detecção desses defeitos. As falhas de rolamento são as principais causas de anomalias em sistemas de acionamento, e a sua detecção pode ser realizada por meio do monitoramento de vibrações em frequências características dos rolamentos.

Jin, Zhao, Chow e Pecht (2014) discutiram técnicas de classificação de falhas em máquinas, levando em conta a disponibilidade de dados rotulados. As tecnologias baseadas em sensores têm demonstrado eficácia na avaliação das condições de saúde das máquinas, com os sinais de vibração sendo amplamente utilizados para diagnosticar anomalias em rolamentos, motores de indução e caixas de engrenagens. O estudo ressalta a importância de um monitoramento contínuo e de métodos de classificação adequados para aprimorar a detecção e a gestão de falhas em sistemas mecânicos.

Tian, Morillo, Azarian e Pecht enfatizam que as falhas de rolamento são as principais causas de anomalias em motores elétricos, e alarmes falsos são um problema comum, apesar dos métodos de análise de vibração disponíveis. O artigo

apresenta um novo método que detecta falhas de rolamento e monitora a degradação em motores elétricos, utilizando a curtose espectral e a correlação cruzada para extrair características de falha.

Flandrin, Rilling e Gonçalves (2004) apresentam a extensão da Decomposição em Modo Empírico (EMD) para séries temporais bivariadas, permitindo a extração de componentes rotativos de média zero. A abordagem adapta o EMD, originalmente limitada a séries de valor real, a dados bivariados, sendo aplicável a sinais em um espaço bidimensional. A técnica é ilustrada com exemplos de sinais reais, e códigos para implementação do método estão disponíveis online.

Yan e Gao (2006) destacam a Transformada de Hilbert-Huang (HHT) como ferramenta alternativa para a análise de sinais, com ênfase no método de Decomposição em Modo Empírico (EMD). O método é utilizado para o monitoramento da degradação de rolamentos e detecção de falhas em máquinas-ferramenta, pois permite identificar características não estacionárias e não lineares ocultas em sinais dinâmicos. O EMD extrai oscilações intrínsecas dos sinais medidos, decompondo-os em Funções de Modo Intrínseco (IMFs) através de um processo de peneiramento que envolve a identificação de máximos e mínimos locais. Apesar de sua eficácia, a validação matemática rigorosa da HHT, incluindo o EMD, ainda é um campo ativo de pesquisa.

Boudraa e Cexus (2007) apresentam um método de filtragem de sinal baseado na Decomposição em Modo Empírico (EMD), que se concentra em abordagem orientada a dados. O método decompõe um sinal ruidoso em Funções de Modo Intrínseco (IMFs) por meio de um processo de peneiramento. As IMFs correspondem a componentes de baixa frequência, permitindo a reconstrução parcial do sinal. Um critério é proposto para identificar as IMFs, garantindo que a energia das estruturas supere a do ruído. Os resultados são comparados a técnicas de filtragem tradicionais, embora o estudo se limite a sinais afetados por ruído gaussiano branco aditivo, com base em experimentos numéricos.

Kopsinis e McLaughlin (2009) discutem a Decomposição em Modo Empírico (EMD) como um método de análise de sinal que ganhou destaque devido ao seu desempenho em diversas aplicações. No entanto, destacam que a falta de base teórica sólida limita a compreensão e as possíveis melhorias do método, resultando



em abordagem que não evoluiu nos últimos anos. O artigo propõe a versão do EMD que melhora a decomposição. O desenvolvimento é baseado em estudo que otimiza a configuração do EMD, focando nos critérios para a seleção de pontos de interpolação.

Ren, Suganthan e Srikanth analisam a Decomposição em Modo Empírico (EMD) como técnica para prever a velocidade do vento, que é desafiadora devido à sua natureza intermitente e características não lineares. O artigo apresenta versões aprimoradas do EMD, como Ensemble EMD (EEMD), Complementary EEMD (CEEMD) e complete EEMD with Adaptive Noise (CEEMDAN), que ajudam a decompor séries temporais complexas em componentes simples. Essas abordagens são hibridizadas com métodos de inteligência computacional, como regressão por vetor de suporte (SVR) e redes neurais artificiais (ANN).

No contexto da detecção de falhas em rolamentos, apesar do avanço significativo nas técnicas e abordagens que utilizam a Decomposição em Modo Empírico (EMD), existem lacunas que merecem atenção. Muitos estudos enfatizam a eficácia do EMD em diferentes aplicações, na maioria das pesquisas concentra-se em dados em contextos específicos, o que pode não refletir a complexidade das condições reais de operação. A pesquisa proposta busca abordar essas lacunas, utilizando a análise de vibração combinada com o EMD para a extração de características do sinal de vibração e a aplicação em classificadores de Machine Learning. A importância da detecção de falhas é destacada como essencial para evitar paradas não programadas e reduzir custos operacionais. O estudo visa não apenas aprimorar a análise de vibração, oferecem solução integrada que abrange desde o desenvolvimento e treinamento de modelos até a avaliação de seu desempenho em comparação com métodos existentes.

A revisão da literatura destaca contribuições para a detecção de falhas em rolamentos, utilizando a Decomposição em Modo Empírico (EMD). Os estudos referenciados fornecem base para o desenvolvimento de metodologias para identificação de falhas. Para sintetizar as principais contribuições e técnicas abordadas, apresentadas nas Tabelas 1 e 2, que listam autores seminais e métodos aplicados à detecção de rolamentos defeituosos. Essas tabelas são a referência para contextualizar as abordagens utilizadas e a evolução das técnicas na área.

Tabela 1. Autores seminais para Detecção de Falhas em Rolamentos e Decomposição em modo empírico.

Tema	Autores
Detecção de falha em rolamentos	RR Schoen, TG Habetler, F. Kamran e RG Bartfield, 1995
	M. Blodt, P. Granjon, B. Raison e G. Rostaing, 2008
	X. Jin, F. Yuan, TWS Chow e M. Zhao, 2014
	J. Tian, C. Morillo, MH Azarian e M. Pecht, 2016
Decomposição em modo empírico	Patrick Flandrin, Gabriel Rilling e Paulo Gonçalves, 2004
	Ruqiang Yan e Robert X. Gao, 2006
	Abdel-Ouahab Boudraa e Jean-Christophe Cexus, 2007
	Yannis Kopsinis e Stephen McLaughlin, 2009
	Ye Ren, P. N. Suganthan e Narasimalu Srikanth, 2015

Fonte: Autor

Tabela 2. Técnicas para Detecção de Falhas em Rolamentos

Tema	Técnicas
Detecção de falha em rolamentos	Decomposição em Modo Empírico (EMD)
	Análise de Vibração com Transformada de Fourier Rápida (FFT)
	Análise de Vibração com Transformada de Fourier Rápida (FFT)

Fonte: Autor

### 1.3. OBJETIVOS GERAL E ESPECÍFICOS

#### 1.3.1. OBJETIVO GERAL

O Objetivo geral da pesquisa consiste em desenvolver um modelo computacional capaz de identificar falhas em rolamentos de motores trifásicos de indução a partir de sinais de vibração da máquina.

#### 1.3.2. OBJETIVOS ESPECÍFICOS

- Desenvolver um modelo computacional baseado na Decomposição em Modo Empírico (EMD) para extrair características dos sinais de vibração;
- Realizar análise das métricas estatísticas extraídas dos sinais de vibração para diferentes condições dos rolamentos, como pista externa, pista interna e elementos rolantes;
- Avaliar a eficácia do modelo computacional em distintas condições de operação do motor, considerando variações de torque de carga; e

- d) Aplicar classificadores de Machine Learning para detectar e classificar os diferentes tipos de falhas nos rolamentos.

#### 1.4. DELIMITAÇÃO DO TEMA

A presente pesquisa se propõe a contribuir na avaliação de métricas estatísticas de forma adicional, visando não apenas o reconhecimento de um rolamento avariado, a detecção precisa da localização do problema, se a falha ocorre na pista externa, elementos rolantes ou na pista interna do rolamento.

A presente pesquisa concentra-se no levantamento da condição dos rolamentos em motores de indução trifásicos, com o objetivo de determinar, por meio de dados de vibração, se um rolamento está saudável ou apresenta falhas, destacando a importância desse componente para o desempenho e a confiabilidade dos motores elétricos. Embora esses motores sejam reconhecidos por sua robustez, os rolamentos estão entre os componentes suscetíveis a falhas, pois podem levar a paradas não programadas, e com isso os custos elevados de manutenção.

A análise de vibração, amplamente utilizada para monitoramento de condições e diagnóstico de falhas, é o método predominante neste estudo, fornece indicadores que possibilitam intervenções de manutenção antes que danos severos ocorram (VISHWAKARMA et al., 2017).

A proposta sublinha a importância da manutenção baseada em condições e na detecção de falhas, estratégias essenciais para evitar paradas não programadas, reduzir custos de manutenção e garantir a eficiência operacional. Para isso, é empregada a Decomposição em Modo Empírico (EMD), técnica de processamento de sinais, capaz de extrair características relevantes de sinais de vibração, mesmo em condições não lineares e não estacionárias, permitindo a identificação de falhas, especialmente as incipientes (MOLINA et al., 2023).

A combinação da análise EMD com estatísticas e classificações de Machine Learning é apresentada como solução para a classificação e localização de anomalias em rolamentos. Os dados experimentais utilizados provêm de base pública da Case Western Reserve University, contendo registros de motores operando em regime permanente, ou que limitam o escopo a condições resultantes e previsíveis. A

abordagem permite análise detalhada e confiável dos dados coletados, oferecendo contribuição para o avanço da manutenção preditiva e a confiabilidade operacional dos rolamentos de motores elétricos.

### 1.5. PROBLEMA DE PESQUISA

Falhas inesperadas em equipamentos rotativos podem acarretar custos elevados, paradas não planejadas e até mesmo danos catastróficos à produção industrial. Os rolamentos, componentes críticos desses equipamentos, desempenham um papel essencial no funcionamento adequado de motores de indução. Quando falham, os impactos podem ser severos, resultando em altos custos de reparo e substituição, além de comprometer a eficiência operacional. Nesse cenário, o monitoramento baseado em vibração surge como técnica eficaz para detectar e diagnosticar problemas, formando a base de estratégias de manutenção preditiva (LACEY et al., 2011).

A detecção de falhas em rolamentos garante a continuidade operacional e minimiza custos. O foco desta pesquisa é a identificação de anomalias específicas em componentes dos rolamentos, como a pista interna, pista externa e elementos rolantes. Por meio da análise de sinais de vibração, é possível identificar padrões indicativos de defeitos incipientes, proporcionando um diagnóstico preciso e confiável. O desafio na manutenção de motores de indução trifásicos é o desenvolvimento de técnicas de monitoramento avançadas capazes de detectar falhas em estágios iniciais, garantindo precisão e rapidez no diagnóstico. Detectar anomalias incipientes permite que ações preventivas sejam tomadas, minimizando a necessidade de intervenções corretivas dispendiosas, que geralmente envolvem altos custos e longos períodos de inatividade.

A abordagem proposta neste estudo busca melhorar a confiabilidade operacional desses motores em ambientes industriais críticos, onde paradas inesperadas podem ter impactos significativos na produção. Com a implementação de métodos eficientes de detecção, espera-se reduzir o tempo de inatividade, otimizando os custos operacionais e contribuindo para estratégia de manutenção sustentável, aumenta a vida útil dos equipamentos e fortalece a competitividade industrial, ao reduzir perdas e melhorar a eficiência global dos processos.

## 1.6. JUSTIFICATIVA DA PESQUISA

A justificativa da pesquisa está fundamentada na necessidade de aumentar a confiabilidade e a eficiência de modelos para detecção de falhas em rolamentos de motores de indução trifásicos, considerando as graves consequências que tais anomalias podem acarretar, como paradas não programadas, perdas de produção, custos elevados de manutenção e até mesmo acidentes industriais (SOUZA, 2021). Entre os componentes desses motores, os rolamentos desempenham um papel fundamental, sendo responsáveis por sustentar e permitir a rotação suave do eixo. Quando apresentam falhas, como vibrações excessivas, desalinhamento ou desgaste acelerado, podem resultar em danos catastróficos ao motor, elevando os custos de reparo e os períodos de inatividade (MURUGESAN et al., 2018).

Os dados de vibração são as principais fontes de informações para avaliar a condição dos rolamentos e identificar falhas. Vibrações indicam alterações nas condições de funcionamento, sendo um importante sinal de alerta para problemas iminentes. Nesse cenário, o monitoramento baseado em vibração é amplamente reconhecido como abordagem eficaz para detectar a presença e o crescimento de falhas (YANG et al., 2013). Contudo, métodos convencionais de análise nem sempre conseguem identificar falhas incipientes com precisão devido à baixa energia dos sinais iniciais e à presença de ruído, evidenciando a necessidade de técnicas avançadas.

Neste contexto, a aplicação da Decomposição em Modo Empírico (EMD) destaca-se como abordagem eficaz. Além de atuar como pré-processamento ao remover ruídos dos sinais, o EMD permite a extração de componentes de frequência não visíveis e a identificação de padrões anômalos relacionados a falhas em estágio inicial. Diferentemente da análise Wavelet, que depende de parâmetros fixos e escolhas subjetivas, o EMD realiza decomposição autoajustável baseada nas características locais do sinal, sendo especialmente adequada para sinais não estacionários e não lineares, típicos de vibrações em rolamentos com falhas incipientes (BIN et al., 2012).

Ao possibilitar análise detalhada e precisa dos sinais vibracionais, o EMD complementa o monitoramento baseado em vibração, oferecendo maior confiabilidade para sistemas de diagnóstico preditivo (JP AMEZQUITA et al., 2017). A

abordagem não só melhora a identificação de falhas, mas contribui para a redução de custos, aumento da vida útil dos rolamentos e segurança operacional dos motores, reforçando a relevância desta pesquisa.

### 1.7. HIPÓTESES DE RESOLUÇÃO DO PROBLEMA

Considerando a importância dos rolamentos na eficiência operacional de máquinas rotativas, a detecção precisa de falhas nesses componentes é essencial para evitar paradas não planejadas e custos elevados. A análise de vibração desempenha um papel fundamental nesse processo, proporcionando sensibilidade aprimorada na identificação de anomalias. A aplicação da Decomposição em Modo Empírico (EMD) surge como solução para superar os desafios na detecção de anomalias, especialmente em ambientes industriais críticos.

A análise detalhada das Funções de Modo Intrínseco (IMFs), extraídas por meio do EMD, pode revelar padrões comportamentais dos rolamentos, tanto em condições saudáveis quanto em estados de falha. A abordagem permite identificação das falhas, facilitando o diagnóstico de problemas específicos, como defeitos na pista interna, externa ou nos elementos rolantes. A partir da investigação, espera-se melhorar a compreensão do desempenho dos rolamentos sob diversas condições operacionais.

O desenvolvimento e aplicação de metodologias avançadas de monitoramento não apenas garantem segurança operacional, as contribuem para a maximização da vida útil dos equipamentos. A evolução na precisão e eficiência das técnicas de diagnóstico impacta diretamente a eficácia das operações industriais, tornando os processos confiáveis e sustentáveis (AL-NAJJAR et al., 2007).

A pesquisa enfatiza a confiabilidade dos motores elétricos, com foco nos motores de indução, destacando a importância dos rolamentos nesse contexto. A combinação do EMD com a análise de vibração é apresentada como abordagem prática para otimizar o desempenho dos sistemas industriais, promovendo redução de custos operacionais, aumento da eficiência e melhoria contínua da confiabilidade operacional.

## 2. FUNDAMENTAÇÃO TEÓRICA

A detecção de anomalias em rolamentos de motores de indução trifásicos é um desafio crítico na manutenção de sistemas industriais. Falhas nesses componentes podem causar interrupções não programadas na produção, elevando os custos de reparo e reduzindo a eficiência operacional (SHEIKH et al., 2022).

Máquinas rotativas, amplamente utilizadas em aplicações industriais, operam frequentemente em ambientes adversos e estão sujeitas a diversas falhas. Para diagnosticar e mitigar essas falhas, técnicas avançadas de processamento de sinais, como a Decomposição em Modo Empírico (EMD), são mostradas extremamente eficazes (Y. LEI et al., 2021).

O EMD é técnica adaptativa que analisa sinais não lineares e não estacionários. Ao contrário dos métodos tradicionais que utilizam funções de base fixa, o EMD deriva suas funções diretamente do sinal, tornando-se abordagem voltada aos dados. O método decompõe o sinal em componentes oscilatórios chamados Funções de Modo Intrínseco (IMFs). Esses IMF capturam modulações específicas de frequência e amplitude, geralmente associadas a processos físicos relevantes. A tarefa ocorre de maneira sequencial, iniciando pelas escalas temporais compostas (modos de alta frequência) e progredindo para escalas amplas (modos de baixa frequência) (WANG et al., 2014).

As principais vantagens do EMD é a capacidade de preservação e integridade do sinal. A soma dos IMFs e do sinal residual tende a reconstruir o sinal de entrada, garantindo que nenhuma informação seja perdida. Além disso, o EMD é amplamente utilizado para reduzir ruídos em sinais. Os IMFs que contenham ruídos podem ser identificados e excluídos, permitindo a cobertura de sinais limpos e protegidos para análises subsequentes (BOUDRAA et al., 2009).

Além de sua aplicação em diagnósticos de falhas, a Decomposição em Modo Empírico (EMD) tem se mostrado eficaz na detecção de sinais mistos e complexos, característica comum em ambientes industriais. Um aspecto fundamental do EMD é sua natureza empírica e adaptativa, que permite decompor sinais sem a necessidade de avisos prévios sobre linearidade. Isso faz com que o método seja amplamente utilizado em aplicações que envolvem dados de vibração altamente ruidosos, como

rolamentos e engrenagens, onde as técnicas falham em capturar características importantes dos sinais (HUANG et al., 1998).

A modelo EMD é particularmente útil em máquinas rotativas, onde sinais oscilatórios frequentemente apresentam características dinâmicas e complexas. Essas características, que variam ao longo do tempo, são difíceis de isolar usando métodos tradicionais. O EMD facilita a tarefa, permitindo a separação dos componentes do sinal e a aplicação de análises avançadas, como transformadas de Hilbert, para extrair frequências instantâneas (A. QUINN et al., 2021). A abordagem ajuda a descrever e identificar padrões não lineares, que são essenciais para diagnósticos de falhas precisos.

Durante o processo de diagnóstico, os sinais de vibração originados, como tempo-frequência e tempo-amplitude, fornecem informações críticas sobre o comportamento da máquina. Esses dados são frequentemente usados como entrada para redes neurais, que podem ser treinados para verificar automaticamente padrões de falhas. Com um treinamento adequado, essas redes tornam o processo de detecção eficiente e automatizado, reduzindo a necessidade de intervenção manual (CHEN et al., 2019).

O EMD desempenha um papel fundamental na detecção de anomalias incipientes. Essas falhas, em seus estágios iniciais, muitas vezes apresentam sinais fracos e mascarados por ruídos. O método de segurança permite a identificação dessas pequenas alterações no comportamento do sinal, proporcionando vantagem para a manutenção preditiva. A capacidade de detectar essas falhas pode ajudar a evitar danos catastróficos e reduzir os custos operacionais (LEI et al., 2013).

O EMD é fundamental no conceito de definição adaptativa, onde oscilações rápidas e lentas são isoladas iterativamente. Esse processo é realizado por meio de um algoritmo conhecido como "peneiramento", que aplica um operador elementar não linear para refinar os componentes do sinal. O EMD se diferencia por não depender de filtros predefinidos, permitindo análise flexível e adaptativa (RILLING et al., 2007). Esse diferencial torna o EMD ferramenta indispensável em diversas áreas, especialmente em diagnósticos industriais, onde a precisão e a eficiência são cruciais.

O EMD é um método amplamente utilizado na separação de sinais não estacionários e não lineares, particularmente em aplicações que envolvem dados



complexos. Diferentemente de abordagens tradicionais, o EMD não pressupõe periodicidade no sinal e utiliza um processo iterativo para decompor o sinal original em IMFs, que representam componentes oscilatórios locais. A vantagem do EMD é sua capacidade de operar diretamente no domínio do tempo, oferecendo análise adaptativa baseada nos dados (HU et al., 2012).

A aplicação de técnicas de Machine Learning (ML) expandiu-se de forma expressiva, impulsionado pela crescente disponibilidade de grandes volumes de dados e pelo avanço das ferramentas, que se tornaram acessíveis e eficientes. O conceito de Machine Learning está estreitamente ligado a outras áreas, como mineração de dados, descoberta de conhecimento e inteligência artificial. Atualmente, as aplicações de Machine Learning são amplamente empregadas em diferentes setores de produção, abrangendo atividades como otimização de processos, controle de sistemas e resolução de problemas avançados (WUEST et al., 2016).

O aprendizado de máquina possibilita a extração de características relevantes e a análise automatizada de padrões em sinais de vibração. A abordagem permite identificar falhas com precisão, reduzindo a necessidade de intervenção manual e otimizando estratégias de manutenção preditiva. A capacidade do ML de reconhecer automaticamente entradas subsequentes com base em amostras previamente aprendidas garante confiabilidade no diagnóstico e na previsão de falhas (Zhang, Zhao e Lin, 2021).


## 2.1. APLICAÇÃO DA DECOMPOSIÇÃO EM MODO EMPÍRICO

### 2.1.1. IDENTIFICAÇÃO DE MÁXIMOS E MÍNIMOS

A Figura 7 demonstra a etapa inicial do algoritmo, a identificação de máximos e mínimos locais no sinal, com os extremos destacados por pontos. Esses extremos são utilizados para construir os envelopes superior e inferior, elementos essenciais para a extração das IMFs. A onda senoidal simples é um IMF, pois a diferença entre mínimos e máximos é, no máximo, de 1, e a média do conjunto de dados é zero. O uso desses envelopes permite que o EMD isole oscilações específicas, garantindo que as variações capturadas sejam representativas das dinâmicas reais do sinal. Esse processo não apenas melhora a precisão da decomposição, facilita análises

subsequentes, como a de frequência instantânea, tornando o EMD ferramenta indispensável para a análise de sinais complexos.

Figura 7. Identificação de máximos e mínimos locais no sinal




Fonte: Autor

### 2.1.2. SINAL DE TESTE COM FREQUÊNCIA DE 1 HZ

A Figura 8 apresenta um sinal de teste com frequência de 1 Hz, utilizado como base para análises no domínio do tempo e da frequência. O sinal representa oscilação simples e periódica. A frequência de 1 Hz facilita a identificação de padrões básicos e permite avaliação clara das oscilações no tempo.

Figura 8. Sinal de Teste com Frequência de 1 Hz




Fonte: Autor

### 2.1.3. SINAL DE TESTE COM FREQUÊNCIA DE 5 HZ

A Figura 9 ilustra um sinal de teste com frequência de 5 Hz. O sinal tem frequência maior em comparação com o anterior, resultando em um padrão de oscilação elevado. É empregado para verificar métodos de como o EMD, executa componentes de frequências maiores, presentes em sinais complexos.

Figura 9. Sinal de Teste com Frequência de 5 Hz




Fonte: Autor

### 2.1.4. SINAL COMBINADO DE 1 HZ E 5 HZ

A Figura 10 apresenta um sinal composto, obtido pela combinação linear dos sinais senoidais de 1 Hz e 5 Hz ilustrados nas figuras anteriores. Esse tipo de sinal simula condições realistas encontradas em ambientes industriais, onde múltiplas frequências coexistem simultaneamente. A construção do sinal combinado visa avaliar a capacidade de algoritmos de processamento de sinais, como a Decomposição em Modo Empírico (EMD), em identificar e separar componentes distintos, preservando as características individuais de cada frequência presente no sinal original.

Figura 10. Sinal Combinado de 1 Hz e 5 Hz




Fonte: Autor

#### 2.1.5. SINAL COMBINADO COM IDENTIFICAÇÃO DE EXTREMOS LOCAIS

A Figura 11 ilustra um sinal combinado de 1 Hz e 5 Hz, no qual os máximos locais estão destacados em vermelho e os mínimos locais em azul. O gráfico demonstra a identificação dos extremos locais, que são etapas fundamentais no processo de construção dos envelopes superiores e inferiores no algoritmo de EMD. A identificação precisa desses pontos é essencial para a correta proteção das IMFs, permitindo análise detalhada dos componentes de frequência do sinal.

Figura 11. Identificação de máximos e mínimos locais no sinal




Fonte: Autor

### 2.1.6. CONSTRUÇÃO DOS ENVELOPES SUPERIOR E INFERIOR

A Figura 12 apresenta o sinal combinado de 1 Hz e 5 Hz, com os máximos locais destacados em vermelho e os mínimos locais em azul. As curvas em verde e laranja representam, respectivamente, os envelopes superior e inferior, que foram construídos a partir dos extremos locais. Os envelopes são elementos para o processo de EMD, pois permitem isolar oscilações características do sinal.

Figura 12. Construção dos Envelopes Superior e Inferior




Fonte: Autor

### 2.1.7. INTERPOLAÇÃO DOS ENVELOPES PARA CÁLCULO DA MÉDIA

A Figura 13 apresenta o sinal combinado de 1 Hz e 5 Hz, destacando os máximos e mínimos locais (em vermelho e azul, respectivamente), com seus envelopes superior (em verde) e inferior (em laranja). Além disso, a curva interpolada em vermelho representa a média desses dois envelopes. Esse passo é fundamental no processo de EMD, pois a média é subtraída do sinal original para isolar as oscilações características, levando à remoção da primeira IMF. A precisão na interpolação garante que os modos sejam representativos das dinâmicas reais do sinal.

Figura 13. Interpolação dos Envelopes para Cálculo da Média




Fonte: Autor

#### 2.1.8. PRIMEIRA FUNÇÃO DE MODO INTRÍNSECO EXTRAÍDA

A Figura 14 apresenta a primeira IMF obtida após a aplicação do processo de EMD ao sinal combinado. Esse IMF corresponde ao componente oscilatório de maior frequência apresentado no sinal original, capturando as oscilações rápidas. A remoção do IMF é fundamental para separar as diferentes frequências do sinal e analisar individualmente as características dinâmicas de cada componente. Esse processo permite a compreensão profunda dos padrões subjacentes no sinal.

Figura 14. Primeira Função de Modo Intrínseco extraída




Fonte: Autor

### 2.1.9. SEGUNDA FUNÇÃO DE MODO INTRÍNSECO EXTRAÍDA

A Figura 15 apresenta a segunda IMF extraída do sinal original utilizando o processo de EMD. Esta captura do IMF pelas oscilações de frequência apresenta no sinal, representando padrões que estão entre os componentes de alta e baixa frequência. A retirada do IMF permite a análise detalhada das características dinâmicas do sistema, fornecendo insights sobre características específicas que podem estar associadas a determinadas condições operacionais ou falhas potenciais.

Figura 15. Segunda Função de Modo Intrínseco extraída




Fonte: Autor

### 2.1.10. CONSTRUÇÃO DOS ENVELOPES DA SEGUNDA ITERAÇÃO

A Figura 16 ilustra a segunda iteração do processo de EMD, com os máximos locais destacados em vermelho e os mínimos locais em azul. O envelope superior (verde) e inferior (laranja) foram construídos para esta nova exclusão de sinal, com a média interpolada apresentada em vermelho. Esse passo é fundamental para refinar a simulação e isolar componentes oscilatórios de frequência baixa. A precisão na construção desses envelopes garante que a IMF seja extraída para capturar corretamente as oscilações características do sinal residual.

Figura 16. Construção dos Envelopes da Segunda Iteração




Fonte: Autor

#### 2.1.11. COMPONENTE DE BAIXA FREQUÊNCIA EXTRAÍDA

A Figura 17 apresenta o componente de baixa frequência obtido após as iterações finais do processo de Decomposição em Modo Empírico (EMD). Isso representa tendência de longo prazo do sinal, capturando oscilações de baixa frequência que não são atribuídas a modos oscilatórios intrínsecos de alta ou média frequência. Esse componente é essencial para analisar variações lentas no comportamento do sistema, que podem indicar mudanças associadas a falhas.

Figura 17. Componente de Baixa Frequência Extraída




Fonte: Autor



### 2.1.12. CONSTRUÇÃO DOS ENVELOPES DE BAIXA FREQUÊNCIA

A Figura 18 apresenta o processo de construção dos envelopes superior (verde) e inferior (laranja) para o componente de baixa frequência extraído na etapa final do processo de EMD. Os máximos locais são indicados por pontos vermelhos, enquanto os mínimos locais são destacados em azul. A média interpolada, representada pela linha central, é utilizada para refinar o componente residual. O processo garante que todas as oscilações relevantes, sejam comprovadas.

Figura 18. Construção dos Envelopes do Componente de Baixa Frequência




Fonte: Autor

### 2.1.13. COMPONENTE LINEAR RESIDUAL DO SINAL

A Figura 19 apresenta o componente linear residual do sinal após a aplicação completa do processo de EMD. O componente final representa a tendência linear remanescente, decrescente que todas as oscilações foram separadas em IMFs. A análise desta exposição linear é útil para compreender a tendência geral do sistema monitorado, sendo relevante especialmente em contextos em que mudanças constantes ou progressivas podem sinalizar condição operacional crítica ou desgaste gradual do equipamento.

Figura 19. Componente Linear Residual do Sinal



Fonte: Autor

Conforme apresentado na figura, a representação da parte final do sinal que não pode ser decomposto em Funções de Modo Intrínseco (IMFs). Esse componente é fundamental para a identificação de tendências de longo prazo no sistema, como variações lineares ou comportamentos constantes, que podem indicar mudanças lentas, como desgaste ou variações de carga. A exceção serve como confirmação da completude do processo de liquidação. Quando a exposição apresenta um comportamento constante, isso indica que todas as oscilações graves do sinal foram capturadas pelos IMFs, garantindo que o processo de EMD foi concluído.

O resíduo fornece base importante para análises adicionais. Enquanto o IMF detalha as oscilações específicas, a exclusão oferece visão global, permitindo correlacionar tendências de longo prazo com opções específicas nos IMFs. Em alguns casos, oscilações inesperadas podem apontar para anomalias ou falhas latentes no sistema, tornando-o ferramenta vital na detecção de problemas. Além disso, o comportamento de exclusão pode ser usado para ajustar os limites do algoritmo EMD, melhorando a precisão das decomposições futuras. Assim, a separação não é apenas um subproduto do processo, peça essencial para análise completa e precisa do sinal.

## 2.2. FUNDAMENTO MATEMÁTICO DA DECOMPOSIÇÃO EM MODO EMPÍRICO

a) Equação 1: Representação geral da EMD aplicada a uma série temporal:

$$x(t) = \sum_{i=1}^n c_i(t) + r_i(t) \quad (1)$$

Onde:

$c_i(t)$  IMFs extraídos através de um processo iterativo de refinamento (sifting);

$r_n$  resíduo final (componente não oscilatório ou tendência do sinal);

$n$  representa o número de IMFs obtidos.

No presente estudo  $x(t)$ , representa o sinal coletado por um acelerômetro instalado no alojamento de uma máquina elétrica rotativa. O processo de EMD está relacionado ao cálculo de todos os extremos locais, máximos e mínimos, sendo que o número de máximos locais, mínimos locais devem ser igual ou diferir no máximo por uma unidade. Além disso, a média dos envelopes superior e inferior deve ser aproximadamente nula em qualquer ponto do tempo.

b) Equação 2: Cálculo da média local:

$$m(t) = \frac{e_{sup}(t) + e_{inf}(t)}{2} \quad (2)$$

Onde:

$e_{sup}(t)$  envelope superior (interpolação dos máximos locais);

$e_{inf}(t)$  envelope inferior (interpolação dos mínimos locais).

A diferença entre o sinal original e a média local  $m(t)$  é chamada de  $h_0(t)$  na primeira etapa do processo de refinamento. Esse processo é aplicado de forma iterativa até que  $h_k(t)$  atenda as condições para ser classificado como IMF. Para cada iteração ( $k= 1, 2, \dots$ ) calcula-se novamente a média dos envelopes, subtrai-

se essa média para obter um novo sinal, o procedimento se repete até a obtenção do valor do resíduo  $r_n(t)$ , função monotônica da qual não se pode mais extrair IMFs.

c) Equação 3, até a equação 7: Etapas do processo de refinamento (sifting):

- Etapa 1 (inicialização):

$$h_0(t) = x(t) \quad (3)$$

- Etapa 2 ( $k = 1, 2, \dots$ ):

$$m_{k-1}(t) = \frac{e_{sup}^{(k-1)}(t) + e_{inf}^{(k-1)}(t)}{2} \quad (4)$$

$$h_k(t) = h_{k-1}(t) - m_{k-1}(t) \quad (5)$$

$$c_i(t) = h_k(t) \quad (6)$$

Etapa 3 (atualização do resíduo):

$$r_i(t) = x(t) - \sum_{j=1}^i c_j(t) \quad (7)$$

As fórmulas e o processo de decomposição foram baseados diretamente no trabalho de Huang et al. (1998), que introduziu a Decomposição em Modo Empírico (EMD) como ferramenta poderosa para a análise de séries temporais não estacionárias e não lineares.

### 2.3. CÁLCULO DAS MÉTRICAS ESTATÍSTICAS

Neste trabalho, algumas métricas estatísticas foram calculadas a partir dos IMFs extraídos, tendo como sinal bruto dados do acelerômetro instalado na máquina. As métricas, descritas nas equações 8 a 12, foram utilizadas como variáveis de entrada para os classificadores aplicados no diagnóstico da condição dos rolamentos.

a) Média:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (8)$$

Onde:

$N$  Número de amostras;

$x_i$  valor do sinal no instante  $i$ ;

b) Desvio Padrão:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (9)$$

c) Variância:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (10)$$

d) Assimetria (Skewness):

$$S_k = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \mu}{\sigma} \right)^3 \quad (11)$$

e) Curtose (Kurtosis):

$$K_u = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \mu}{\sigma} \right)^4 \quad (12)$$

f) Cruzamentos por Zero (Zero Crossings):

$$ZC = \sum_{i=1}^{N-1} \delta[(x_i - \bar{x})(x_{i+1} - \bar{x}) < 0] \quad (12)$$

Onde:

$ZC$  número total de cruzamentos por zero;

$\bar{x}$  valor médio do sinal;

$\delta[\cdot]$  função indicadora, que retorna 1 se a condição lógica dentro dos colchetes for verdadeira e 0 caso contrário.

### 3. MATERIAIS E MÉTODOS

#### 3.1. NATUREZA DA PESQUISA

A pesquisa é exploratória e quantitativa. Realiza testes controlados em motores de indução trifásicos com falhas introduzidas nos rolamentos, registrando dados de vibração sob diferentes condições operacionais. Explora abordagens combinando Decomposição em Modo Empírico e dados estatísticos para aprimorar a detecção de anomalias. A análise quantitativa inclui métricas como média e assimetria, para avaliar o impacto das falhas e treinar modelos de Machine Learning para sua classificação.


A pesquisa tem como foco principal a detecção de falhas em rolamentos de motores elétricos, utilizando técnicas de processamento de sinais. Entre as metodologias adotadas, destaca-se o EMD, técnica que permite decompor sinais complexos em componentes oscilatórios de frequência variável, facilitando a identificação de padrões.

#### 3.2. APARELHOS E PROCEDIMENTOS

O site da Case Western Reserve University oferece acesso a um conjunto de dados provenientes de testes de rolamentos de esfera, que incluem informações sobre rolamentos em condições saudáveis e defeituosas. Os experimentos foram realizados com um motor Reliance Electric de 2 HP, onde foram medidas acelerações em diferentes pontos, próximo do rolamento do motor e distante dele.

A bancada de teste, conforme ilustrado na Figura 20, é composta por um transdutor/codificador de torque posicionado no centro e um dinamômetro à direita, além de componentes eletrônicos de controle que não estão visíveis na figura. Os rolamentos utilizados nos testes desempenham a função de suportar o eixo do motor. Para simular anomalias, foram introduzidas falhas de ponto único nos rolamentos através da usinagem por descarga elétrica.

Figura 20. Ensaio Case Western Reserve University



Fonte: (Case Western Reserve University, 2023)

1. Os rolamentos em condições saudáveis foram testados sob diferentes cargas aplicadas ao motor. Para cada carga, a velocidade do motor foi monitorada, e dados de vibração foram coletados a taxa de amostragem de 12.000 Hz, estabelecendo linha de base fundamental para comparações com condições de falha. As cargas aplicadas variaram de 0 a 3 HP, resultando em velocidades do motor que diminuíram de (1797 a 1730 RPM) com o aumento da carga. A análise das acelerações medidas permitiu identificar variações fora do esperado para rolamentos saudáveis, que poderiam indicar o início de desgaste ou outras anomalias.
2. Rolamentos com falhas na Pista Interna, Pista Externa e elementos rolantes: Os defeitos foram introduzidos nas pistas interna e externa, assim como nos elementos rolantes, em diferentes diâmetros. Falhas de ponto único foram geradas utilizando a técnica de usinagem por descarga elétrica, com diâmetros que variavam entre 0.007 e 0.028 polegadas. Esses defeitos foram testados nas mesmas condições de carga e velocidade dos rolamentos saudáveis, permitindo a comparação direta entre os dados.
3. Testes na Extremidade do Acionamento e Ventilador: Os testes foram conduzidos tanto na extremidade do acionamento quanto na extremidade do ventilador, usando o mesmo motor Reliance Electric. Em ambos os lados, os dados de vibração foram coletados a 12.000 amostras/segundo, e as falhas



foram localizadas nas mesmas posições (pistas interna e externa e elementos rolantes), com diferentes diâmetros e profundidades.

Esses cenários experimentais permitiram análise abrangente das condições operacionais dos rolamentos, possibilitando a detecção de falhas com base em dados comparativos entre rolamentos saudáveis e aqueles com falhas conhecidas. A coleta e análise desses dados fornecem insights essenciais para a manutenção preditiva e para aumentar a confiabilidade operacional dos motores.

### 3.2.1. ESPECIFICAÇÕES DE FALHAS

A Tabela 3 oferece análise detalhada das falhas identificadas em rolamentos, apresentando informações sobre a localização da falha, o diâmetro, a profundidade e o fabricante dos rolamentos. Os dados estão organizados da seguinte maneira:

- **Local da Falha:** Especifica a localização da falha no rolamento, categorizada como "Pista Interna", "Pista Externa" ou "Elementos Rolantes", todas situadas na extremidade de acionamento ("Drive End").
- **Diâmetro:** Indica o diâmetro das falhas detectadas, com valores variando entre 0.007 e 0.028 polegadas. O diâmetro é um parâmetro fundamental para avaliar a gravidade da falha.
- **Profundidade:** Refere-se à profundidade da anomalia no rolamento, com valores listados como 0.011" e 0.050" polegadas. Esta medida é essencial para compreender o impacto da falha no desempenho do rolamento.
- **Fabricante:** Identifica o fabricante do rolamento, sendo SKF e NTN os fabricantes mencionados. A informação sobre o fabricante é relevante para identificar possíveis padrões ou problemas associados a diferentes marcas.
- Cada linha da tabela representa combinação específica de localização da falha, diâmetro, profundidade e fabricante, proporcionando visão detalhada das características das falhas detectadas em diversos tipos de rolamentos.

Tabela 3. Características das Falhas Detectadas em Rolamentos: Localização, Diâmetro, Profundidade e Fabricante

Consequência	Local da Falha	Diâmetro (polegadas)	Profundidade (polegadas)	Fabricante
Drive End	Pista Interna	0.007	0.011	SKF
Drive End	Pista Interna	0.014	0.011	SKF
Drive End	Pista Interna	0.021	0.011	SKF
Drive End	Pista Interna	0.028	0.050	NTN
Drive End	Pista Externa	0.007	0.011	SKF
Drive End	Pista Externa	0.014	0.011	SKF
Drive End	Pista Externa	0.021	0.011	SKF
Drive End	Pista Externa	0.028	0.050	NTN
Drive End	Elementos Rolantes	0.007	0.011	SKF
Drive End	Elementos Rolantes	0.014	0.011	SKF
Drive End	Elementos Rolantes	0.021	0.011	SKF
Drive End	Elementos Rolantes	0.028	0.050	NTN
Fan End	Pista Interna	0.007	0.011	SKF
Fan End	Pista Interna	0.014	0.011	SKF
Fan End	Pista Interna	0.021	0.011	SKF
Fan End	Pista Externa	0.007	0.011	SKF
Fan End	Pista Externa	0.014	0.011	SKF
Fan End	Pista Externa	0.021	0.011	SKF
Fan End	Elementos Rolantes	0.007	0.011	SKF
Fan End	Elementos Rolantes	0.014	0.011	SKF
Fan End	Elementos Rolantes	0.021	0.011	SKF

Fonte: (Case Western Reserve University, 2023)

### 3.2.2. COLETA E ORGANIZAÇÃO DE ARQUIVOS DE DADOS

Os dados foram coletados para rolamentos saudáveis, defeitos na extremidade do acionamento de ponto único e na extremidade do ventilador. Os dados foram coletados a 12.000 amostras/segundo para experimentos de rolamento na extremidade de acionamento. Todos os dados dos rolamentos das extremidades do ventilador foram coletados a 12.000 amostras/segundo.

#### a) DADOS DE REFERÊNCIA

A Tabela 4 apresenta dados de referência normalizados para diferentes condições de carga e velocidade do motor. Os dados estão organizados com base em três variáveis principais:

- Motor Load (HP): Refere-se à carga aplicada ao motor, variando de 0 a 3 HP.
- Approx. Motor Speed (RPM): Indica a velocidade aproximada do motor em rotações por minuto (RPM), que diminui à medida que a carga aumenta.
- Normal Baseline Data: Fornece a designação dos dados de referência normalizados correspondentes a cada condição de carga e velocidade.

Os dados normalizados servem como linha de base para comparação, ajudando a identificar variações que possam indicar problemas ou alterações nas condições operacionais do motor. A análise destes dados garante a operação eficiente do motor em diferentes níveis de carga.

Tabela 4. Dados de referência normalizados para diferentes cargas e velocidades de motor

Motor Load (HP)	Approx. Motor Speed (RPM)	Normal Baseline Data
0	1797	Normal_0
1	1772	Normal_1
2	1750	Normal_2
3	1730	Normal_3

Fonte: (Case Western Reserve University, 2023)

#### b) DADOS DE FALHA DO ROLAMENTO

A Tabela 5 fornece visão detalhada dos dados de referência para rolamentos com diferentes diâmetros, potências e velocidades do motor, com análise realizada a frequência de 12.000 Hz. A tabela está organizada da seguinte forma:

- Diâmetro: Indica o diâmetro do rolamento, com os valores sendo 0.007", 0.014", 0.021" e 0.028" (polegadas).
- Potência (HP): Refere-se à carga aplicada ao motor, variando de 0 a 3 HP.
- Velocidade (RPM): Representa a velocidade do motor em rotações por minuto, que diminui conforme a carga aumenta.

- Inner Race: Identifica os dados de referência para o Inner Race, com códigos correspondentes para cada combinação de diâmetro, potência e velocidade.
- Ball: Fornece os dados de referência para a Ball Data, com códigos específicos para cada condição.

Os dados foram coletados a frequência de 12.000 Hz, proporcionando análise detalhada das características de desempenho dos rolamentos. No entanto, para as análises realizadas, frequência de 1 KHz é suficiente, pois cobre adequadamente as faixas de frequência relevantes para a detecção de rolamentos defeituosos. A tabela resultante permite comparar e avaliar como as diferentes condições operacionais afetam os dados relacionados às falhas em Inner Race e Ball, facilitando a identificação de padrões e a detecção de variações sem perda de precisão na análise.

Tabela 5. Dados de referência para Inner Race e ball (análise com frequência de 12.000 hz)

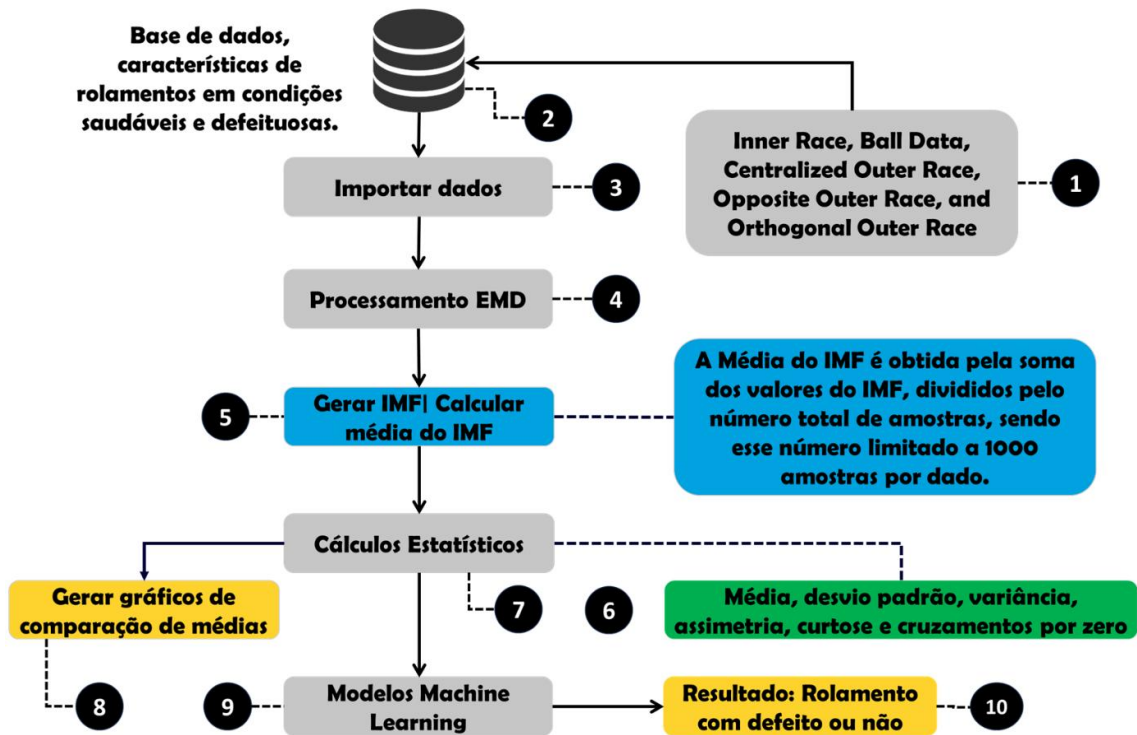
Diâmetro (polegadas)	Potência (HP)	Velocidade (RPM)	Inner Race	Ball
0.007"	0	1797	IR007_0	B007_0
	1	1772	IR007_1	B007_1
	2	1750	IR007_2	B007_2
	3	1730	IR007_3	B007_3
0.014"	0	1797	IR014_0	B014_0
	1	1772	IR014_1	B014_1
	2	1750	IR014_2	B014_2
	3	1730	IR014_3	B014_3
0.021"	0	1797	IR021_0	B021_0
	1	1772	IR021_1	B021_1
	2	1750	IR021_2	B021_2
	3	1730	IR021_3	B021_3
0.028"	0	1797	IR028_0	B028_0
	1	1772	IR028_1	B028_1
	2	1750	IR028_2	B028_2
	3	1730	IR028_3	B028_3

Fonte: (Case Western Reserve University, 2023)

### 3.3. FLUXOGRAMA METODOLOGIA PROPOSTA

As etapas apresentadas na Figura 21 detalham o processo de detecção de rolamentos defeituosos utilizando a técnica de Decomposição em Modo Empírico (EMD) combinada com análises estatísticas e aprendizado de máquina. O processo segue as seguintes fases:


Figura 21. Fluxograma Metodologia Proposta



Fonte: Autor

1. Tipos de Dados: O processo trabalha com diferentes categorias de dados relacionados a anomalias em rolamentos: Inner Race, Ball Data, Outer Race Centralizado, Outer Race Oposto e Outer Race Ortogonal localizados, conforme apresentado na Figura 22. Esses dados são extraídos de uma base experimental, permitindo a análise entre rolamentos saudáveis e defeituosos.

Figura 22. Representação das regiões de coleta de dados em rolamento de esferas



Fonte: Autor

2. Organização dos Arquivos: Os arquivos são estruturados e classificados de acordo com suas características, garantindo um fluxo eficiente para o processamento subsequente. A organização possibilita uma comparação entre as diferentes condições operacionais dos rolamentos.
3. Importação de Dados: Os dados são importados e interpretados diretamente no ambiente Google Colab, utilizando bibliotecas específicas para garantir a correta preparação para o processamento.
4. Processamento via EMD: A Decomposição de modo empírico (EMD) foi aplicada aos sinais de vibração dos rolamentos utilizando a biblioteca PyEMD. O método permite a separação do sinal em componentes fundamentais como as Funções de modo intrínseco (IMF), facilitando a análise das características vibracionais. Após essa etapa, os sinais foram submetidos a estatísticas descritivas, para a identificação de padrões que indicam falhas. O código desenvolvido para este processo segue os seguintes procedimentos:
  - 4.1 Instalação e Importação: A biblioteca PyEMD foi instalada com o comando `!pip install EMD-signal`, e outras bibliotecas auxiliares, como `numpy`, `scipy` e `matplotlib`, foram utilizadas para carregar, processar e visualizar os dados.

- 4.2 Decomposição EMD: A extração das IMFs foi realizada utilizando a função `emd.emd(x)`, onde  $x$  representa os dados de vibração. O processo resultou na decomposição do sinal em diferentes componentes, facilitando a análise de suas frequências e padrões.
- 4.3 Contribuições e Benefícios: O uso do Python e da biblioteca PyEMD aprimorou o processo de análise, proporcionando confiabilidade e eficiência na identificação de anomalias.
5. Geração de IMFs: As Funções de modo intrínseco (IMFs) geradas a partir da decomposição do sinal possibilitam a análise detalhada das frequências presentes no comportamento dos rolamentos. Cada IMF representa um componente distinto do sinal original, facilitando a detecção de falhas.
- 5.1 Análise Estatística das IMFs: Para cada IMF extraído, foram calculadas estatísticas descritivas essenciais para a caracterização do comportamento do sinal. Esses cálculos fornecem insights importantes para a diferenciação entre rolamentos saudáveis e defeituosos.
- 5.2 Visualização: Os IMFs foram plotados utilizando a biblioteca `matplotlib`, permitindo uma visualização clara dos componentes do sinal e facilitando a interpretação dos padrões vibracionais.
6. Métricas Estatísticas: Para análise quantitativa, foram definidas métricas estatísticas, incluindo média, desvio padrão, variância, assimetria, curtose e cruzamentos por zero, permitindo a identificação de padrões nos sinais de vibração.
7. Cálculos Estatísticos: As métricas calculadas foram utilizadas para avaliar o comportamento dos sinais e diferenciar entre rolamentos em condições saudáveis e defeituosas, servindo de base para a detecção de anomalias.
8. Geração de Gráficos: Gráficos comparativos foram gerados para facilitar a visualização das diferenças entre rolamentos saudáveis e com falhas. As

estatísticas extraídas possibilitam uma análise mais intuitiva dos padrões de vibração.

9. Treinamento de Modelo de Machine Learning: Os dados utilizados neste estudo foram extraídos de seis categorias distintas de condição de rolamentos: Normal, Inner Race, Ball Data, Outer Race Centralizado, Outer Race Ortogonal e Outer Race Oposto. Cada instância representa uma janela temporal de medição de vibração, sintetizada em seis métricas estatísticas: média, desvio padrão, variância, assimetria, curtose e cruzamentos por zero. Essas métricas foram selecionadas por sua relevância na descrição de comportamentos dinâmicos associados à presença de falhas em componentes rotativos, diferentes modelos de aprendizado de máquina foram treinados para classificar os rolamentos como saudáveis ou defeituosos.
10. Resultado: O processo final consiste na identificação do estado do rolamento, classificando-o como saudável ou defeituoso com base na análise dos dados processados, como acurácia, precisão, recall e F1-score, garantindo que o melhor classificador fosse selecionado para a tarefa de detecção de falhas em rolamentos.

### 3.4. DECOMPOSIÇÃO DO SINAL

#### 3.4.1. PROCESSO DA DECOMPOSIÇÃO EM MODO EMPÍRICO

- a) Identificação dos Extremos: O algoritmo começa identificando os máximos e mínimos locais do sinal original.
- b) Interpolação: linha de interpolação é criada entre os máximos e mínimos identificados para formar linha de referência.
- c) Extração da IMF: A média da linha de referência é subtraída do sinal original, resultando na primeira IMF. O processo é repetido iterativamente no resíduo até que um critério de parada seja atendido.



- d) Decomposição Contínua: O resíduo obtido após a extração de cada IMF é analisado de forma semelhante até que não se possa extrair novas IMFs.

#### 3.4.2. CARACTERÍSTICAS DAS FUNÇÕES DE MODO INTRÍNSECO

- a) Frequências Específicas: Cada IMF captura oscilações que ocorrem em faixa de frequência específica, permitindo a análise detalhada de diferentes modos de vibração presentes no sinal original.
- b) Número Variável de IMFs: O número total de IMFs geradas varia dependendo do conteúdo de frequência do sinal original e do comportamento adaptativo do algoritmo EMD. Sinais com maior complexidade de frequência tendem a produzir um maior número de IMFs.
- c) Sinal Residual: Após a extração de todas as IMFs, um sinal residual é obtido, que representa a tendência ou a média do sinal original, sendo útil para análises adicionais.

#### 3.4.3. APLICAÇÕES DA DECOMPOSIÇÃO EM MODO EMPÍRICO EM ANÁLISE DE FALHAS

A decomposição dos sinais em IMFs facilita a identificação de padrões de vibração associados a falhas específicas nos rolamentos, pois permite o monitoramento de componentes de frequência que podem ser indicativos de problemas mecânicos, como desbalanceamento, desalinhamento ou desgaste. O EMD, portanto, se torna ferramenta valiosa para a detecção de falhas e a manutenção preditiva em sistemas industriais.

#### 4. RESULTADOS PRELIMINARES OBTIDOS

Os resultados a seguir foram obtidos utilizando a metodologia proposta neste estudo. É importante destacar que a coleta de dados foi realizada com um motor elétrico Reliance de 2 hp, com medições de aceleração feitas tanto em locais próximos quanto distantes dos rolamentos do motor.

Análise do IMF demonstra a limitação do sinal em diferentes faixas de frequência:


- IMF 1 captura como componentes de alta frequência, associados a ruídos e eventos transitórios. A média de amplitude próxima de zero indica oscilações rápidas e de baixa intensidade.
- IMF 2 e IMF 3 representam frequências relevantes. Esses IMF podem refletir vibrações regulares do sistema e indicar comportamentos típicos de operação saudável.
- IMF 4 e IMF 5 mostram oscilações de baixa frequência, com amplitudes menores em relação as condições anteriores e variações lentas, indicando o comportamento estrutural e tendências de longo prazo do sistema.

As características estatísticas dos IMF reforçam a estabilidade do sistema. A análise do sinal original e das extraídas do IMF não indica desvios significativos que possam sugerir a presença de falhas ou anomalias. A amplitude ajustada em todos os gráficos, variando em torno dos valores próximos a zero, facilita a identificação de padrões vibracionais.

A ausência de picos extremos e índices por zero dentro dos valores esperados para cada IMF reforçam a normalidade operacional do rolamento analisado. Portanto, os resultados obtidos validam o comportamento típico de um sistema em condições saudáveis de operação.

A Figura 23 apresenta o sinal original e as cinco primeiras Funções de modo Intrínsecas (IMFs) extraídas de um arquivo com base de dados saudável, utilizando a técnica de Decomposição em Modo Empírico. O sinal original, representado no primeiro gráfico, encapsula toda a informação vibracional capturada, incluindo componentes de alta, média e baixa frequência, bem como possíveis transientes e ruídos.

Figura 23. Sinal Original e as Cinco Primeiras Funções de modo Intrínsecas extraídas de um arquivo em condição de saudável




Fonte: Autor

#### 4.1. EXTRAÇÃO DA FUNÇÃO DE MODO INTRÍNSECO DE DADOS SAUDÁVEIS

A Figura 24 apresenta o sinal original obtido a partir dos dados de teste de um rolamento de esfera em condições saudáveis. A técnica de (EMD) posteriormente aplicada para decompor o sinal em diferentes (IMFs). O sinal apresentado reflete diretamente o comportamento vibracional capturado, incluindo componentes de alta e baixa frequência, para análise detalhada do sistema.

Figura 24. Sinal Original - análise arquivo dados saudáveis



Fonte: Autor

#### Sinal Original Estatísticas:

- Média: 0.0715
- Desvio padrão: 0.0818
- Variância: 0.0067
- Assimetria: 0.0555
- Curtose: -0.1607
- Cruzamentos por Zero: 295

A análise estatística do sinal original demonstra características vibracionais típicas de um comportamento estável em condições saudáveis de operação. A média de 0.0715 indica que o sinal oscila acima do zero, sugerindo vibrações equilibradas. O desvio padrão de 0.0818 e a variância de 0.0067 refletem dispersão moderada e estabilidade nas vibrações.


A assimetria positiva (0.0555) apresenta leve inclinação da distribuição, indicando que as vibrações possuem tendência mínima de orientação para um dos lados. A curtose de -0.1607, revela distribuição achatada, sem a presença de picos vibracionais extremos, reafirmando a ausência de eventos críticos no sistema.

O número de cruzamentos por zero, que totaliza 295. Esses resultados apontam para condição de normalidade operacional do sistema para um sinal original,

vez que os indicadores estatísticos não apresentam variações abruptas ou comportamentos anômalos associados a falhas.

A Figura 25 exibe a primeira Função de Modo Intrínseco (IMF 1) extraída a partir dos dados de teste de um rolamento de esfera em condições saudáveis, utilizando a técnica de Decomposição em Modo Empírico (EMD). Esta IMF captura as componentes de alta frequência presentes nos sinais de aceleração.

Figura 25. Função de Modo Intrínseco 01 - análise arquivo dados saudáveis



Fonte: Autor

IMF 1 Estatísticas:

- Média: 0.00339
- Desvio padrão: 0.06031
- Variância: 0.00364
- Assimetria: -0.05380
- Curtose: -0.11099
- Cruzamentos por Zero: 254

A análise do IMF 1 referente ao arquivo com dados saudáveis demonstra características vibracionais que indicam um comportamento estável e típico de condições de operação sem falhas no rolamento. A média de 0,00339 aponta que o sinal oscila de maneira mínima ao redor do zero, indicando vibração equilibrada. O

desvio padrão de 0,06031, juntamente com a variância de 0,00364, revela baixa dispersão e estabilidade nas vibrações.


A assimetria negativa (-0.05380) sugere distribuição simétrica, decrescente que as vibrações não apresentam tendências marcantes de orientação para um dos lados. Além disso, curtose de -0,11099, próxima de zero, revela distribuição achatada, sem a presença de picos vibracionais extremos, condicionada à ausência de eventos críticos no sistema.

O número de cruzamentos por zero, que totaliza 254, sugere frequência estável nas oscilações do sinal, diminuindo um padrão vibracional regular e sem grandes flutuações. A análise reafirma a condição de normalidade operacional do sistema, vez que os indicadores estatísticos não apontam para variações pontuais ou comportamentos anômalos que possam sugerir a presença de falhas.

Os resultados obtidos do IMF 1 apresentam um comportamento estável do rolamento, com baixas variações nas vibrações, típico de um sistema em operação saudável.

A Figura 26 mostra a segunda Função de Modo Intrínseco (IMF 2), que representa as frequências intermediárias detectadas no sinal de aceleração do rolamento de esfera em condições saudáveis.

Figura 26. Função de Modo Intrínseco 02 - análise arquivo dados saudáveis



Fonte: Autor

#### IMF 2 Estatísticas:

- Média:  $-6.21487e-05$
- Desvio padrão: 0.02429
- Variância: 0.00061
- Assimetria: 0.01495
- Curtose: 0.46353
- Cruzamentos por Zero: 136


A análise do IMF 2 referente ao arquivo com dados saudáveis evidencia um comportamento vibracional da condição de operação sem falhas no rolamento. A média de  $-6.21487e-05$  sugere que o sinal oscila em torno de zero, reduz vibração equilibrada e sem desvio significativo. O desvio padrão de 0,02429, juntamente com a variância de 0,00061, aponta para dispersão reduzida, o que é característico de um sistema estável em condições saudáveis.

A assimetria progressiva positiva (0,01495) revela distribuição simétrica das vibrações, o que reforça a estabilidade do sinal. A curtose de 0,46353, sugere distribuição ao redor da média, sem a presença de picos extremos.

O número de cruzamentos por zero, que totaliza 136, sugere frequência de oscilação moderada, o que reforça a ausência de variações abruptas ou comportamentos imprevisíveis. Assim, a análise do IMF 2 corrobora o cenário de estabilidade operacional do rolamento, sem indicativos de falhas, apresentando a regularidade e a previsibilidade do comportamento vibracional observado.

Conforme a ilustrado na Figura 27 a terceira Função de Modo Intrínseco, responsável por capturar frequências baixas, associadas a padrões de vibração menos intensos do rolamento.

Figura 27. Função de Modo Intrínseco 03 - análise arquivo dados saudáveis



Fonte: Autor

#### IMF 3 Estatísticas:

- Média: -0.0005
- Desvio padrão: 0.02596
- Variância: 0.00067
- Assimetria: -0.32602
- Curtose: 0.27937
- Cruzamentos por Zero: 59

A análise do IMF 3 referente ao arquivo com dados saudáveis complementa as observações dos modos anteriores, mantendo o padrão de comportamento estável esperado para condições saudáveis de operação do rolamento. A média de -0,0005 indica oscilação de nível negativa ao redor de zero.

O desvio padrão de 0,02596 e a variância de 0,00067 apontam para dispersão um pouco maior em comparação com os modos anteriores, dentro da faixa que indica estabilidade vibracional. Essas medidas continuam a demonstrar que as variações do sinal são controladas.

A assimetria de -0,32602 revela um nível de influência negativa na distribuição das vibrações, os valores tendem a se concentrar abaixo da média. Isso não indica a presença de falhas, mas sim pequena variação no comportamento vibracional que se




encontra dentro dos limites esperados para operação saudável. A curtose de 0,27937, por sua vez, aponta para distribuição levemente experimentada, sem a ocorrência de picos extremos.

O número de cruzamentos por zero, que totaliza 59, é menor do que os modos anteriores, indicando que esta captura do IMF possui oscilações de frequências baixas, compatíveis com o comportamento saudável do rolamento.

O IMF 3 reflete condição de operação estável e regular, sem acusações de falhas, e reforça as observações dos IMFs anteriores, que indicam que o rolamento está operando de maneira consistente em condições saudáveis.

A Figura 28 ilustra a quarta Função de Modo Intrínseco (IMF 4), que concentra frequências baixas, proporcionando visão clara das características de vibração de médio a longo prazo do rolamento em condições saudáveis

Figura 28. Função de Modo Intrínseco 04 - análise arquivo dados saudáveis



Fonte: Autor

IMF 4 Estatísticas:

- Média: -0.00104
- Desvio padrão: 0.02522
- Variância: 0.00064
- Assimetria: -0.17419
- Curtose: -0.57612

- Cruzamentos por Zero: 26

A análise do IMF 4 referente ao arquivo com dados saudáveis complementa as observações dos modos anteriores, mantendo o padrão de comportamento estável esperado para condições saudáveis de operação do rolamento. A média de -0,00104 indica oscilação negativa em torno de zero, indicando um sinal equilibrado.

O desvio padrão de 0,02522 e a variância de 0,00064 indicam dispersão um pouco maior em comparação com os modos anteriores, mas ainda dentro da faixa que sugere estabilidade vibracional. Essas medidas continuam a demonstrar que as variações do sinal são controladas, sem evidências de comportamentos anômalos.


A assimetria de -0,17419 revela um nível de influência negativa na distribuição das vibrações, diminuindo que os valores tendem a se concentrar abaixo da média. Há pequena variação no comportamento vibracional que permanece dentro dos limites esperados para operação saudável. A curtose de -0,57612, por sua vez, indica distribuição moderadamente achatada, sem a presença de picos extremos.

O número de cruzamentos por zero, que totaliza 26, é menor do que os modos anteriores, indicando que o IMF possui oscilações de frequência menores, compatíveis com o comportamento saudável do rolamento.

O IMF 4 reflete condição de operação estável e regular, sem compromissos de falhas, reforçando as observações dos IMFs anteriores, que indicam que o rolamento está operando de maneira consistente em condições saudáveis.

A Figura 29 apresenta a quinta Função de Modo Intrínseco (IMF 5), destacando as componentes de frequências baixas e constantes, que refletem as tendências de vibração de longo prazo no teste de rolamento de esfera saudável.

Figura 29. Função de Modo Intrínseco 05 - análise arquivo dados saudáveis



Fonte: Autor

#### IMF 5 Estatísticas:

- Média:  $6.46637 \times 10^{-5}$
- Desvio padrão: 0.00760
- Variância:  $5.76698 \times 10^{-5}$
- Assimetria: 0.01635
- Curtose: -0.74497
- Cruzamentos por Zero: 13

A análise do IMF 5 do arquivo com dados saudáveis, segue as observações feitas nos modos anteriores. A média de  $6,46637 \times 10^{-5}$  demonstra que o sinal permanece próximo de zero, mantendo o comportamento equilibrado, característico de condições saudáveis de operação.

O desvio padrão de 0,00760 e a variância de  $5,76698 \times 10^{-5}$  indicam menor dispersão em comparação ao IMF 4, indicando maior estabilidade nas variações do sinal. Esses resultados reforçam a consistência vibracional típica de um rolamento em boas condições operacionais.

A assimetria de 0,01635 é praticamente nula, indicando distribuição simétrica das vibrações, sem tendência significativa para valores acima ou abaixo da média.

Esse comportamento sugere que o rolamento continua a operar de maneira uniforme e estável, sem sinais de irregularidades.

A curtose de -0,74497 aponta para distribuição levemente achatada, indicando a ausência de picos ou extremos significativos, o que é esperado em um sinal vibracional estável.

O número de cruzamentos por zero, totalizando 13, é menor em relação aos IMFs anteriores, refletindo oscilações de frequência baixas. Apesar disso, essas oscilações são compatíveis com o comportamento saudável do rolamento, caracterizando operação estável.

#### 4.2. EXTRAÇÃO DA FUNÇÃO DE MODO INTRÍNSECO DE DADOS COM FALHA

A Figura 30 apresenta o sinal original e as cinco primeiras Funções de modo Intrínsecas (IMFs) extraídas do arquivo que corresponde a condição de anomalia no Inner Race, com diâmetro de 0.007 polegadas, utilizando a técnica de Decomposição em Modo Empírico (EMD). O sinal original encapsula ampla gama de frequências, refletindo tanto as vibrações regulares do sistema quanto as oscilações anômalas associadas à falha no componente.


A decomposição do sinal em diferentes IMFs permite análise detalhada das contribuições em distintas faixas de frequência:

- IMF 1 captura componentes de alta frequência, que podem estar associadas a impactos súbitos ou ruídos amplificados por irregularidades no sistema. A amplitude elevada indica a presença de eventos transitórios anormais.
- IMF 2 e IMF 3 evidenciam frequências intermediárias, que podem refletir oscilações decorrentes de vibrações regulares combinadas com perturbações provenientes da falha. Esses IMFs destacam padrões que diferem daqueles esperados em condições saudáveis.
- IMF 4 e IMF 5 apresentam oscilações de baixa frequência, associadas a componentes estruturais do sistema. Nesses IMFs, as amplitudes maiores

podem ser indicativas de efeitos de longo prazo ou degradação progressiva causada pela falha.

A análise estatística dos IMFs demonstra variações significativas, indicando um comportamento atípico do sistema. Amplitudes altas e um número elevado de cruzamentos por zero refletem a instabilidade causada pela falha. Além disso, a presença de picos vibracionais extremos em algumas IMFs reforça a existência de eventos críticos, típicos de condições de falha.

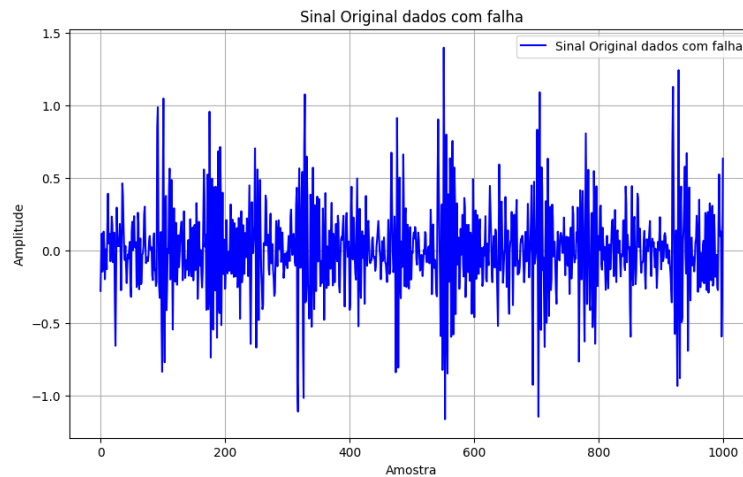
Figura 30. Sinal Original e as Cinco Primeiras Funções de modo Intrínsecas extraídas de um arquivo em Condição de Falha com diâmetro de 0.007 polegadas



Fonte: Autor

A Figura 31 apresenta o sinal original obtido a partir dos dados de teste de um rolamento de esfera em condições saudáveis, considerando as primeiras 1000 amostras. A técnica de (EMD) será posteriormente aplicada para decompor o sinal em diferentes (IMFs). O sinal apresentado reflete diretamente o comportamento vibracional capturado, incluindo componentes de alta e baixa frequência, para análise detalhada do sistema.

Figura 31. Sinal Original - análise arquivo dados com falha



Fonte: Autor

#### Sinal Original Estatísticas:


- Média: 0.0056
- Desvio padrão: 0.2910
- Variância: 0.0847
- Assimetria: 0.1434
- Curtose: 2.6602
- Cruzamentos por Zero: 588

A análise estatística do sinal original apresenta características vibracionais típicas de um sistema operando em condições de falha. A média de 0.0056 indica que o sinal oscila acima do zero, sugerindo vibrações equilibradas, enquanto o desvio padrão de 0.2910 e a variância de 0.0847 refletem dispersão significativa nos dados, indicando maior instabilidade vibracional.

A assimetria positiva (0.1434) sugere leve inclinação na distribuição dos valores, indicando que as vibrações possuem tendência de orientação para um dos lados. A curtose de 2.6602, superior ao esperado em condições saudáveis, indica a presença de picos e variações no sinal, associadas a eventos vibracionais anômalos. O número de cruzamentos por zero, totalizando 588, aponta para um padrão vibracional consistente com a presença de falhas, reafirmando a condição de operação anômala do sistema. Esses resultados refletem variações e comportamentos anômalos.

A Figura 32 exibe a primeira Função de Modo Intrínseco (IMF 1) extraída a partir dos dados de teste de um rolamento de esfera em condições defeituosas, utilizando a técnica Decomposição em Modo Empírico (EMD). Esta IMF captura as componentes de alta frequência presentes nos sinais de aceleração.

Figura 32. Função de Modo Intrínseco 01 - análise dados com falha em diâmetro de 0.007 polegadas



Fonte: Autor

#### IMF 1 Estatísticas:

- Média: -0.00404
- Desvio Padrão: 0.25856
- Variância: 0.06685
- Assimetria: -0.01673
- Curtose: 2.11652
- Cruzamentos por Zero: 545

A análise do IMF 1 do arquivo que contém dados de falha e características do comportamento vibracional do rolamento. A média de -0,00404 sugere leve oscilação negativa em torno de zero, indicativo inicial de comportamento anômalo. O valor negativo aponta para tendência de queda no sinal, não implica, por si só, em um desvio significativo.

O desvio padrão de 0,25856 e a variância de 0,06685 indicam dispersão significativa dos dados, sugerindo instabilidade vibracional maior em comparação aos

dados saudáveis. Esses valores estão associados à presença da anomalia no rolamento, resultando em variações acentuadas no comportamento do sinal.


A assimetria de -0,01673 mostra que a distribuição das vibrações é próxima de simétrica, sem grandes desvios em direção a valores positivos ou negativos. Isso sugere que o comportamento vibracional anômalo não está concentrado em direção específica, mantendo distribuição relativamente equilibrada, apesar da falha.

A curtose de 2,11652 revela a presença de picos na distribuição, indicando que há eventos vibracionais, o que é consistente com a condição de falha. Os picos indicam variações no sinal, as quais estão associadas à falha no rolamento.

O número de cruzamentos por zero, que totaliza 545, é maior do que o observado em condições saudáveis. Esse valor indica maior frequência de oscilação, indicativo de anomalia no rolamento, já que maior taxa de cruzamentos por zero está associada a sinais de instabilidade. Os dados estatísticos do IMF 1 indicam condição de falha no rolamento, caracterizada por maior dispersão dos dados, presença de picos na distribuição e aumento na frequência das oscilações.

A Figura 33 mostra a segunda Função de Modo Intrínseco (IMF 2), que representa as frequências intermediárias detectadas no sinal de aceleração do rolamento de esfera em condições defeituosas.

Figura 33. Função de Modo Intrínseco 02 - análise dados com falha em diâmetro de 0.007 polegadas



Fonte: Autor



#### IMF 2 Estatísticas:

- Média: 0.00081
- Desvio Padrão: 0.11805
- Variância: 0.01394
- Assimetria: -7.23749e-05
- Curtose: 1.73983
- Cruzamentos por Zero: 265

A análise do IMF 2 do arquivo que contém dados de falha, apresenta média de 0,00081, indicando que o sinal oscila em torno de zero com pouca variação. O valor próximo de zero indica um comportamento estável em comparação ao IMF 1.

O desvio padrão de 0,11805 e a variância de 0,01394 refletem dispersão moderada dos dados. Estes valores indicam variação menor no comportamento vibracional, indicando condição um pouco estável, embora haja sinais de irregularidade no funcionamento do rolamento.


A assimetria de -7.23749e-05, aponta para distribuição das vibrações equilibrada, sem orientação relevante para valores positivos ou negativos. Isso sugere que o comportamento anômalo do rolamento não depende da direção específica.

A curtose de 1.73983 apresenta menores picos quando comparada ao IMF 1. A curtose baixa indica que os eventos vibracionais são menos extremos, embora existam variações que estão relacionadas a falha.

O número de cruzamentos por zero, 265, revela oscilação reduzida em relação ao IMF 1. Um menor número de cruzamentos por zero sugere menor instabilidade, embora haja alterações no comportamento vibracional.

A Figura 34 apresenta a terceira Função de Modo Intrínseco (IMF 3), responsável por capturar frequências baixas, associadas a padrões de vibração menos intensos do rolamento.

Figura 34. Função de Modo Intrínseco 03 - análise dados com falha em diâmetro de 0.007 polegadas



Fonte: Autor

#### IMF 3 Estatísticas:

- Média: -0.00139
- Desvio Padrão: 0.06815
- Variância: 0.00464
- Assimetria: -0.02536
- Curtose: 0.09669
- Cruzamentos por Zero: 123

A análise do IMF 3 apresenta média de -0,00139, indicando um nível de oscilação negativa em torno de zero. Esse valor indica um comportamento vibracional caracterizado por tendência de queda no sinal.

O desvio padrão de 0,06815 e a variância de 0,00464 indicam dispersão relativamente menor em comparação aos IMFs anteriores, o que reflete variação reduzida no comportamento vibracional. O sinal é estável nesta fase da inspeção, potencialmente implicando que falha detectada está em um estágio inicial, com menores impactos sobre o sistema.

A assimetria de -0,02536 aponta para distribuição inclinada para valores negativos, apontando distribuição próxima de simétrica. A característica indica que as variações do comportamento vibracional não se concentram em direção específica.

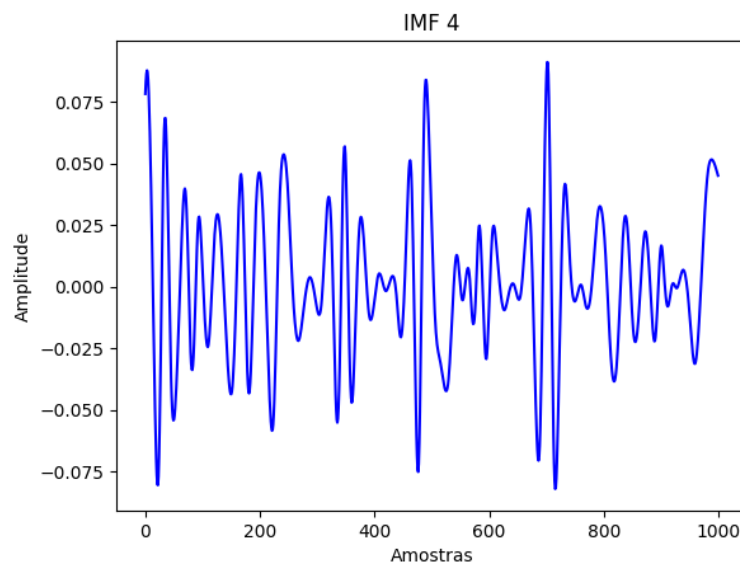
A curtose de 0,09669 revela distribuição com poucos picos, o que sugere que os eventos vibracionais são suaves e menos extremos do que nos IMFs anteriores.

O número de cruzamentos por zero, 123, é menor em comparação com análises anteriores. Isso indica menor frequência. Embora a frequência de cruzamentos por zero tenha diminuído, a presença de oscilações contínuas reforça a presença de falha.

Em suma, os resultados estatísticos do IMF 3 indicam que as falhas nos rolamentos são presentes.

A Figura 35 ilustra a quarta Função de Modo Intrínseco (IMF 4), que concentra frequências baixas, proporcionando visão clara das características de vibração de médio a longo prazo do rolamento em condições defeituosas.

Figura 35. Função de Modo Intrínseco 04 - análise dados com falha em diâmetro de 0.007 polegadas



Fonte: Autor

#### IMF 4 Estatísticas:

- Média: 0.00140
- Desvio Padrão: 0.03027
- Variância: 0.00092
- Assimetria: 0.10743
- Curtose: 0.38268
- Cruzamentos por Zero: 62

A análise do IMF 4 apresenta média de 0,00140, indicando um deslocamento positivo no sinal vibracional em torno de zero. Esse valor indica um comportamento vibracional caracterizado por tendência de elevação sem sinal, o que indica variação estável.

O desvio padrão de 0,03027 e a variância de 0,00092 evidenciam dispersão baixa, indicando que as flutuações do sinal são pequenas e o comportamento vibracional é estável.


A assimetria de 0,10743 indica distribuição levemente inclinada para o lado positivo, mostrando que, o sinal apresenta predominância de valores progressivos acima da média. A característica reflete um comportamento vibracional consistente, sem variações abruptas.

A curtose de 0,38268 revela distribuição achatada, indicando que os eventos vibracionais são menos intensos e que os picos são menos frequentes. Isso reforça que o sistema não está apresentando oscilações extremas.

Com 62 cruzamentos por zero, o IMF 4 exibe frequência de oscilação moderada, inferior a outros modos. Embora o número de cruzamentos seja reduzido, ele revela a presença de vibrações contínuas, indicando que o sistema está sujeito a oscilações. Os resultados obtidos no IMF 4 indicam um comportamento vibracional estável, com baixa variabilidade e oscilações de menor intensidade.

A Figura 36 apresenta a quinta Função de Modo Intrínseco (IMF 5), destacando as componentes de frequências baixas e constantes, que refletem as tendências de vibração de longo prazo no teste de rolamento de esfera defeituoso.

Figura 36. Função de Modo Intrínseco 05 - análise dados com falha em diâmetro de 0.007 polegadas



Fonte: Autor

#### IMF 5 Estatísticas:

- Média: -0.00123
- Desvio Padrão: 0.01479
- Variância: 0.00022
- Assimetria: -0.21919
- Curtose: 0.26191
- Cruzamentos por Zero: 27

A análise das características do IMF 5 revela média de -0,00123, indicando um nível de oscilação negativa em torno de zero. Embora esse valor indique pequena tendência de queda, ele não apresenta um desvio significativo, apontando para um comportamento estável.

O desvio padrão de 0,01479 e a variância de 0,00022 indicam dispersão baixa dos dados, indicando que as variações no comportamento vibracional são reduzidas. Esses valores mostram que, em comparação com outros modos, o IMF 5 captura oscilações de menor amplitude.

A assimetria de -0,21919 indica que a distribuição está inclinada para o lado negativo, indicando que os valores de vibração tendem a se concentrar abaixo da média.

A curtose de 0,26191 indica que a distribuição é achatada, com menos picos em comparação com as distribuições normais. As oscilações no IMF 5 são suaves, com eventos vibracionais menos extremos.

Com 27 cruzamentos por zero, o IMF 5 apresenta baixa frequência de oscilações. A baixa taxa de índices sugere que, nesse modo, o sistema apresenta variações de menor intensidade e menor frequência, diferentes dos modos de alta frequência, como o IMF 1, que apresenta maior instabilidade.

Os dados estatísticos do IMF 5 indicam condição de falha incipiente no rolamento, caracterizada por baixa dispersão e frequência de oscilações. A leve assimetria negativa e a curtose achatada reforçam a ideia de um comportamento vibracional relativamente estável.

A análise estatística das vibrações revela padrões distintos entre condições saudáveis e com falhas em rolamentos. Em condições saudáveis, as vibrações apresentam baixa amplitude, variabilidade reduzida e distribuição simétrica. Com a introdução de anomalias, observa-se um aumento na variabilidade e na assimetria das vibrações

A presença de picos de vibração, evidenciada pela alta curtose, indicam eventos extremos associados às falhas. Esses resultados sugerem que a análise estatística das vibrações é ferramenta para a detecção de anomalias em rolamentos, permitindo a implementação de ações a identificar defeitos em rolamentos.

#### 4.3. COMPARAÇÃO DE MÉTRICAS ESTATÍSTICAS DAS FUNÇÕES DE MODOS INTRÍNSECOS DE DADOS SAUDÁVEIS ENTRE DADOS COM FALHAS EM DIFERENTES FREQUÊNCIAS

A comparação do IMF 1 com os demais IMFs na base saudável do rolamento ou na base com falhas, revela a relevância do primeiro modo na captura das componentes de alta frequência e sua relação com o comportamento vibracional do sistema. O IMF 1 destaca-se por apresentar maior amplitude em relação aos outros modos, com exceção da Assimetria indicando as vibrações principais, características do estado de operação, estão concentradas neste primeiro componente. Os modos subsequentes (IMF 02 a IMF 05), embora forneçam informações importantes,

apresentam valores médios menores, sugerindo que as suas contribuições estão relacionadas a flutuações de baixa frequência ou ruídos no sistema.

A comparação entre os dados saudáveis e com falha reforça a importância de observar as diferenças nos IMFs para identificar falhas operacionais. No IMF 1, as discrepâncias marcantes entre os dois conjuntos de dados evidenciam a sensibilidade deste modo à presença de anomalias. À medida que se analisa os modos subsequentes, as diferenças tornam-se menos acentuadas, mas ainda perceptíveis, indicando mudanças no comportamento vibracional ao longo das frequências. A análise comparativa é essencial para destacar como os dados de vibração em condições saudáveis e com falhas se diferenciam em nível estrutural, fornecendo informações para a detecção de anomalias.

A Figura 37 ilustra a comparação entre a média dos sinais de vibração obtidos de dados saudáveis e dados com falha em diferentes Funções de Modo Intrínseco (IMFs). O eixo horizontal mostra os cinco IMF (IMF 01 a IMF 05), enquanto o eixo vertical representa os valores médios correspondentes, variando entre valores positivos e negativos.

No IMF 01, observa-se diferença significativa entre os dois tipos de dados. Os dados saudáveis apresentam média positiva, enquanto os dados com Falha, média negativa. A divergência indica mudança no comportamento vibracional, indicando a presença da anomalia nos dados com falha.

No IMF 02, as médias para os dados saudáveis e com falha são próximas de zero, No entanto, a média dos dados com anomalia é maior, indicando variação no sinal de falha em comparação aos dados do rolamento saudável.


O IMF 03 exibe médias negativas para ambos os tipos de dados, com os dados com anomalia mostrando amplitude negativa maior. Esse comportamento indica um nível de manipulação no rolamento, refletido na amplitude negativa dos sinais.

Para o IMF 04, observa-se que a média dos dados saudáveis é negativa e menor em relação aos dados com Falha, que apresenta um valor positivo, com maior amplitude. Existe a alteração nas características vibracionais, embora menos expressiva do que nos IMFs anteriores.

No IMF 05, existe a diferença entre os dois tipos de dados. Os dados saudáveis apresentam média positiva, enquanto os dados com falha apresentam média negativa.

O gráfico demonstra como as médias dos sinais de vibração variam ao longo dos diferentes IMFs, proporcionando visão comparativa importante entre dados saudáveis e com falha.

Figura 37. Análise comparativa da estatística média entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

A Figura 38 ilustra a comparação entre os desvios padrão dos sinais de vibração obtidos de dados saudáveis e com falhas, representados em diferentes Funções de Modo Intrínseco (IMFs).

No IMF 01, há diferença marcante entre os dados saudáveis e com anomalias. O desvio padrão dos dados com falha é maior do que o dos dados saudáveis, indicando maior variabilidade e instabilidade no comportamento vibracional, característica típica de um sistema com anomalias.

No IMF 02, observa-se um aumento específico no desvio padrão dos dados com falha em comparação com os dados saudáveis, diminuindo que o sistema com anomalias começa a mostrar variações amplas nesse modo de variação.




O IMF 03 apresenta diferença moderada, significativa, entre os dois conjuntos de dados. O desvio padrão dos dados com falha é superior, refletindo oscilações amplas e um comportamento anômalo sem sinal de anomalia.

Para o IMF 04, os dados saudáveis e com anomalia mostram diferença menor no desvio padrão, embora o desvio nos dados com falha seja maior, apontando pequena alteração nas características vibracionais.

No IMF 05, ambos os dados saudáveis e com falhas apresentam desvios padrão. No entanto, os dados com anomalia demonstram um nível elevado na variabilidade, o que sugere que, mesmo nos modos de menor frequência, o comportamento anômalo persiste, embora em menor intensidade.

O gráfico fornece visão clara sobre como a dispersão dos sinais de vibração varia ao longo dos diferentes IMFs, revelando que as falhas no sistema resultam em maior variabilidade, especialmente nos modos iniciais (IMF 01 e IMF 02).

Figura 38. Análise comparativa da estatística Desvio Padrão entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

A Figura 39 ilustra a comparação entre a variação dos sinais de vibração obtidos de dados saudáveis e com falhas, representados em diferentes Funções de Modo Intrínseco (IMFs). A variância mede a dispersão dos dados em torno da média, sendo um indicador importante da instabilidade do comportamento vibracional do sistema.

No IMF 01, observa-se diferença marcante entre os dois conjuntos de dados. A variação dos dados com anomalias é maior do que a dos dados saudáveis, resultando em maior dispersão e, conseqüentemente, a instabilidade no comportamento vibracional. Isso é característico de um sistema que apresenta falhas, onde as oscilações tornam-se amplas e irregulares.

No IMF 02, há um aumento notável na variação dos dados com falha em comparação aos dados saudáveis. A diferença indica que o sistema falho apresenta variações amplas no sinal, refletindo alteração nas condições de operação do rolamento.


No IMF 03, a variação entre os dados saudáveis e com falha é menos acentuada, significativa. A variação dos dados com anomalia é maior, indicando a presença de oscilações amplas, embora o impacto seja menor do que nos IMFs anteriores.

No IMF 04, a diferença na variação entre os dados saudáveis e com falha é pequena. Apesar disso, os dados com anomalias continuam apresentando maior variabilidade, o que indica que, mesmo com oscilações suaves, o comportamento vibracional anômalo pode ser detectado.

No IMF 05, tanto os dados saudáveis quanto os com falha apresentam baixas variações. No entanto, os dados com anomalia mostram um nível maior de dispersão, indicando que, mesmo nas frequências baixas, o sistema com falha exibe um comportamento anômalo, embora em menor intensidade.

O gráfico fornece visão da variância dos sinais de vibração, e como varia ao longo dos diferentes IMFs, revelando que as falhas resultam em maior dispersão dos dados, especialmente nos modos de maior frequência (IMF 01 e IMF 02), onde as variações vibracionais são pronunciadas.

Figura 39. Análise comparativa da estatística Variância entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

A Figura 40 apresenta comparação entre a assimetria dos sinais de vibração de dados saudáveis e com anomalia, representando cinco Funções de Modo Intrínseco (IMFs). A assimetria indica a distribuição dos dados em relação à média, refletindo se há predominância de valores positivos ou negativos.

No IMF 01, ambos os dados saudáveis e com falha exibem assimetria negativa. No entanto, a assimetria nos dados saudáveis possui maior amplitude. A assimetria negativa aponta para predominância de valores abaixo da média.

No IMF 02, a assimetria dos dados saudáveis e com falha é muito próxima de zero, indicando distribuição equilibrada em torno da média para ambos os casos. Isso sugere que, nesse sentido, não há especificação significativa nos sinais, e o comportamento vibracional é simétrico.

Para o IMF 03, observa-se assimetria negativa nos dados saudáveis, com amplitude maior, enquanto os dados com falha mostram assimetria negativa próxima de zero.


No IMF 04, a assimetria nos dados saudáveis é acentuadamente negativa, enquanto os dados com falha mostram visão positiva. A mudança indica mudança

clara no comportamento vibracional entre os dois estados. Nos dados saudáveis, o sistema tende a oscilar abaixo da média, enquanto nos dados com falha, a orientação é oposta, com maior concentração de valores acima da média.

No IMF 05, os dados saudáveis apresentam assimetria positiva, já os dados com anomalia, apresentam a assimetria negativa, com magnitude maior. Nos modos de menor frequência, os sinais de falha tendem a indicar um nível de orientação para valores negativos no comportamento vibracional.

A assimetria varia ao longo dos diferentes IMFs, fornecendo visão sobre as mudanças nas distribuições dos sinais de vibração quando o sistema opera com falhas. Essas mudanças na direção dos sinais são indicativas de mudanças no comportamento vibracional, principalmente em modos como o IMF 04 e IMF 05, onde a inversão de sinal é evidente.

Figura 40. Análise comparativa da estatística Assimetria entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

A Figura 41 ilustra a comparação da curtose dos sinais de vibração obtidos de dados saudáveis e com anomalias, representados em diferentes Funções de Modo Intrínseco (IMFs). A curtose é medida da distribuição dos dados.

No IMF 01, há diferença expressiva entre os dados saudáveis e os dados com anomalias. Enquanto os dados saudáveis apresentam curtose negativa próxima de zero. Os dados com falha exibem curtose elevada, indicando a presença de eventos vibracionais intensos e picos frequentes no comportamento do rolamento em falha. Esse aumento na curtose é um indicativo de um comportamento anômalo, onde as vibrações são bruscas e extremas.

No IMF 01, a curtose dos dados saudáveis é baixa, enquanto a curtose dos dados com falha é elevada, o que reforça a presença de variações e picos pronunciados no sinal vibracional do sistema com Falha. Esse padrão indica que o rolamento em falha está sujeito a eventos vibracionais.


No IMF 03, a diferença de curtose entre os dois conjuntos de dados diminuiu. A curtose nos dados saudáveis e com falha são positivas, os valores são menores do que nos IMFs anteriores, indicando que as variações vibracionais estão distribuídas e com menor concentração de picos.

No IMF 04, os dados saudáveis apresentam curtose negativa, enquanto os dados com falha exibem curtose positiva. Isso sugere que, nos dados saudáveis, os picos são menos frequentes, enquanto os dados com falha mostram a presença de eventos vibracionais concentrados, embora com menor intensidade do que nos IMFs de maior frequência.

No IMF 05, os dados saudáveis apresentam curtose negativa, indicando que os picos são menos recorrentes do que em distribuição padrão. Por outro lado, os dados de falha apresentam curtose positiva, sugerindo a ocorrência de eventos vibracionais concentrados, embora com menor intensidade em comparação aos IMFs de frequências elevadas.

As curtoses dos dados com anomalias são maiores nos primeiros IMFs, indicando a presença de picos frequentes e oscilações bruscas, características típicas de um sistema em falha. Já nos IMFs de menor frequência, a curtose dos dados saudáveis tende a ser negativa, indicando oscilações suaves, o que é esperado em condições de operação estáveis.

Figura 41. Análise comparativa da estatística Curtose entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

A Figura 42 apresenta comparação entre os cruzamentos por zero dos sinais de vibração obtidos de dados saudáveis e com falhas, em diferentes Funções de Modo Intrínseco (IMFs). O número de cruzamentos por zero reflete a frequência com que o sinal atravessa o eixo horizontal (valor zero), sendo um indicador de instabilidade e oscilação do sistema.

No IMF 01, observa-se diferença significativa entre os dois conjuntos de dados. Os dados com falha apresentam um número maior de cruzamentos por zero (de 500), em comparação com os dados saudáveis, que têm aproximadamente 250 cruzamentos. Esse aumento acentuado no número de cruzamentos sugere instabilidade maior no sinal, característica de um sistema com anomalias, onde as oscilações são frequentes e desordenadas.

No IMF 02, os cruzamentos por zero são frequentes nos dados com anomalias, com cerca de 300 cruzamentos, enquanto os dados saudáveis apresentam valor próximo de 150. Esse comportamento indica que, mesmo em modos de frequência baixa, o sistema com falha continua a apresentar um padrão de oscilação intenso, refletindo a presença da anomalia incipiente no rolamento.


O IMF 03 mostra diferença moderada entre os dois conjuntos de dados. Embora os dados com falha apresentem um número maior de cruzamentos por zero (aproximadamente 150), os dados saudáveis possuem cerca de 60 cruzamentos, o que indica que, nesse modo, o comportamento oscilatório é menos pronunciado em ambos os estados.

No IMF 04, o número de índices por zero é relativamente baixo para ambos os conjuntos de dados. Os dados com falha apresentam um número maior de cruzamentos do que os dados saudáveis, o que sugere que, apesar de ser um modo de frequência baixo, a presença da anomalia gera oscilações, embora em menor intensidade.

No IMF 05, tanto os dados saudáveis quanto os com anomalia apresentam menor quantidade de cruzamentos por zero, refletindo um padrão de oscilação estável. Os dados com falha mostram um número maior de cruzamentos, a diferença entre os dois conjuntos de dados é pequena, indicando que as oscilações são menos frequentes e suaves nos modos de frequência baixa.

Os cruzamentos por zero são frequentes nos dados com anomalias, especialmente nos primeiros IMFs (IMF 01 e IMF 02). Esse aumento no número de cruzamentos está diretamente relacionado à maior instabilidade do sistema em falha, onde as oscilações se tornam frequentes e desordenadas. Nos IMFs de menor frequência, as diferenças entre os dois conjuntos de dados são menos pronunciadas, indicando um comportamento vibracional estável.

Figura 42. Análise comparativa da estatística Cruzamentos por Zero entre Funções de Modo Intrínseco em dados saudáveis e com falhas



Fonte: Autor

#### 4.4. COMPARAÇÃO DA PRIMEIRA FUNÇÃO DE MODO INTRÍNSECO ENTRE DADOS SAUDÁVEIS E DADOS COM FALHAS EM DIFERENTES DIÂMETROS

A análise do impacto das falhas de 0,007 polegadas apresenta maior complexidade de serem distinguidas em termos de média vibracional, vez que apresentam valores médios com menor amplitude quando comparado aos dados saudáveis. Esse comportamento ocorre devido a severidade da falha ser pequena, o que não resulta em alterações nas vibrações globais. Em contrapartida, os diâmetros maiores, como 0,014, 0,021 e 0,028 polegadas, apresentam um aumento evidente no desvio padrão, variância e curtose, indicando instabilidade e a presença de picos vibracionais.

A análise dos modos intrínsecos (IMFs), em especial o IMF 1, demonstra sua alta sensibilidade às falhas, apresentando maior amplitude nas condições com anomalias. Esse comportamento auxilia na distinção entre diferentes condições de falha e entre condições dados saudáveis e defeituosas. A diferença nas amplitudes do IMF 1 para anomalias de 0,007 e 0,028 polegadas sugere que o componente é ferramenta útil para identificar a anomalia. Além disso, ao utilizar a média das



estatísticas dos IMFs, é possível obter visão geral das características globais das vibrações. A abordagem simplifica a interpretação dos dados, tornando evidentes os impactos das falhas.

Embora a anomalia de menor diâmetro (0,007 polegadas) possa não se diferenciar drasticamente das condições dados saudáveis em algumas métricas, a análise estatística detalhada, combinada com a decomposição em IMFs, permite identificar mudanças no comportamento vibracional. As falhas de diâmetros maiores (0,014, 0,021 e 0,028 polegadas) apresentam padrões claros de instabilidade e picos vibracionais, facilitando a distinção entre condições saudáveis e defeituosas. Assim, é possível diferenciar essas condições de forma confiável, desde que se utilizem métodos estatísticos robustos e análise detalhada dos IMFs.

Portanto, a identificação de anomalias menores, como de 0,007 polegadas, é fundamental para prever o desenvolvimento de falhas expressivas. A análise estatística detalhada, aliada ao uso de ferramentas como o IMF, torna possível monitorar a progressão das condições do sistema. Com isso, reduzindo o risco de anomalias graves e otimizando a confiabilidade da análise.


A Figura 43 apresenta a sobreposição do IMF 1 para dados saudáveis, falhas com diâmetro de 0,007 polegadas e falhas com diâmetro de 0,028 polegadas. A análise da Figura destaca a sensibilidade do IMF 1 em captar as diferenças vibracionais entre as condições saudáveis e com anomalias. O sinal correspondente à condição saudável do rolamento, representado em azul, exibe amplitudes regulares e de menor magnitude, refletindo a estabilidade do sistema em condições saudáveis de operação.

Já o sinal associado à anomalia de 0,007 polegadas, representado em laranja, apresenta amplitudes maiores em comparação ao dado saudável. A diferença, embora sutil, indica que mesmo falhas de menor severidade pode ser captadas por meio do IMF 1. Por outro lado, o sinal correspondente à anomalia de 0,028 polegadas, exibido em preto, demonstra amplitudes elevadas e variações acentuadas, evidenciando instabilidade vibracional e a presença de picos frequentes associados à maior severidade da falha.

A disposição das curvas no gráfico reforça a importância do IMF 1 na identificação de falhas incipientes e severas. A maior amplitude e dispersão

observadas no dado com anomalia de 0,028 polegadas evidencia a progressão do dano no sistema. Assim, a análise comparativa apresentada contribui para o diagnóstico e a detecção de anomalias.

Figura 43. Sobreposição da Função de Modo Intrínseco 1 entre em Dados saudáveis e com falha em Rolamentos (Diâmetros de 0,007 e 0,028 polegadas)



Fonte: Autor

#### 4.5. COMPARAÇÃO ENTRE AS FUNÇÕES DE MODO INTRÍNSECO DE ALTA E BAIXA FREQUÊNCIA EM DADOS SAUDÁVEIS E DADOS COM FALHAS

Na Figura 44, é realizada análise comparativa entre os modos intrínsecos IMF 1 e IMF 5 com os dados saudáveis revela diferenças nos parâmetros estatísticos.

A média do IMF 1 foi de 0,00339, enquanto o IMF 5 apresentou média de 0,000065. Esse contraste indica que, em termos médios, o IMF 1 tende a se afastar do valor zero em comparação com o IMF 5, o que sugere que o IMF 1 captura variações no sinal. A média no IMF 5 indica um comportamento estável e centralizado em torno de zero, indicando menor influência de eventos transitórios nesse modo.

Os valores do desvio padrão foram diferentes: 0,06031 para o IMF 1 e 0,00759 para o IMF 5. Isso reflete variabilidade maior no IMF 1, com dispersão ampla dos dados ao redor da média.

A variância, confirma a diferença com 0,00364 para o IMF 1 e 0,000058 para o IMF 5. A maior variância no IMF 1 sugere que o modo concentra a maior parte das oscilações do sinal, capturando eventos de alta frequência, relacionada a falhas incipientes em rolamentos, que apresentam variações rápidas e de alta amplitude.


A assimetria de ambos os sinais foi próxima de zero, com valores de -0,05381 para o IMF 1 e 0,01635 para o IMF 5. Isso indica que ambos os modos são simétricos em torno de suas respectivas médias, com o IMF 1 exibindo um nível de orientação negativa e o IMF 5 orientação mínima positiva.

A curtose, que mede a concentração dos dados em torno da média, foi negativa para o IMF 5 (-0,74497), enquanto o IMF 1 apresentou um valor de -0,11099. A curtose negativa no IMF 5 indica distribuição achatada, com menos picos e valores extremos, indicando que o IMF 5 captura oscilações de baixa intensidade com menos variabilidade abrupta, em contraste com o IMF 1, que exibe distribuição uniforme.

O número de cruzamentos por zero é um indicador de frequência de oscilação do sinal. O IMF 1 apresentou 254 índices, enquanto o IMF 5 teve apenas 13. A maior quantidade de índices no IMF 1 indica um sinal de alta frequência, com rápidas mudanças de polaridade, o que consistente com a presença de componentes de alta frequência relacionados a falha. Por outro lado, o IMF 5, com seus 13 cruzamentos, reflete um comportamento de baixa frequência, capturando variações lentas e suaves no sinal.

As diferenças estatísticas entre o IMF 1 e o IMF 5 indicam que esses modos capturam diferentes aspectos do comportamento vibracional dos rolamentos. O IMF 1, com maior média, variabilidade e frequência, reflete componentes de alta frequência associados a falhas dinâmicas e abruptas, enquanto o IMF 5, com sua baixa variação e frequência, pode capturar informações gerais, relacionadas a tendências lentas ou de longo prazo no comportamento do rolamento.

Figura 44. Comparação entre função de modo intrínseco 01 e função de modo intrínseco 05 na base de dados saudáveis



Fonte: Autor

Na Figura 45, é realizada comparação entre os modos intrínsecos IMF 1 e IMF 5 para dados de falha revela estatísticas do comportamento vibracional do rolamento sob condições anômalas.

A média do IMF 1 foi de -0,00404, enquanto o IMF 5 apresentou média de -0,00123. Esses valores sugerem que ambos os sinais oscilam abaixo de zero. A maior oscilação negativa no IMF 1 indica que esse modo está capturando desvios pronunciados, indicando presença forte de falhas no sistema. O IMF 5, por sua vez, apresenta um comportamento próximo de zero, o que reflete um nível baixo de oscilação e variação vibracional no sinal, que esteja inclinado para valores negativos.

Os dados com anomalias apresentam diferença notável nos desvios padrão: 0,25856 para o IMF 1 e 0,01479 para o IMF 5. Esse contraste reflete dispersão muito maior nos dados do IMF 1, indicando maior variabilidade e instabilidade no sistema sob falha.

A variância, com 0,06685 no IMF 1 e 0,00022 no IMF 5, reforça a diferença, apontando que o IMF 1 captura eventos de maior amplitude, típicos de um

comportamento vibracional desordenado e característico de um sistema com falhas severas. O IMF 5, com menor variância, indica que as oscilações neste modo são muito suaves e menos impactantes.


A assimetria do IMF 1 é de -0,01673, próxima de zero, o que indica distribuição relativamente simétrica em torno da média, embora inclinada para o lado negativo. Isso sugere que, embora a falha esteja presente, as oscilações são distribuídas de forma equilibrada. Já no IMF 5, a assimetria é acentuada ( -0,21919), indicando que há um nível de orientação para valores negativos, o que reflete pequena tendência a oscilações abaixo da média.

Quanto à curtose, o IMF 1 apresenta um valor elevado de 2,11652, o que sugere a presença de picos significativos no sinal de falha, diminuindo a ocorrência de eventos vibracionais extremos. Já no IMF 5, a curtose é de 0,26191, o que indica distribuição com menor ocorrência de picos extremos, refletindo oscilação controlada e distribuída.

No IMF 1, foram registrados 545 cruzamentos por zero, um número maior do que o apresentado no IMF 5, que apresentou apenas 27 cruzamentos. O maior número de cruzamentos por zero no IMF 1 indica maior frequência de oscilação, característica de um sinal com alta energia e variabilidade, o que é esperado em sistemas sob falha. Por outro lado, o IMF 5, reflete um sinal de baixa frequência, capturando variações lentas.

Os resultados dos parâmetros estatísticos indicam que o IMF 1 é sensível a variações de alta frequência e maior amplitude, importante para a identificação de falhas graves no sistema. O IMF 5, com seu comportamento estável, capta variações de menor impacto e auxilia em acompanhar o comportamento do rolamento em um estágio inicial de falha. A análise desses dois modos destaca a importância de considerar múltiplos IMFs para obter visão completa das anomalias em rolamentos, permitindo a detecção.

Figura 45. Comparação entre função de modo intrínseco 01 e função de modo intrínseco 05 na base de dados com falhas



Fonte: Autor

#### 4.6. COMPARAÇÃO DAS FUNÇÕES DE MODO INTRÍNSECO COM MESMA FREQUÊNCIA ENTRE DADOS SAUDÁVEIS E DADOS DE FALHAS

A Figura 46 apresenta a sobreposição dos sinais do IMF 1, comparando dados saudáveis com dados de falha. O IMF 1 é caracterizado por capturar os componentes de alta frequência do sinal, e esta visualização permite observar as diferenças na amplitude e variação do comportamento vibracional entre os dois estados.

A amplitude do sinal de falha é visivelmente maior em comparação com o sinal saudável do rolamento. Os dados com anomalia apresentam oscilações, com picos que chegam nas amplitudes positivas de 1,00 e negativas de -1,00, enquanto o sinal de dados saudáveis, se mantém concentrado dentro da faixa menor, com amplitudes que oscilam de forma contida entre 0,25 e -0,25. Esse comportamento indica que o sistema em falha está sujeito a variações bruscas e instáveis, características típicas de anomalias sem rolamento.


O sinal com anomalia apresenta maior dispersão ao longo do tempo, como evidenciado pelas oscilações amplas em relação ao sinal saudável do rolamento.

Além disso, o número de cruzamentos por zero é maior nos dados com anomalia, o que reflete maior frequência de oscilações. Essas variações evidenciam maior instabilidade no comportamento vibracional do sistema sob falha.

Por outro lado, o sinal do rolamento saudável apresenta oscilações centradas em torno de zero, com variações de baixa amplitude, o que indica que o sistema opera de forma estável sob condições normais. A estabilidade é evidenciada tanto pela menor amplitude quanto pela dispersão reduzida do sinal de vibração.

O IMF 1 é fundamental para a detecção de falhas dinâmicas, pois captura os componentes de alta frequência associados a eventos vibracionais intensos e frequentes. maior amplitude e dispersão no sinal de falha indicam que o sistema está experimentando variações anômalas, indicando um desgaste significativo ou a presença de danos no rolamento.

Figura 46. Comparação entre função de modo intrínseco 01 de dados saudáveis e função de modo intrínseco 01 de dados com Falha



Fonte: Autor

A Figura 47 ilustra a sobreposição dos sinais do IMF 5, comparando os dados saudáveis com os dados de falha. A visualização oferece análise das diferenças entre os dois estados de operação do rolamento.

O IMF 5 representa um modo de frequência baixa, e a análise evidencia que, mesmo em modos de frequência reduzidos, o comportamento vibracional do sistema é impactado pela presença da falha. O sinal de falha exibe variações amplas e frequentes em comparação ao sinal saudável do rolamento, que apresenta oscilação suave ao redor de zero.

O sinal com anomalia tem amplitude maior em relação ao sinal saudável do rolamento, o que indica maior variabilidade e instabilidade no comportamento vibracional. Enquanto o sinal saudável tende a oscilar com amplitudes moderadas, o sinal de anomalia exibe picos altos, indicando maior intensidade de vibrações quando o sistema está em condição de falha.


A dispersão dos dados com anomalias é maior, pois pode ser observada pela amplitude e variação ao longo do tempo. O sinal saudável mantém-se próximo da linha de zero, refletindo um sistema estável, enquanto o sinal com anomalia apresenta maior dispersão ao longo do eixo vertical, o que confirma a presença de um comportamento vibracional anômalo.

A sobreposição dos sinais do IMF 5 demonstra que, embora seja um modo de baixa frequência, falha no rolamento afeta o comportamento vibracional. O aumento na amplitude e dispersão do sinal com anomalia sugere que o sistema está operando com oscilações pronunciadas e frequentes, o que pode ser um indicativo de desgaste ou danos sem rolamento.

A análise confirma que o IMF 5, apesar de capturar componentes de menor frequência, é relevante para identificar variações anômalas no comportamento vibracional do sistema. O uso de diferentes IMF, incluindo os de baixa frequência, é importante para análise completa e precisa da condição dos rolamentos, permitindo a detecção de falhas em estágios iniciais ou avançados.



Figura 47. Comparação entre função de modo intrínseco 05 de dados saudáveis e função de modo intrínseco 05 de dados com Falha



Fonte: Autor

#### 4.7. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO INNER RACE

Na presente análise, foi utilizada a técnica de Decomposição em modo empírico (EMD) para decompor os sinais em diferentes componentes de frequência, como Função de Modo Intrínseco (IMFs), os quais representam as oscilações características do sinal original.

A partir da decomposição, com a utilização da média dos IMFs, foram calculadas as seguintes estatísticas: média, desvio padrão, variância, assimetria, curtose e número de cruzamentos por zero. Esses indicadores foram fundamentais para caracterizar e diferenciar os padrões vibracionais entre os rolamentos com dados saudáveis e os rolamentos com anomalia. O cálculo dessas estatísticas foi realizado, permitindo a análise quantitativa das alterações vibracionais relacionadas à presença de falhas. O processo de análise foi dividido em etapas principais:

1. Carregamento dos dados: Arquivos contendo dados de vibração de rolamentos foram organizados em duas categorias principais – dados saudáveis e dados

com falha no Inner Race. Os sinais foram processados para extrair as primeiras 1000 amostras do sinal, garantindo uniformidade nas análises.

2. Decomposição dos sinais: Os sinais foram submetidos à EMD, resultando na obtenção dos cinco primeiros IMFs para cada condição operacional.
3. Cálculo das estatísticas: Para cada IMF, foram calculados indicadores estatísticos detalhados que permitiram descrever o comportamento vibracional de forma precisa. Além disso, foi realizada a média das estatísticas dos IMFs.
  - A média fornece ideia geral das características globais dos modos de vibração (IMFs) em diferentes condições (saudáveis e com Falha).
  - A abordagem simplifica a interpretação ao reduzir a quantidade de informações no gráfico, tornando clara a comparação entre as condições analisadas.
4. Comparação entre condições: As estatísticas médias foram comparadas entre os dados saudáveis e os dados com falha em diferentes condições de RPM e para falhas com diâmetros variados.

Os gráficos gerados a partir das médias das estatísticas apresenta visualização das diferenças entre os dados saudáveis e com Falha. As comparações detalhadas são para diferentes condições de rotações por minuto (1797, 1772, 1750 e 1730 RPM) e para anomalias de diferentes diâmetros (0.007", 0.014", 0.021" e 0.028" polegadas). Esses resultados fornecem informações sobre os impactos das falhas no Inner Race e a relevância da análise estatística na detecção de anomalias incipientes.

A Figura 48 apresenta comparação detalhada entre as estatísticas dos dados saudáveis e os dados de falha no Inner Race para um rolamento com diâmetro de 0.007 polegadas de falha. Os dados de ambas as condições são analisados em termos de medidas estatísticas como média, desvio padrão, assimetria, variância e curtose.

A média dos dados saudáveis serve como um ponto de referência para entender o comportamento típico de vibração do rolamento em condições ideais. Em contraste, a média dos dados do Inner Race apresenta um deslocamento, indicando a presença de anomalias ou falhas na superfície interna do rolamento.

O desvio padrão reflete a dispersão dos dados em torno da média. Nos dados saudáveis, espera-se um desvio padrão baixo, indicando variação mínima. Para os dados do Inner Race, um aumento no desvio padrão evidência maior variabilidade no comportamento vibracional, sugerindo a existência de danos.


A assimetria mede a distribuição dos dados em relação à sua média. Para dados saudáveis, a assimetria tende a ser próxima de zero, indicando distribuição simétrica. No entanto, para o Inner Race danificado, a assimetria exibe dados diferentes de zero, refletindo inclinação da distribuição de dados, o que indica que as falhas estão causando vibrações anômalas.

A variância complementa o desvio padrão ao fornecer medida quadrática da dispersão dos dados. Valores de variância elevados para os dados do Inner Race, em comparação com os dados saudáveis, reforçam a ideia da maior variabilidade devido a falhas.

Os dados saudáveis apresentam curtose próxima de uma distribuição normal. Os dados do Inner Race exibem curtose elevada, que indica a presença de picos acentuados, presente em eventos vibracionais maiores, devido à falha.

A comparação estatística é essencial para identificar e diferenciar condições saudáveis de condições com falhas, ajudando a melhorar a detecção de anomalias em rolamentos.

Figura 48. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.007 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero. Isso ocorre porque, em condições saudáveis, a vibração do rolamento é mínima e uniforme, refletindo um funcionamento saudável do sistema. Para as falhas com diâmetro de 0.007 polegadas, as médias das vibrações em diferentes velocidades (1797, 1772, 1750 e 1730 RPM) estão próximas de zero. A similaridade sugere que, mesmo em condições de falha, as vibrações podem não aumentar drasticamente em comparação com as condições saudáveis, indicando que a severidade da falha pode não ser suficientemente alta para gerar vibrações perceptíveis em todas as velocidades. No entanto, é importante observar que, à medida que a velocidade do motor aumenta, existe a tendência de que vibrações sutis se tornem evidentes devido a interações anômalas.

O desvio padrão permanece baixo e uniforme nas condições saudáveis, reforçando a ideia de um padrão vibracional estável. O desvio padrão mostra um aumento em todas as velocidades em comparação com os dados saudáveis. No entanto, esse aumento é pronunciado nas velocidades baixas, indicando maior variabilidade nas vibrações conforme as falhas nos rolamentos se tornam severas e as interações dinâmicas se intensificam.


A variância dos dados saudáveis é mínima, demonstrando um comportamento controlado. Para os dados do Inner Race, a variância aumenta com a baixa velocidade do motor. À medida que as falhas se tornam severas, em baixas velocidades, a variância se eleva, refletindo um comportamento vibracional cada vez instável e errático.

A assimetria dos dados saudáveis é negativa e próxima de zero, diminuindo um nível de orientação à esquerda na distribuição das vibrações, o que reflete um comportamento estável e controlado. Em contrapartida, nos dados com falhas, a assimetria apresenta variação, podendo ser positiva ou negativa, sendo a única velocidade que apresenta valor positivo a de 1750 RPM. A assimetria aumenta com as anomalias, com valores elevados nas velocidades altas. Isso reflete distribuição inclinada, resultando em um padrão de vibração não simétrico devido à presença de falhas. A mudança na assimetria reflete a influência crescente das anomalias no comportamento vibracional à medida que a severidade das condições operacionais aumenta.

A curtose dos dados saudáveis é negativa e se aproxima de zero, sugerindo ausência de picos acentuados nas velocidades analisadas. A curtose dos dados com falha é elevada em todas as velocidades, especialmente nas intermediárias. A alta curtose indica presença significativa de picos de vibração, indicando eventos vibracionais extremos decorrentes das falhas na pista interna. O comportamento se torna pronunciado à medida que a velocidade aumenta, o que é típico de anomalias localizadas que se tornam evidentes em condições operacionais severas.

A Figura 49 apresenta comparação detalhada entre as estatísticas dos dados saudáveis e os dados de falha no Inner Race para um rolamento com diâmetro de falha de 0.014 polegadas. Os dados de ambas as condições são analisados em termos de medidas estatísticas como média, desvio padrão, assimetria, variância e curtose.

Figura 49. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.014 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero, refletindo um comportamento de vibração mínima e uniforme em condições operacionais ideais. Esse resultado demonstra que, em condições saudáveis, o rolamento opera de maneira estável, sem grandes desvios na vibração. Para as falhas com diâmetro de 0.014 polegadas, as médias das vibrações nas velocidades de (1797, 1772, 1750 e 1730 RPM) se mantêm próximas de zero. Esse comportamento sugere que a presença da falha não provoca um aumento expressivo nas médias vibracionais em comparação com os dados saudáveis.

O desvio padrão permanece baixo nas condições saudáveis, evidenciando um padrão vibracional estável e com baixa variabilidade. Para os dados de falha, o desvio padrão apresenta aumento em todas as velocidades, sendo acentuado nas velocidades baixas, sugerindo maior dispersão das vibrações.


A variância, que é baixa nos dados saudáveis, aumenta nas condições de falha, especialmente em velocidades baixas, indicando um comportamento vibracional instável e imprevisível. A anomalia apresenta um impacto maior em condições de operação em velocidades baixas, onde as interações dinâmicas do rolamento com a falha são proeminentes.

A assimetria dos dados saudáveis é próxima de zero, indicando distribuição simétrica das vibrações. Com a presença de anomalias, a assimetria mantém-se próximo de zero, indicando que a presença da falha com diâmetro de 0.014 polegadas não provoca um aumento expressivo. Em contrapartida, nos dados com falhas, a assimetria apresenta variação, podendo ser positiva ou negativa, sendo a única velocidade que apresenta valor positivo a de 1797 RPM.

A curtose dos dados saudáveis aproxima-se dos valores típicos da distribuição normal, indicando a ausência de picos extremos de vibração. Para os dados de falha, a curtose é maior em todas as velocidades. Esse aumento na curtose sugere a presença de eventos vibracionais extremos, relacionados a picos de vibração causados pelas falhas no Inner Race. A maior curtose indica a presença de picos acentuados na distribuição, devido à severidade da falha, especialmente em condições de operação em velocidades altas.

A Figura 50 exhibe comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Inner Race para um rolamento com diâmetro de 0.021 polegadas. Ambas as condições são analisadas utilizando medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 50. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.021 polegadas



Fonte: Autor

Os dados saudáveis exibem média próxima de zero, indicando um nível mínimo de vibração e comportamento uniforme em condições ideais de operação. Esse resultado evidencia que, em situações saudáveis, o rolamento funciona de forma estável, sem grandes variações nas vibrações. No caso de falhas com um diâmetro de 0.021 polegadas, as médias das vibrações para as velocidades de (1797, 1772, 1750 e 1730 RPM) permanecem próximas de zero. Esse padrão sugere que a presença da falha não resulta em um aumento significativo nas médias vibracionais quando comparado aos dados saudáveis.

O desvio padrão permanece baixo nas condições saudáveis, evidenciando um padrão vibracional estável e com baixa variabilidade. Para os dados de falha, o desvio padrão apresenta aumento em todas as velocidades, sugerindo maior dispersão das vibrações.

A variância, que é baixa nos dados saudáveis, aumenta nas condições de falha, indicando um comportamento vibracional instável e imprevisível. A severidade da falha tem impacto maior em condições de operação lentas, onde as interações dinâmicas do rolamento defeituoso são proeminentes.


A assimetria dos dados saudáveis é próxima de zero, apresentando uma distribuição simétrica das vibrações. Quando há anomalias, a assimetria permanece próxima de zero, indicando que a presença da falha não causa um aumento significativo no diâmetro de 0,021 polegadas. No entanto, nos dados com falhas, a

assimetria pode variar entre valores positivos e negativos, sendo que as velocidades de (1797 e 1750 RPM) são as únicas que apresentam valores positivos.

A curtose dos dados saudáveis indica a ausência de picos extremos de vibração. Para os dados de falha, a curtose é maior em todas as velocidades. Esse aumento na curtose sugere a presença de eventos vibracionais extremos, relacionados a picos de vibração causados pelas falhas no "Inner Race". A maior curtose indica a presença de picos acentuados na distribuição, devido a severidade da falha, especialmente em condições de operação em velocidades intermediárias e altas.

A Figura 51 mostra comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Inner Race para um rolamento com falha de diâmetro de 0.028 polegadas. As duas condições são avaliadas por meio de medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 51. Comparação entre estatísticas de dados saudáveis e Inner Race, diâmetro de falha de 0.028 polegadas



Fonte: Autor

Os dados saudáveis exibem média próxima de zero, indicando um nível reduzido de vibração e um comportamento regular em condições ideais de operação. Esse resultado revela que, em cenários saudáveis, o rolamento funciona de maneira estável, sem grandes flutuações nas vibrações. No caso de falhas com um diâmetro de 0.028 polegadas, as médias das vibrações nas velocidades de (1797, 1772, 1750 e 1730 RPM) possuem um aumento não significativo no valor da média.



O desvio padrão é baixo em condições saudáveis, demonstrando um padrão de vibração estável e com pouca variabilidade. Para os dados de falha, o desvio padrão se eleva em todas as velocidades, indicando maior dispersão das vibrações, especialmente em condições de operação com velocidades intermediárias.

A variância, que é baixa nos dados saudáveis, cresce nas condições de falha, indicando um comportamento vibracional instável e imprevisível. A severidade da falha apresenta um impacto significativo em condições de operação em velocidades intermediárias.

A assimetria dos dados saudáveis é próxima de zero, apresentando um valor negativo, indicando distribuição simétrica das vibrações. A assimetria em condição de falha em velocidade baixa e intermediária possuem dados elevados, que variam entre valores positivos e negativos, as velocidades de (1772 e 1750 RPM) sendo as únicas que apresentam valores positivos. Isso reflete distribuição inclinada, resultando em um padrão de vibração não simétrico devido à presença de falhas.

A curtose dos dados saudáveis aproxima-se dos valores típicos da distribuição normal, diminuindo a ausência de picos vibracionais extremos. Nos dados de falha, a curtose aumenta em todas as velocidades, proporcionando a presença de eventos vibracionais extremos, resultando em picos de vibração gerados pelas falhas no "Inner Race". O aumento da curtose indica a existência de picos acentuados na distribuição, especialmente sob condições de operação com velocidades baixas.


Conforme a Figura 52, há comparação detalhada entre as estatísticas dos dados saudáveis e os dados de falha no Inner Race para rolamentos com diâmetros de falhas de 0.007, 0.014, 0.021 e 0.028 polegadas. Os dados são analisados em termos da comparação dos cruzamentos por zero.

O cruzamento por zero é uma métrica importante na análise de sinais vibracionais, pois representa o número de vezes que o sinal de vibração cruza o eixo zero, indicando mudanças na direção do movimento. Em condições saudáveis, o comportamento do cruzamento por zero é relativamente estável, refletindo um padrão de vibração típico e esperado para o rolamento. No entanto, quando há falha, como um defeito no Inner Race, o número de cruzamentos por zero apresenta grande variação.

Um aumento no número de cruzamentos por zero indica instabilidade ou irregularidade na vibração, causada por impactos repetitivos decorrentes de defeitos na superfície do rolamento.

A análise dos cruzamentos por zero ajuda a identificar mudanças no comportamento vibracional do rolamento, permitindo a detecção de falhas e a prevenção de danos graves ao equipamento.

Figura 52. Comparação entre estatísticas de dados saudáveis e Inner Race, cruzamento por zero



Fonte: Autor

O código desenvolvido foi estruturado para iterar por todos os arquivos contidos no conjunto de dados denominado arquivos\_Inner\_Race.

- Os dados de vibração são extraídos de cada arquivo utilizando funções adequadas da biblioteca de manipulação de dados no Python, garantindo a integridade e a precisão das informações.
- A Decomposição em Modo Empírico é aplicada aos dados de vibração, permitindo a separação do sinal original em várias componentes que representam diferentes frequências. O passo é fundamental para analisar as características dinâmicas do rolamento sob diferentes condições de operação.
- As IMFs resultantes da decomposição são armazenadas para posterior análise e comparação. Essas componentes são essenciais para identificar padrões e anomalias no comportamento do rolamento.


- Até cinco IMFs são plotadas para cada arquivo processado. Os gráficos resultantes proporcionam visualização clara das diferentes componentes do sinal, facilitando a interpretação dos dados e a identificação de possíveis falhas.

A análise dos dados revela que a quantidade de cruzamentos por zero nos sinais de vibração é menor nas condições saudáveis quando comparada às condições de falha. O comportamento indica estabilidade vibracional nos dados saudáveis, enquanto as condições de falha apresentam um aumento nos cruzamentos por zero, indicando um padrão vibracional instável. Esse aumento de instabilidade é atribuído à maior severidade da anomalia, impacta de forma acentuada as condições de operação.

#### 4.8. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO BALL DATA

Conforme Figura 53, existe a comparação detalhada entre as estatísticas dos dados saudáveis e dos dados de falha no Ball Data para um rolamento com diâmetro de 0.007 polegadas de falha. As duas condições são avaliadas com base em medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 53. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.007 polegadas



Fonte: Autor

Os dados saudáveis exibem média próxima de zero, resultado das vibrações mínimas e uniformes do rolamento em condições ideais de operação, representando o funcionamento adequado do sistema. Para as falhas com diâmetro de 0,007

polegadas, as médias das vibrações registradas nas diferentes velocidades (1797, 1772, 1750 e 1730 RPM) se mantiveram próximas de zero. A similaridade indica que, mesmo em situações de anomalia, não ocorre um aumento significativo nas médias vibracionais em comparação às condições saudáveis.

O desvio padrão permanece reduzido e uniforme em condições saudáveis, reforçando a estabilidade no comportamento vibracional. No entanto, com a presença de falhas, observa-se um aumento expressivo no desvio padrão em todas as velocidades, especialmente nas velocidades baixas. Esse incremento reflete maior variabilidade nas vibrações, à medida que as falhas nos rolamentos se tornam severas e as interações dinâmicas se intensificam.


A variância, baixa em condições saudáveis, demonstra o comportamento controlado do sistema. Para os dados relacionados ao Inner Race, a variância aumenta em velocidades baixas do motor. Esse crescimento sugere um padrão vibracional instável e imprevisível, especialmente em condições severas de falha.

A assimetria dos dados saudáveis apresenta-se negativa, indicando leve inclinação à esquerda na distribuição das vibrações, o que reflete um sistema estável e bem controlado. Em contrapartida, os dados com falhas mostram assimetria positiva, revelando inclinação à direita. Esse comportamento é evidente em velocidades intermediárias, apontando para um padrão de vibração assimétrico, característico de rolamentos defeituosos. A mudança na assimetria evidencia o impacto crescente das falhas no comportamento vibracional conforme a severidade das condições operacionais aumenta.

A curtose dos dados saudáveis é positiva e próxima de zero, sem a presença de picos vibracionais pronunciados. Já nos dados de falha, a curtose apresenta valores negativos e distantes de zero, refletindo distribuição achatada, com menor ocorrência de eventos vibracionais extremos. Apesar das anomalias nos elementos rolantes influenciarem o padrão vibracional, elas não resultaram em picos vibracionais extremos nas condições analisadas.

A Figura 54 exhibe comparação das estatísticas dos dados saudáveis e dos dados de falha no Ball Data para um rolamento com diâmetro de falha de 0.014 polegadas. As duas condições são examinadas utilizando medidas estatísticas, incluindo média, desvio padrão, assimetria, variância e curtose.

Figura 54. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.014 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero, resultante da vibração mínima e uniforme do rolamento, refletindo o funcionamento do sistema. Em relação às falhas com diâmetro de 0,014 polegadas, as médias das vibrações registradas em diferentes velocidades (1797, 1772, 1750 e 1730 RPM) permaneceram próximas de zero. A semelhança indica que, mesmo em condições de falha, as vibrações não apresentam um aumento significativo em comparação com as condições saudáveis.

O desvio padrão se mantém baixo e uniforme nas condições saudáveis, reforçando a ideia de um padrão vibracional estável. No entanto, observa-se um aumento do desvio padrão em todas as velocidades em comparação com os dados saudáveis, sendo pronunciado nas velocidades intermediárias. Isso indica maior variabilidade nas vibrações conforme as falhas nos rolamentos.

A variação dos dados saudáveis é mínima, demonstrando um comportamento controlado. Para os dados dos corpos girantes, a variância aumenta nas velocidades intermediárias do motor.


A assimetria dos dados saudáveis é negativa, diminuindo um nível de orientação à esquerda na distribuição das vibrações, o que reflete um comportamento estável e controlado. Em contrapartida, nos dados com anomalias, a assimetria apresenta variação, podendo ser positiva ou negativa, sendo a única velocidade que apresenta valor positivo a de 1750 RPM. O comportamento que destoa de zero é acentuado nas velocidades altas, resultando em um padrão de vibração não simétrico, decorrente da presença de falhas nos rolamentos. A mudança na assimetria reflete a

influência crescente das anomalias no comportamento vibracional à medida que a severidade das condições operacionais aumenta.

A curtose dos dados saudáveis é negativa e se aproxima de zero, determina um comportamento característico da distribuição normal, sem a presença de picos acentuados nas vibrações observadas. Em contraste, a curtose dos dados com falhas é positiva e distante de zero, evidenciando a presença de picos significativos. A alta curtose reflete distribuição achada, com ocorrência de eventos vibracionais extremos. A curtose aumenta nas altas velocidades do motor, apresentando valores elevados.

A Figura 55 apresenta comparação das estatísticas dos dados saudáveis e dos dados de falha no Ball Data para um rolamento com diâmetro de falha de 0.021 polegadas. As condições são analisadas com base em medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 55. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.021 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero, o que reflete um nível mínimo de vibração e um comportamento estável sob condições ideais de operação. Esse comportamento sugere que, em situações saudáveis, o rolamento opera de maneira uniforme, sem grandes variações nas vibrações. Mesmo diante de falhas com um diâmetro de 0,021 polegadas, as médias das vibrações nas velocidades de (1797, 1772, 1750 e 1730 RPM) permaneceram próximas de zero, o que indica que a falha não provoca um aumento expressivo nas médias vibracionais em relação aos dados saudáveis.

O desvio padrão, que permanece baixo em condições saudáveis, demonstra um padrão vibracional estável e com pouca variabilidade. Nos dados de falha, o desvio padrão apresenta um pequeno crescimento em todas as velocidades, indicando maior dispersão das vibrações.


A variação, que se mantém reduzida nos dados saudáveis, aumenta em pequena parcela nas condições de falha, sinalizando um comportamento vibracional maior em relação aos dados saudáveis. O gráfico indica que a gravidade da anomalia tem maior impacto nas operações em velocidades intermediárias, onde as interações dinâmicas entre o rolamento e a falha tornam-se evidentes.

A assimetria nos dados saudáveis permanece próxima de zero com valor negativo, refletindo distribuição simétrica das vibrações. Com a presença de anomalias, a assimetria se mantém próxima de zero, indicando que a falha não gera um aumento significativo no diâmetro de 0,021 polegadas. Nos dados com falhas, a assimetria possui valores positivos, sendo que a velocidade de 1797 RPM apresenta o maior valor em relação aos outros dados.

A curtose dos dados saudáveis apresenta a ausência de picos vibracionais extremos. Nos dados de falha, a curtose é maior em todas as velocidades, que variam entre valores positivos e negativos, indicando a ocorrência de eventos vibracionais extremos, associados a picos de vibração causados pelas falhas nos campos girantes. O aumento da curtose sugere a presença de picos pronunciados na distribuição.

A Figura 56 apresenta comparação das estatísticas dos dados saudáveis e dos dados de falha no Ball Data para um rolamento com diâmetro de falha de 0.028 polegadas. Ambas as condições são avaliadas por meio de medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 56. Comparação entre estatísticas de dados saudáveis e ball data, diâmetro de falha de 0.028 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero, refletindo níveis baixos de vibração e comportamento consistentes em condições ideais de operação. Isso evidencia que, em situações saudáveis, o rolamento opera de forma estável, sem oscilações graves nas vibrações. No caso de falhas com diâmetro de 0,028 polegadas, as médias das vibrações nas velocidades de (1797, 1772, 1750 e 1730 RPM) mostram um nível de aumento, mas sem relevância. Esse comportamento sugere que a falha não resulta em elevação expressiva nas médias vibracionais quando comparada aos dados saudáveis.

O desvio padrão permanece restrito em condições saudáveis, diminuindo estabilidade no padrão de vibração e variações mínimas. Nos dados de falha, há um aumento do desvio padrão em todas as velocidades, diminuindo maior dispersão nas vibrações, especialmente em velocidades baixas.

A variação, que é pequena em condições saudáveis, torna-se elevada com a presença de falhas, sinalizando um comportamento vibracional intenso. Em velocidades reduzidas, a variância apresenta valores altos em relação às outras velocidades, evidenciando interações dinâmicas pronunciadas entre o rolamento e a falha.

A assimetria dos dados saudáveis é próxima de zero e negativa, o que reflete distribuição simétrica das vibrações. A presença de anomalias, na assimetria apresenta alterações em relação às condições saudáveis, com valores tanto positivos quanto negativos. A 1750 RPM é a única velocidade que mostra um valor positivo,




indicando distribuição assimétrica e padrões vibracionais específicos associados a falhas.

A curtose dos dados saudáveis aproxima-se dos valores típicos da distribuição normal, proporcionando a ausência de vibrações extremas. Em contrapartida, nos dados de falha, há um aumento da curtose em todas as velocidades, demonstrando a ocorrência de eventos vibracionais extremos relacionados a picos gerados pelas falhas nos campos girantes. Esse aumento reflete a presença de picos acentuados e prolongados na distribuição.

A Figura 57 apresenta a comparação detalhada entre os dados saudáveis e os dados com falha no Ball Data, considerando rolamentos com diâmetros de falhas de 0,007, 0,014, 0,021 e 0,028 polegadas. A análise da métrica de cruzamentos por zero, permite avaliar como essa estatística varia entre as diferentes condições operacionais e dimensões de falhas nos rolamentos.

Figura 57. Comparação entre estatísticas de dados saudáveis e ball data, cruzamento por zero



Fonte: Autor

O código desenvolvido foi estruturado para iterar por todos os arquivos contidos no conjunto de dados denominados arquivos\_Ball\_Data. Para cada arquivo:

Os dados de vibração são extraídos com funções adequadas da biblioteca de manipulação de dados em Python, garantindo a integridade e precisão das informações.

- A Decomposição em Modo Empírico (EMD) é aplicada aos dados de vibração, permitindo a separação do sinal original em vários componentes que representam diferentes frequências.


- As IMF (Funções de Modo Intrínsecas) resultantes da reserva são armazenadas para análise e comparação futura. Os componentes são importantes para identificar padrões e anomalias no comportamento do rolamento.
- Cinco IMF são plotadas para cada arquivo processado. Os gráficos gerados oferecem visualização clara dos diferentes componentes do sinal, facilitando a interpretação dos dados e a identificação de possíveis falhas.

A análise dos dados revela que a quantidade de cruzamentos por zero nos sinais de vibração é menor em condições saudáveis em comparação às condições de falha. Esse comportamento sugere maior estabilidade vibracional nos dados saudáveis, enquanto as condições de falha apresentam um aumento nos índices por zero, diminuindo um padrão vibracional imprevisível. A instabilidade crescente está associada a severidade de anomalias, que tendem a impactar as condições de operação. Nessas situações, as interações dinâmicas entre o rolamento e o defeito se intensificam, reforçando a anomalia e facilitando a identificação do dano.

#### 4.9. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHANO OUTER RACE CENTRALIZADO

A Figura 58 apresenta comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Centralizado para um rolamento com diâmetro de falha de 0.007 polegadas. As duas condições são analisadas utilizando medidas estatísticas, incluindo média, desvio padrão, assimetria, variância e curtose.

Figura 58. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.007 polegadas



Fonte: Autor

Os dados saudáveis exibem média próxima de zero, refletindo a vibração mínima e uniforme do rolamento em condições saudáveis, evidenciando o funcionamento adequado do sistema. De maneira similar, nas falhas com diâmetro de 0,007 polegadas, as médias das vibrações registradas em diferentes rotações (1797, 1772, 1750 e 1730 RPM) permaneceram próximas de zero, sugerindo que, apesar da presença de anomalias, não há um aumento significativo nas vibrações em relação às condições saudáveis.

O desvio padrão dos dados saudáveis mantém-se baixo e constante, reforçando a ideia de um padrão vibracional estável. No entanto, em todas as velocidades sob condições de falha, o desvio padrão mostra um aumento, o que indica maior variabilidade nas vibrações conforme a severidade da anomalia aumenta e as interações dinâmicas no sistema se intensificam.


A variância dos dados saudáveis é mínima, evidenciando um comportamento controlado e estável. Em contraste, a variância dos dados de falha no Outer Race Centralizado aumenta. Esse crescimento na variabilidade reflete um comportamento vibracional instável e errático.

A assimetria dos dados saudáveis é negativa e próxima de zero, indicando leve inclinação à esquerda na distribuição das vibrações, o que reforça o comportamento estável do sistema. Em condições de falha, as assimetrias mantêm-se negativas, exceto na velocidade de 1772 RPM que é positivo, em todas as velocidades a assimetria apresenta dados com maior amplitude.

A curtose dos dados saudáveis é próxima de zero, sinalizando distribuição de vibração, sem picos acentuados. Em contrapartida, a curtose dos dados com falhas é maior, destacando distribuição com maior ocorrência de vibrações extremas. Embora as anomalias nos rolamentos influenciem a vibração.

A Figura 59 mostra comparação minuciosa das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Centralizado para um rolamento com diâmetro de 0.014 polegadas de falha. A análise considera medidas estatísticas como média, desvio padrão, assimetria, variância e curtose.

Figura 59. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.014 polegadas



Fonte: Autor

Os dados saudáveis apresentam média próxima de zero, refletindo o comportamento vibracional do sistema sob condições saudáveis de operação, com variações mínimas que indicam operação estável. As falhas com diâmetro de 0,014 polegadas nas velocidades de (1797, 1772, 1750 e 1730 RPM) mantêm média próxima de zero. Esse comportamento sugere que, mesmo com anomalias, as vibrações não mostram um aumento significativo em comparação às condições saudáveis.

O desvio padrão nos dados saudáveis é estável e baixo, indicando consistência no comportamento vibracional sem grandes variações. Sob condições de falha, o desvio padrão apresenta pequenas variações, notavelmente em velocidades altas.

A variância permanece inalterada para os dados saudáveis quanto para os dados de falha, com pequenas variações em diferentes velocidades. Isso demonstra


que, apesar das falhas, o comportamento vibracional se mantém estável, sem grandes desvios.

Nos dados saudáveis, a assimetria é negativa, indicando leve inclinação à esquerda na distribuição das vibrações. No entanto, nos dados de falhas, a assimetria varia, podendo ser negativa quanto positiva. As velocidades de (1797 e 1772 RPM) apresentam valor positivo de assimetria. Em velocidades altas e intermediárias, observa-se um desvio acentuado em relação a zero, o que sugere distribuição assimétrica das vibrações.

A curtose dos dados saudáveis é negativa e com baixa amplitude, sinalizando distribuição achatada com poucas vibrações extremas. Para os dados de falha, a curtose é negativa em todas as velocidades, com maior amplitude quando comparado com os dados saudáveis.

A Figura 60 exibe comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Centralizado para um rolamento com diâmetro de 0.021 polegadas de falha. Ambas as condições são avaliadas em termos de medidas estatísticas, incluindo média, desvio padrão, assimetria, variância e curtose.

Figura 60. Comparação entre estatísticas de dados saudáveis e outer race centralizado, diâmetro de falha de 0.021 polegadas



Fonte: Autor

A média das vibrações nos dados saudáveis e de falha apresenta valores próximos de zero, demonstrando que, mesmo com a presença de falhas de diâmetro de 0,021 polegadas nas velocidades de (1797, 1772, 1750 e 1730 RPM), as vibrações

médias permanecem estáveis e não mostram aumentos significativos em relação às condições saudáveis.

O desvio padrão dos dados saudáveis é reduzido, indicando baixa variabilidade nas vibrações. Para os dados com Falha, o desvio padrão permanece baixo, com pequenas variações entre as diferentes velocidades, sugerindo que, apesar da falha, o comportamento vibracional não apresenta grandes oscilações, sendo o impacto das falhas moderado nessa métrica.


A variância dos dados, tanto na base de dados saudáveis quanto de falhas, mostra-se mínima em todas as condições analisadas. Esse comportamento reflete a estabilidade do sistema, mesmo na presença de anomalias no rolamento, demonstrando que a dispersão dos dados não é afetada pelas falhas.

A assimetria dos dados, tanto em condições saudáveis quanto com Falha, permanece próximas de zero em todas as situações avaliadas. Esse resultado indica que os sistemas se mantêm estáveis, mesmo com a presença de falhas nos rolamentos, indicando que as anomalias não impactam de maneira significativa a distribuição das vibrações.

A curtose é o parâmetro que se destaca nesta análise. Enquanto nos dados saudáveis a curtose é nula, sugerindo distribuição achatada e sem picos de vibração, nos dados de falha há um aumento significativo da curtose. A alta amplitude indica a presença de picos acentuados nas vibrações, refletindo a ocorrência de eventos vibracionais, típicos de condições de anomalia no rolamento.

A Figura 61 apresenta uma comparação entre os dados saudáveis e os dados com falha no Outer Race Centralizado, considerando rolamentos com diâmetros de falhas de 0,007, 0,014 e 0,021 polegadas. A análise concentra-se na comparação dos cruzamentos por zero, permitindo avaliar as alterações no comportamento vibracional associadas à presença de falhas.

Figura 61. Comparação entre estatísticas de dados saudáveis e outer race centralizado, cruzamento por zero



Fonte: Autor

O gráfico gerado mostra a Comparação dos Cruzamentos por Zero para diferentes condições e diâmetros de falhas em 4 velocidades distintas (1797, 1772, 1750 e 1730 RPM). Ele apresenta a média dos cruzamentos por zero para as condições saudáveis e para diferentes diâmetros de falha no rolamento (0.007, 0.014 e 0.021 polegadas).


- Velocidade 1797 RPM: As condições saudáveis exibem o menor número de cruzamentos por zero, enquanto as condições com falhas apresentam números elevados, sendo a falha com diâmetro de 0.014 polegadas a que se destaca com a maior quantidade de cruzamentos.
- Velocidade 1772 RPM: O comportamento é semelhante ao da velocidade anterior, com as condições saudáveis apresentando menos cruzamentos por zero em comparação às condições de falha. A anomalia de 0.014 possui a maior quantidade de cruzamentos.
- Velocidade 1750 RPM: Os padrões de cruzamentos por zero para todas as falhas são próximos, A anomalia de 0.007 possui a maior quantidade. As condições saudáveis apresentam menor número.
- Velocidade 1730 RPM: Na menor velocidade, o número de cruzamentos por zero permanece elevado para as condições de falha, com pequena variação entre os diâmetros.

O aumento no número de cruzamentos por zero nas condições de falha em comparação com as condições saudáveis é um indicador claro do impacto das anomalias no comportamento vibracional. Esse aumento está relacionado à maior variabilidade e instabilidade que as falhas nos rolamentos trazem ao sistema, causando inversões de sinal no padrão de vibração. Esse comportamento é consistente em todas as velocidades analisadas.

#### 4.10. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO OUTER RACE OPOSTO

A Figura 62 apresenta comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Oposto para um rolamento com diâmetro de 0.007 polegadas de falha. As duas condições são analisadas utilizando medidas estatísticas, incluindo média, desvio padrão, assimetria, variância e curtose.

Figura 62. Comparação entre estatísticas de dados saudáveis e outer race oposto, diâmetro de falha de 0.007 polegadas



Fonte: Autor

A média das vibrações, tanto nas condições saudáveis quanto de falha, permanece próxima de zero. Isso demonstra que, mesmo com falhas, as vibrações médias não se alteram em comparação às condições saudáveis, sugerindo estabilidade no comportamento médio.

O desvio padrão dos dados saudáveis é baixo, indicando pouca variação. Em condições de falha, há um leve aumento no desvio padrão, as variações são



pequenas, indicando que as falhas não geram grandes oscilações nas vibrações em torno da média.

A variância é mínima para todos os casos, refletindo um comportamento estável e dispersão limitada das vibrações, mesmo com a presença de falhas.


A assimetria possui o valor próximo de zero em todos os casos, refletindo um comportamento estável e dispersão limitada das vibrações, mesmo com a presença de falhas, que variam entre polaridades.

Nos dados saudáveis a Curtose é nula, nas condições de falha, particularmente a 1797 RPM, a curtose aumenta significativamente, indicando a presença de picos vibracionais acentuados.

A análise demonstra que, embora a média, o desvio padrão e a variância não apresentem grandes variações entre as condições saudáveis e de falha, a assimetria e, principalmente, a curtose se destacam ao indicar a presença de falhas.

A Figura 63 mostra comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Oposto para um rolamento com diâmetro de falha de 0.021 polegadas. A análise considera medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 63. Comparação entre estatísticas de dados saudáveis e outer race oposto, diâmetro de falha de 0.021 polegadas



Fonte: Autor

As vibrações médias nas condições de falha possuem amplitudes similar à de dados saudáveis. Isso indica que a presença da anomalia no Outer Race Oposto com diâmetro de 0.021 polegadas não impacta o comportamento vibracional do sistema.

O desvio padrão dos dados saudáveis é reduzido, mostrando pouca variação nas vibrações. Assim como os dados de falha, que apresentam um leve aumento no desvio padrão, a variabilidade nas vibrações aumenta de forma moderada com a presença de falhas.


Assim como o desvio padrão, a variância é mínima em todas as condições analisadas, refletindo dispersão limitada das vibrações, tanto em condições saudáveis quanto de falha.

A assimetria dos dados saudáveis é praticamente nula, indicando distribuição equilibrada das vibrações. Nos dados de falha, principalmente a 1730 RPM, observa-se leve assimetria positiva, sugerindo pequena distorção na distribuição.

A curtose destaca-se como a métrica sensível às falhas. Nos dados saudáveis, a curtose é inexistente, indicando distribuição sem picos acentuados. Por outro lado, nas condições de falha, especialmente a 1772 RPM, observa-se um aumento expressivo da curtose, indicando a presença de picos vibracionais pronunciados, que são característicos de eventos extremos causados por anomalia no rolamento.

A Figura 64 apresenta comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Oposto de rolamentos com diâmetros de falhas 0.007 e 0.021 polegadas. A análise compara os cruzamentos por zero.

Figura 64. Comparação entre estatísticas de dados saudáveis e outer race oposto, cruzamento por zero



Fonte: Autor

O gráfico apresentado compara os Cruzamentos por Zero para diferentes condições e diâmetros de falhas do rolamento em 4 velocidades distintas (1797, 1772,

1750, 1730 RPM). Ele exibe a média dos cruzamentos por zero tanto para as condições saudáveis quanto para falhas no Outer Race Oposto com diâmetros de falhas de 0.007 e 0.021 polegadas.

- Velocidade 1797 RPM: As condições saudáveis registram o menor número de cruzamentos por zero, enquanto as falhas apresentam números consideravelmente maiores. A anomalia de 0.007 polegadas apresenta o maior valor de cruzamentos.
- Velocidade 1772 RPM: O padrão se repete, com menos cruzamentos por zero nas condições saudáveis em relação às falhas. As anomalias com diâmetros de falhas 0.007 e 0.021 polegadas exibem valores próximos.
- Velocidade 1750 RPM: O número de cruzamentos nas condições de falha permanece elevado, com variações mínimas entre os dois diâmetros, sendo a anomalia de 0.021 polegadas expressiva. As condições saudáveis continuam apresentando o menor número de cruzamentos.
- Velocidade 1730 RPM: Na menor velocidade, as falhas mantêm um número elevado de cruzamentos por zero, com pouca diferença entre os diâmetros. As condições saudáveis permanecem com a menor quantidade de cruzamentos.


O aumento no número de cruzamentos por zero nas condições de falha, comparado às condições saudáveis, reflete claramente o impacto das falhas no comportamento vibracional do sistema. Esse acréscimo demonstra maior variabilidade e instabilidade nas vibrações causadas pelas anomalias, resultando em inversões de sinal. O comportamento é consistente em todas as velocidades, evidenciando a influência das falhas nos rolamentos sobre o padrão vibracional.

#### 4.11. COMPARAÇÃO DAS ESTATÍSTICAS DOS DADOS SAUDÁVEIS E COM FALHA NO OUTER RACE ORTOGONAL

A Figura 65 apresenta comparação detalhada das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Ortogonal para um rolamento com

diâmetro de falha de 0.007 polegadas. As duas condições são analisadas utilizando medidas estatísticas, incluindo média, desvio padrão, assimetria, variância e curtose.

Figura 65. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, diâmetro de falha de 0.007 polegadas



Fonte: Autor

A média das vibrações nos dados saudáveis e de falha apresentam valores próximos de zero, indicando que, mesmo com a presença de falhas com diâmetro de 0.007 polegadas nas velocidades de (1797, 1772, 1750 e 1730 RPM), as vibrações médias permanecem estáveis e não apresentam aumentos significativos em relação às condições saudáveis.

O desvio padrão permanece baixo em condições saudáveis, refletindo um padrão de vibração estável e com pouca variação. No entanto, em situações de falha, observa-se um aumento significativo no desvio padrão em todas as velocidades, proporcionando maior dispersão das vibrações, com destaque para as velocidades intermediárias.

A variação, é baixa em condições saudáveis, na presença de falhas, se eleva, evidenciando um comportamento vibracional de maior intensidade. Esse aumento é pronunciado em velocidades intermediárias, onde as interações dinâmicas entre o rolamento e a anomalia se tornam evidentes.


A assimetria nos dados saudáveis e de falha permanecem próximas de zero, com valores negativos, em algumas situações avaliadas, com exceção das velocidades de (1750 e 1730 RPM), que apresentam amplitude positiva. Mesmo com

a presença de anomalias nos rolamentos, as falhas não alteram de forma significativa a distribuição das vibrações.

Nos dados saudáveis, a curtose é reduzida, sem picos acentuados de vibração. Nas condições de falha, há um aumento significativo da curtose, especialmente na velocidade de 1797 RPM. Esse aumento indica a presença de picos acentuados nas vibrações, refletindo eventos vibracionais intensos.

A Figura 66 apresenta comparação das estatísticas dos dados saudáveis e dos dados de falha no Outer Race Ortogonal para um rolamento com diâmetro de 0.021 polegadas de falha. As condições são analisadas com base em medidas estatísticas, como média, desvio padrão, assimetria, variância e curtose.

Figura 66. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, diâmetro de falha de 0.021 polegadas



Fonte: Autor

A média das vibrações nos dados saudáveis e nas condições de falha se mantém próximas de zero, mesmo com a existência de falhas, não há um aumento expressivo nas vibrações. As médias das vibrações permanecem consistentes e estáveis, comparáveis às observadas em condições saudáveis de operação.

O desvio padrão dos dados saudáveis é reduzido, o que reflete baixa variabilidade nas vibrações sob condições saudáveis de operação. Para os dados de falha, o desvio padrão permanece baixo, com pequenas variações.


A variância dos dados, tanto saudáveis quanto de falha, é mínima em todas as condições analisadas, refletindo estabilidade na dispersão dos dados. Mesmo com a presença de falhas, a dispersão dos dados não é fortemente afetada.

A assimetria dos dados saudáveis permanece próxima de zero, indicando distribuição simétrica das vibrações. Nos dados de falha, há variações na assimetria, com dados variando entre polaridades, sendo a velocidade de 1730 RPM a que apresenta o maior valor de amplitude e a única que apresenta o valor negativo.

A curtose é a métrica que se destaca, nos dados saudáveis, a curtose é nula, indicando distribuição sem eventos vibracionais extremos. Por outro lado, nos dados de falha, observa-se um aumento expressivo na curtose, especialmente em 1797 RPM, refletindo a presença de picos acentuados nas vibrações, o que indica a ocorrência de eventos vibracionais, característicos de falhas nos rolamentos.

A Figura 67 ilustra uma análise detalhada dos dados saudáveis em comparação aos dados com falha no Outer Race Ortogonal, considerando rolamentos com diâmetros de 0,007 e 0,021 polegadas. A avaliação contempla métricas estatísticas, com destaque para a comparação dos cruzamentos por zero, evidenciando as variações no comportamento vibracional decorrentes das falhas.

Figura 67. Comparação entre estatísticas de dados saudáveis e outer race ortogonal, cruzamento por zero



Fonte: Autor

O gráfico gerado mostra a comparação dos Cruzamentos por Zero para diferentes condições e diâmetros de falhas em 4 velocidades distintas (1797, 1772, 1750, 1730 RPM). Ele apresenta a média dos cruzamentos por zero para as condições saudáveis e para dois diâmetros de falha no rolamento (0.007 e 0.021 polegadas).

- Velocidade 1797 RPM: As condições saudáveis apresentam o menor número de cruzamentos por zero, enquanto as condições de falha mostram números

maiores. As falhas com ambos os diâmetros (0.007 e 0.021 polegadas) apresentam quantidades de cruzamentos por zero próximas.

- Velocidade 1772 RPM: As condições saudáveis apresentam menos cruzamentos por zero em comparação às condições de falha. As falhas com ambos os diâmetros (0.007 e 0.021 polegadas) apresentam quantidades de cruzamentos por zero próximas.
- Velocidade 1750 RPM: A anomalia de 0.021 polegadas registra o maior número de cruzamentos, enquanto a condição com dados saudáveis mantém o menor número de cruzamentos.
- Velocidade 1730 RPM: Na menor velocidade, o número de cruzamentos por zero permanece elevado para ambas as condições de falha, com pouca variação entre os diâmetros. A condição com dados saudáveis continua mostrando o menor número de cruzamentos.

O aumento de cruzamentos por zero nas condições de falha, em comparação com as condições saudáveis, é um indicador claro do impacto das anomalias no comportamento vibracional. Esse aumento reflete maior variabilidade e instabilidade do sinal.

#### 4.12. APLICAÇÃO DE MODELOS DE MACHINE LEARNING PARA DETECÇÃO DE FALHAS EM ROLAMENTOS

Nesta etapa do estudo, diferentes modelos de aprendizado de máquina foram aplicados na detecção de falhas em rolamentos, com base em dados vibracionais processados por meio da técnica de Decomposição em Modo Empírico (EMD). O objetivo principal dessa análise é classificar as condições operacionais dos rolamentos, distinguindo entre estados saudáveis e com falha.

A base de dados foi organizada com seis categorias: Normal, Inner Race, Ball Data, Outer Race Centralizado, Outer Race Ortogonal e Outer Race Oposto. Cada amostra representa uma janela temporal extraída de sinais de vibração e foi sintetizada em seis métricas estatísticas: média, desvio padrão, variância, assimetria,

curtose e cruzamentos por zero. Essas métricas foram definidas por sua relevância na representação de propriedades dinâmicas de sistemas rotativos, proporcionando uma análise complementar e precisa do comportamento vibracional.

Cada amostra possui um intervalo temporal de 83 milissegundos, reforçando a velocidade para detecção. As métricas estatísticas foram extraídas a partir das Funções de Modo Intrínseco (IMFs), geradas por meio da aplicação da EMD aos sinais brutos. Posteriormente, os conjuntos de dados foram carregados individualmente e unificados em um único DataFrame.

Para fins de classificação supervisionada, foi atribuída uma variável binária às amostras: 0 para representar a classe Normal e 1 para as diferentes condições de Falha. A Tabela 6 apresenta a distribuição original das amostras por classe antes do balanceamento, evidenciando um desnível entre as categorias, com 21 amostras normais em comparação a 308 amostras com falha.

Tabela 6. Distribuição das Amostras por Classe antes do balanceamento

Classe	Nº de Amostras	Métricas por Amostra	Total de Dados Estatísticos
Normal	21	6	126
Inner Race	82	6	492
Ball Data	82	6	492
Outer Race Centralizado	61	6	366
Outer Race Ortogonal	42	6	252
Outer Race Oposto	41	6	246
<b>Total</b>	<b>329</b>	—	<b>1.974</b>

Fonte: Autor

A fim de mitigar o desbalanceamento e garantir uma representação equitativa das classes durante o treinamento dos modelos, foi adotada a técnica SMOTE (Synthetic Minority Oversampling Technique). A abordagem gera amostras sintéticas da classe minoritária por meio da interpolação de exemplos existentes, promovendo um conjunto de dados balanceado. Como resultado, obteve-se um total de 616 amostras, sendo 308 de cada classe, conforme ilustrado na Tabela 7.



Tabela 7. Distribuição das Amostras por Classe após o balanceamento

Classe	Nº de Amostras	Métricas por Amostra	Total de Dados Estatísticos
Normal	308	6	1848
Com Falha	308	6	1848
<b>Total</b>	<b>616</b>	<b>—</b>	<b>3696</b>

Fonte: Autor

A utilização do SMOTE neste estudo fundamenta-se na revisão de PRADIPTA et al. (2021), a qual ressalta a eficácia da técnica na ampliação de conjuntos de dados desbalanceados. Quando adequadamente parametrizada, essa abordagem contribui significativamente para a redução do viés estatístico, ao mesmo tempo em que favorece a capacidade de generalização dos modelos de aprendizado supervisionado, minimizando o risco de ajuste excessivo aos dados de treinamento.

O conjunto final foi estruturado em um DataFrame com 616 linhas por 6 colunas, em que cada linha representa uma amostra e cada coluna corresponde a uma métrica estatística. Esse arranjo resultou em 3.696 valores numéricos, utilizados como variáveis independentes (features) nos modelos. Os rótulos binários foram armazenados em um vetor, preservando a integridade da estrutura de aprendizado supervisionado. Formato adotado em bibliotecas como Scikit-learn, que favorece a separação entre os atributos e as classes, garantindo a integridade do processo de treinamento e avaliação dos modelos (PEDREGOSA et al., 2011).

Cada uma das métricas adotadas desempenha um papel fundamental na caracterização dos sinais de vibração:

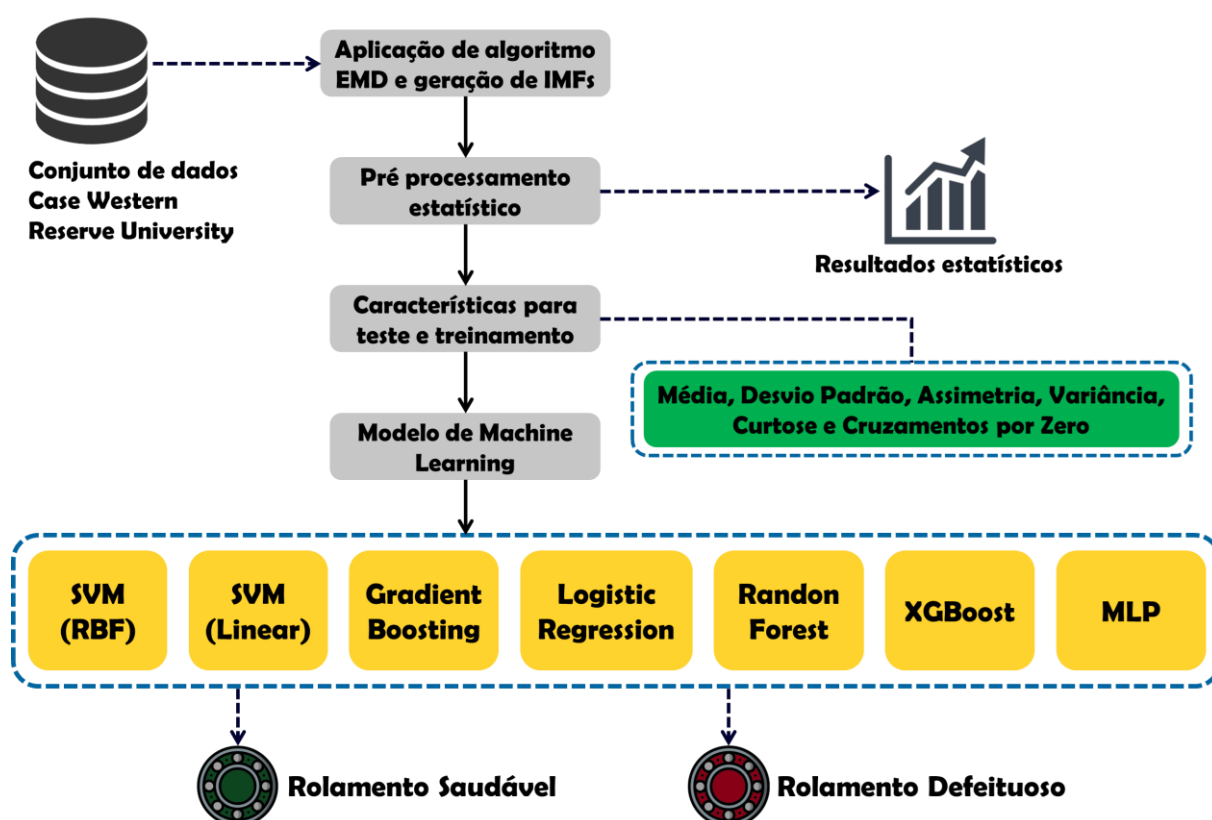
- A média representa a tendência central das amplitudes ao longo do tempo;
- O desvio padrão e a variância quantificam a dispersão e a instabilidade do sinal;
- A assimetria avalia a simetria da distribuição, identificando padrões irregulares;
- A curtose aponta a presença de picos anômalos, relacionados a impactos mecânicos;
- Os cruzamentos por zero indicam a frequência das oscilações, refletindo a regularidade do comportamento dinâmico.

A integração dessas métricas fortalece a capacidade dos modelos de detectar padrões complexos associados a diferentes tipos de falha em rolamentos.

Por fim, os dados foram divididos em dois conjuntos: 70% para treinamento e 30% para teste, utilizando a técnica de estratificação. A abordagem assegura que a proporção das classes seja mantida em ambos os conjuntos, permitindo que os modelos treinados apresentem robustez e capacidade de generalização em situações reais.

A Figura 68 ilustra o fluxo completo da metodologia de detecção de falhas empregada neste estudo. O processo se inicia com a aplicação da EMD para extração das IMFs, seguida pelo pré-processamento estatístico. Em seguida, as métricas extraídas compõem a base de entrada para os modelos de aprendizado supervisionado, que realizam a classificação entre condições saudáveis e defeituosas dos rolamentos.

Figura 68. Processamento e classificação de falhas utilizando modelos de Machine Learning



Fonte: Autor

O diagrama apresenta os algoritmos avaliados, incluindo SVM (Linear e RBF), Gradient Boosting, Logistic Regression, Random Forest, XGBoost e MLP. Esses modelos foram treinados e testados para classificar os rolamentos em condições saudáveis ou com falhas. A partir da abordagem, foi possível avaliar o desempenho

dos algoritmos na distinção entre padrões saudáveis e de falhas, fornecendo resultados estatísticos que auxiliam na compreensão da eficácia de cada modelo.

#### 4.12.1. UTILIZAÇÃO DE SETE MODELOS DE MACHINE LEARNING PARA CLASSIFICAÇÃO DOS DADOS

Cada modelo foi treinado com o conjunto de treino e posteriormente avaliado utilizando o conjunto de teste. A configuração de cada modelo é detalhada a seguir:

1. MLPClassifier (Perceptron Multicamadas): Configurado com camada oculta contendo 100 neurônios e limite de 500 iterações, o MLP foi utilizado para capturar padrões complexos nos dados por meio da rede neural conectada. Segundo (LECUN et al. 2015), redes neurais multicamadas são eficazes na modelagem de relações não lineares.
2. XGBoost Classifier: Configurado com a métrica de avaliação logloss, o modelo treinou árvores de decisão sequencialmente, ajustando os erros cometidos em iterações anteriores. Trabalhos como (CHEN et al. 2016) demonstram a alta performance do XGBoost em classificações de dados complexos.
3. Random Forest Classifier: O modelo utilizou um conjunto de árvores de decisão independentes, cuja combinação final das previsões resultou em maior precisão e redução de overfitting. (BREIMAN et al. 2001) destaca a robustez desse modelo na redução de variância e melhoria da generalização.
4. Logistic Regression: Empregado como um modelo linear, realizou a classificação das amostras com base na probabilidade de pertencerem a das classes, utilizando função sigmoidal. (HASTIE et al. 2009) enfatizam sua aplicação em problemas de classificação binária.
5. Gradient Boosting Classifier: Implementado para corrigir iterativamente os erros das árvores de decisão anteriores, este modelo foi eficaz na identificação de padrões nos dados. Segundo (NATEKIN et al. 2013), o Gradient Boosting

demonstra alto desempenho ao lidar com conjuntos de dados complexos, sendo amplamente utilizado em aplicações de aprendizado supervisionado.

6. SVM com kernel linear: Utilizou um hiperplano linear para separar as classes, sendo ideal para conjuntos de dados com padrões lineares. Trabalhos como (VAPNIK et al. 1995) evidencia sua aplicação em diferentes cenários de classificação.
7. SVM com kernel RBF (Radial Basis Function Kernel): Aplicou um kernel não linear para capturar padrões nos dados, sendo adequado para situações em que as classes não são linearmente separáveis. (VAPNIK et al. 1998) destaca a capacidade do SVM-RBF de generalizar bem em espaços de alta dimensionalidade.

Após o treinamento, os modelos foram avaliados utilizando métricas de desempenho como acurácia, precisão, recall e F1-Score. Além disso, gráficos de curvas ROC foram gerados para cada modelo, e matrizes de confusão foram analisadas para identificar o desempenho nas classes saudável e de falha.

#### 4.12.2. RESULTADOS DE DESEMPENHO DOS MODELOS DE MACHINE LEARNING, PARA CONDIÇÕES SAUDÁVEIS E COM FALHA

Os resultados gerais obtidos para cada modelo estão apresentados na Tabela 8. Observa-se que os modelos Random Forest, XGBoost e Gradient Boosting destacaram-se com os melhores desempenhos em termos de acurácia e F1-Score, indicando alta eficiência na classificação entre condições saudáveis e com falhas.

Tabela 8. Desempenho dos modelos de Machine Learning para detecção de falhas em rolamentos

Base de dados geral de rolamentos saudáveis e defeituosos				
Modelo	Acurácia	Precisão	Recall	F1-Score
MLP	0,92	1,00	0,85	0,92
XGBoost	0,96	0,99	0,93	0,96
Random Forest	0,97	1,00	0,93	0,97
Logistic Regression	0,89	0,97	0,80	0,88
Gradient Boosting	0,96	1,00	0,92	0,96
SVM (Linear)	0,90	0,99	0,8	0,89
SVM (RBF)	0,90	0,96	0,83	0,89

Fonte: Autor

A Tabela 9 apresenta os resultados detalhados para a classificação de rolamentos na condição saudável. Os modelos Random Forest, Gradient Boosting e XGBoost exibiram excelente desempenho, com alta precisão, recall e F1-Score, indicando eficácia na identificação correta de condições saudáveis.

Tabela 9. Desempenho dos modelos para a classe saudável

Base de dados de rolamento saudável			
Modelo	Precisão	Recall	F1-Score
MLP	0,87	1,00	0,93
XGBoost	0,94	0,99	0,96
Random Forest	0,94	1,00	0,97
Logistic Regression	0,83	0,98	0,9
Gradient Boosting	0,93	1,00	0,96
SVM (Linear)	0,84	0,99	0,91
SVM (RBF)	0,85	0,97	0,9

Fonte: Autor

A Tabela 10 exibe os resultados para a classe Falha, destacando a capacidade dos modelos em identificar corretamente rolamentos com falhas. Os modelos Random Forest, Gradient Boosting e XGBoost apresentaram os melhores desempenhos, com alta precisão e F1-Score, evidenciando a eficácia para aplicação.

Tabela 10. Desempenho dos modelos para a classe Falha

Base de dados de rolamento defeituoso			
Modelo	Precisão	Recall	F1-Score
MLP	1,00	0,85	0,92
XGBoost	0,99	0,93	0,96
Random Forest	1,00	0,93	0,97
Logistic Regression	0,97	0,80	0,88
Gradient Boosting	1,00	0,92	0,96
SVM (Linear)	0,99	0,80	0,89
SVM (RBF)	0,96	0,83	0,89

Fonte: Autor

A aplicação de modelos de Machine Learning apresentou eficácia para a detecção de falhas em rolamentos, utilizando dados vibracionais. Entre os modelos avaliados, o Random Forest se destacou como o robusto, seguido por XGBoost e Gradient Boosting.

Os resultados sugerem que métodos baseados em árvores de decisão, como Random Forest, são adequados para lidar com dados de falhas em rolamentos, devido à sua alta capacidade de generalização e manuseio de dados balanceados. Modelos como Logistic Regression e SVM apresentaram desempenhos inferiores, sendo sensíveis a padrões lineares.

A combinação de métricas estatísticas com algoritmos de aprendizado de máquina se mostrou eficaz para identificar anomalias incipientes e severas, contribuindo para o diagnóstico confiável em aplicações de monitoramento de condição de máquinas.


#### 4.12.3. ANÁLISE DAS CURVAS RECEIVER OPERATING CHARACTERISTIC PARA OS MODELOS DE MACHINE LEARNING

As curvas ROC (Receiver Operating Characteristic) ilustram o desempenho dos modelos de Machine Learning em termos da taxa de verdadeiros positivos (sensibilidade) e da taxa de falsos positivos (1 - especificidade). A área sob a curva (AUC - Area Under the Curve) foi calculada para cada modelo como métrica de

avaliação de desempenho. Valores de AUC próximos de 1 indicam maior eficácia do modelo na separação entre as classes.

A Figura 69 apresenta a curva ROC do modelo MLP, demonstrando um desempenho sólido na classificação entre as condições saudáveis e com Falha. Com área sob a curva (AUC) de 0,97, o modelo apresenta capacidade de distinção entre as classes, indicando sua eficácia no processamento e análise dos dados de vibração.


Figura 69. Curva Receiver Operating Characteristic do modelo Multilayer Perceptron



Fonte: Autor

A Figura 70 apresenta a curva ROC do modelo XGBoost, evidenciando desempenho com área sob a curva (AUC) de 1,00. O resultado destaca a capacidade do modelo em diferenciar entre as condições saudáveis e com Falha, apresentando alta eficiência e precisão na classificação dos dados.


Figura 70. Curva Receiver Operating Characteristic do modelo Extreme Gradient Boostin



Fonte: Autor

A Figura 71 apresenta a curva ROC do modelo Random Forest, que alcançou área sob a curva (AUC) de 1,00. Esse desempenho ressalta a eficácia do modelo em classificar corretamente as condições saudáveis e com falha, sem apresentar falsos positivos ou negativos, tornando-o altamente confiável para esta classificação.

Figura 71. Curva Receiver Operating Characteristic do modelo Random Forest




Fonte: Autor



A Figura 72 apresenta a curva ROC do modelo Logistic Regression, com área sob a curva (AUC) de 0,91. O resultado indica que o modelo possui capacidade moderada de discriminação entre as classes saudáveis e com falha.


Figura 72. Curva Receiver Operating Characteristic do modelo Logic Regression



Fonte: Autor

A Figura 73 apresenta a curva ROC do modelo Gradient Boosting, com área sob a curva (AUC) de 1,00. O resultado reflete o desempenho do modelo na distinção entre as classes saudáveis e com falha, demonstrando sua eficiência na classificação.


Figura 73. Curva Receiver Operating Characteristic do modelo Gradient Boosting



Fonte: Autor

A Figura 74 apresenta a curva ROC do modelo SVM com kernel linear, com área sob a curva (AUC) de 0,91. O resultado reflete desempenho moderado com algumas limitações em relação a modelos com AUC superiores.


Figura 74. Curva Receiver Operating Characteristic do modelo Support Vector Machine (Linear)



Fonte: Autor

A Figura 75 exibe a curva ROC do modelo SVM com kernel RBF, com área sob a curva (AUC) de 0,95. Esse resultado apresenta boa capacidade do modelo em distinguir entre as classes.

Figura 75. Curva Receiver Operating Characteristic do modelo Support Vector Machine (Radial Basis Function Kernel)



Fonte: Autor


Com base na análise das curvas ROC, os modelos XGBoost, Random Forest e Gradient Boosting apresentaram o melhor desempenho, alcançando área sob a curva (AUC) de 1.00. Esse resultado indica que esses modelos têm alta capacidade de separar corretamente as classes Normal (saudável) e de falha (defeituoso) em todas as condições analisadas. Entre eles, destaca-se o Gradient Boosting pela consistência no ajuste de erros, e sua eficácia em problemas de classificação.

#### 4.12.4. ANÁLISE DAS MATRIZES DE CONFUSÃO PARA OS MODELOS DE MACHINE LEARNING

As matrizes de confusão fornecem análise detalhada do desempenho dos modelos de Machine Learning, permitindo identificar a distribuição dos verdadeiros positivos e negativos, falsos positivos e negativos. A abordagem avalia a capacidade dos modelos em distinguir corretamente entre as condições saudáveis e com falhas.

A matriz de confusão apresentada na Figura 76 para o modelo MLP ilustra o desempenho do modelo em termos de acertos e erros de classificação. O modelo identificou corretamente todas as 93 amostras da classe Normal (saudável) e 78 amostras da classe com falha. Ocorreram 14 falsos negativos, onde amostras da classe com falha foram incorretamente classificadas como Normal. Não houve falsos positivos, evidenciando um bom desempenho nas condições saudáveis.


Figura 76. Matriz de Confusão do modelo Multilayer Perceptron



Fonte: Autor


A matriz de confusão exibida na Figura 77 apresenta desempenho do modelo XGBoost. O modelo classificou corretamente 92 das 93 amostras da classe Normal (saudável) e 86 das 92 amostras da classe com falha. Foi apresentado 1 falso positivo, onde amostra da classe Normal (saudável) foi classificada incorretamente como falha, e 6 falsos negativos, indicando amostras de falha classificadas como Normal. Esses resultados refletem a eficácia do modelo XGBoost em detectar classes.

Figura 77. Matriz de Confusão do modelo Extreme Gradient Boostin



A matriz de confusão apresentada na Figura 78 demonstra o desempenho do modelo Random Forest. O modelo classificou corretamente 93 das 93 amostras da classe Normal (saudável), sem gerar falsos positivos. Para a classe com Falha, o modelo identificou corretamente 86 das 92 amostras, resultando em 6 falsos negativos. Esse desempenho destaca a alta precisão do Random Forest.


Figura 78. Matriz de Confusão do modelo Random Forest



Fonte: Autor

A matriz de confusão apresentada na Figura 79 mostra o desempenho do modelo Logistic Regression. Na classe Normal (saudável), o modelo classificou corretamente 91 das 93 amostras, gerando 2 falsos positivos. Para a classe com falha, o modelo identificou corretamente 74 das 92 amostras. A capacidade de detectar falhas foi menor devido a quantidade de falsos negativos.


Figura 79. Matriz de Confusão do modelo Logistic Regression



Fonte: Autor


A matriz de confusão na Figura 80 apresenta o desempenho do modelo Gradient Boosting. Para a classe Normal (saudável), o modelo classificou corretamente todas as 93 amostras, sem registrar falsos positivos. Já na classe com falha, o modelo identificou corretamente 85 das 92 amostras, com 7 falsos negativos. Esses resultados destacam a alta eficácia do modelo.

Figura 80. Matriz de Confusão do modelo Gradient Boosting




Na Figura 81, a matriz de confusão do modelo SVM com kernel linear é apresentada. O modelo classificou corretamente 92 das 93 amostras da classe Normal (saudável), resultando em apenas 1 falso positivo. Para a classe com falha, 74 das 92 amostras foram classificadas corretamente, enquanto 18 foram identificadas como falsos negativos. Embora apresente bom desempenho na classe Normal (saudável), a taxa de falsos negativos para a classe com falha não é eficiente.

Figura 81. Matriz de Confusão do modelo Support Vector Machine (Linear)



A Figura 82 apresenta a matriz de confusão do modelo SVM com kernel RBF. O modelo classificou corretamente 90 das 93 amostras da classe Normal (saudável), com 3 falsos positivos. Na classe com falha, 76 das 92 amostras foram classificadas corretamente, enquanto 16 amostras foram classificadas como classe Normal.

Figura 82. Matriz de Confusão do modelo Support Vector Machine (Radial Basis Function Kernel)




Ao avaliar as matrizes de confusão obtidas durante os experimentos, verificou-se que os modelos Random Forest, Gradient Boosting e XGBoost apresentaram

desempenho superior em relação aos demais, destacando-se pelas maiores médias de acertos tanto para a classe Normal (rolamento saudável) quanto para a classe com falha. Além disso, o número reduzido de falsos positivos e falsos negativos obtidos por esses modelos evidenciam sua robustez na tarefa de classificação, demonstrando alta precisão na distinção entre condições normais e de falha dos rolamentos.

#### 4.12.5. ANÁLISE DE DESEMPENHO DOS MODELOS DE MACHINE LEARNING EM CENÁRIOS MULTICLASSE

A Figura 83 apresenta a matriz de confusão do modelo XGBoost. O modelo classificou corretamente 42 das 43 amostras da classe Normal (saudável), apresentando 1 falso positivo. Para a classe Inner Race, 38 das 43 amostras foram classificadas corretamente, enquanto 5 foram confundidas com a classe Ball Data. Já para a classe Ball Data, o modelo identificou corretamente 32 das 44 amostras, com 12 classificadas incorretamente como Inner Race. Por fim, na classe Outer Race, 34 das 43 amostras foram corretamente previstas, com 7 sendo classificadas erroneamente como Normal e 2 como Inner Race. O modelo XGBoost obteve uma acurácia geral de 0,84, destacando a eficácia do modelo na tarefa de classificação multiclases para detecção de falhas em rolamentos.

Figura 83. Matriz de Confusão Multiclasse do modelo XGBoost




Fonte: Autor



A Figura 84 apresenta a matriz de confusão referente ao modelo Random Forest. Observa-se que o modelo classificou de forma correta 42 das 43 amostras pertencentes à classe Normal (saudável), apresentando apenas 1 classificação incorreta. Para a classe Inner Race, 36 das 43 amostras foram classificadas corretamente, enquanto 7 foram classificadas de forma incorreta como Ball Data. Em relação à classe Ball Data, o modelo classificou corretamente 36 das 44 amostras, com 8 sendo atribuídas incorretamente à classe Inner Race. Já para a classe Outer Race, 33 das 43 amostras foram classificadas corretamente, sendo que 7 foram classificadas como Normal e 3 como Inner Race. A acurácia geral do modelo foi de 0,85, evidencia a capacidade do Random Forest em distinguir, com precisão, diferentes tipos de falhas, além de identificar a condição normal dos rolamentos.


Figura 84. Matriz de Confusão Multiclasse do modelo Random Forest



A Figura 85 apresenta a matriz de confusão referente ao modelo Gradient Boosting. Observa-se que o modelo classificou de forma correta 39 das 43 amostras pertencentes à classe Normal (saudável), apresentando 4 classificações incorretas atribuídas à classe Outer Race. Para a classe Inner Race, 35 das 43 amostras foram classificadas corretamente, enquanto 8 foram indevidamente atribuídas à classe Ball Data. Em relação à classe Ball Data, o modelo classificou corretamente 36 das 44 amostras, com as 8 restantes sendo classificadas de forma incorreta como Inner Race.

Já para a classe Outer Race, 36 das 43 amostras foram corretamente classificadas, sendo 6 classificadas como Normal e 1 como Inner Race. Esse desempenho demonstra a capacidade do modelo Gradient Boosting em realizar a classificação multiclasse com boa precisão, especialmente nas classes Ball Data e Outer Race.

Figura 85. Matriz de Confusão Multiclasse do modelo Gradient Boosting



Fonte: Autor

No contexto da avaliação por meio das matrizes de confusão multiclasse, foram selecionados para análise os modelos Random Forest, Gradient Boosting e XGBoost, uma vez que esses algoritmos apresentaram os melhores desempenhos em todas as avaliações realizadas, superando as demais abordagens testadas. Com acurácias variando entre 0,84 e 0,85, os modelos demonstraram elevada capacidade de generalização e consistência na tarefa de classificação multiclasse, o que justifica sua escolha para uma análise mais aprofundada na detecção de falhas em rolamentos.

A adoção de uma abordagem multiclasse no processo de classificação traz vantagens significativas na avaliação do desempenho dos modelos. Isso se deve ao fato de que, além de identificar a presença de falhas, a abordagem permite distinguir com precisão o tipo específico de anomalia. Tais anomalias incluem falhas na pista interna (Inner Race), no elemento rolante (Ball Data) e na pista externa (Outer Race). A capacidade de identificação detalhada é essencial para a implementação de

sistemas de monitoramento eficazes, capaz de alertar para a falha, e para a localização e tipo da falha, o que contribui para a manutenção preditiva eficiente e direcionada.

Estudos anteriores destacam a eficácia desses modelos na detecção e classificação de falhas em sistemas mecânicos. O Random Forest tem sido amplamente aplicado, como no trabalho de (QUIROZ et al. 2017), que obteve uma acurácia de 98,8% na classificação de falhas em motores de indução. O Gradient Boosting se destaca, como demonstrado por (PANI et al. 2020), que utiliza o algoritmo para detectar falhas internas em transformadores, alcançando desempenho superior a outros modelos. Por sua vez, o XGBoost foi utilizado por (WANG et al. 2021), na detecção de falhas em rolamentos, apresentando uma acurácia média de 97%.

Esses resultados reforçam a aplicabilidade de técnicas baseadas em aprendizado de máquina, como o Random Forest, Gradient Boosting e XGBoost, para a detecção de falhas em rolamentos, comprovando a capacidade desses modelos não apenas em identificar falhas, mas também em classificar diferentes tipos de anomalias, fundamentais para a precisão e eficácia da manutenção preditiva em sistemas industriais.

## 5. CONCLUSÕES

O presente estudo aborda a relevância dos motores elétricos de indução trifásicos (MIT), amplamente empregados nos setores industriais, comerciais e residenciais, devido à sua eficiência energética e robustez operacional. Esses motores, responsáveis por uma parcela significativa do consumo de energia elétrica em economias industrializadas, encontram-se no centro de inovações tecnológicas voltadas para a manutenção preditiva e o diagnóstico de falhas, essenciais para garantir sua confiabilidade e durabilidade.

As falhas em rolamentos, componentes críticos para o funcionamento adequado dos motores, foram analisadas sob a perspectiva de seu impacto na continuidade operacional e nos custos associados à manutenção. A análise de vibração foi empregada como método para identificar alterações precoces nos padrões vibracionais, relacionadas a anomalias nos rolamentos. A avaliação das frequências características associadas às falhas demonstrou sua importância para a compreensão das condições operacionais e para a mitigação de danos.

No desenvolvimento do estudo, a Decomposição em Modo Empírico (EMD) foi aplicada como técnica avançada de processamento de sinais, devido à sua capacidade de decompor sinais não lineares e não estacionários. O método permitiu a extração de Funções de Modo Intrínseco (IMFs), proporcionando uma análise detalhada das características específicas dos sinais de vibração. Essa abordagem viabilizou a identificação de componentes relevantes associados a falhas, contribuindo para um diagnóstico mais preciso.

A integração do EMD com algoritmos de aprendizado de máquina possibilitou a classificação entre condições saudáveis e defeituosas de maneira eficaz. Modelos como Random Forest, Gradient Boosting e XGBoost foram empregados para análise, demonstrando alto desempenho na distinção de padrões vibracionais. Essa combinação de técnicas evidenciou o potencial de sistemas de monitoramento baseados em dados para otimizar a gestão de manutenção e aumentar a confiabilidade operacional.

O estudo apresenta contribuições significativas para o campo da manutenção preditiva de motores elétricos, ao propor a integração de análise de vibração, EMD e aprendizado de máquina como ferramentas para aprimorar o diagnóstico de falhas em

rolamentos. Essa abordagem oferece suporte para o desenvolvimento de estratégias robustas, capazes de promover maior eficiência operacional e reduzir custos associados a paradas não programadas. A aplicação dessas metodologias destaca o papel da pesquisa científica no avanço tecnológico e na sustentabilidade dos sistemas industriais.

Os resultados obtidos confirmam a eficácia da abordagem proposta, evidenciando que a aplicação combinada de EMD e algoritmos de aprendizado de máquina foi bem-sucedida na detecção e classificação de falhas em rolamentos. Os modelos utilizados apresentaram elevado desempenho, com boas acurácias, validando a viabilidade do método.

## 5.1. CONTRIBUIÇÃO PARA A ÁREA

A pesquisa contribui para o entendimento da confiabilidade de motores elétricos de indução trifásicos, com abordagem nas falhas em rolamentos. São apresentados elementos que auxiliam na formulação de estratégias de manutenção eficaz, evitando impactos adversos ao desempenho e preservando a integridade do sistema. A classificação de rolamentos é abordada como um componente central para a operação eficiente dos motores, considerando sua influência na precisão dos movimentos, na sustentabilidade e na eficiência industrial.

O estudo destaca a detecção de falhas em rolamentos como um aspecto essencial para a manutenção preditiva, utilizando a análise de vibração no domínio do tempo como base metodológica. Essa abordagem permite a identificação de padrões específicos de vibração associados a anomalias, possibilitando a mitigação de falhas antes que gerem paradas não planejadas ou custos elevados de manutenção.

A aplicação da Decomposição em Modo Empírico (EMD) é explorada como uma técnica para o processamento de sinais vibracionais, devido à sua capacidade de analisar sinais não lineares e não estacionários. Integrado aos dados de vibração, o EMD facilita a remoção de características relevantes que são importantes para o diagnóstico de falhas em rolamentos. Essa metodologia representa um avanço no campo da manutenção preditiva, oferecendo meios para melhorar a confiabilidade operacional.

O estudo amplia as possibilidades de pesquisa na área de manutenção e análise de falhas, integrando técnicas de processamento de sinais com métodos de detecção baseados em dados. A proposta apresentada ressalta a relevância de desenvolver ferramentas que combinem eficiência técnica e impacto econômico industrial positivo, promovendo a sustentabilidade e a longevidade dos sistemas.

A análise das características estatísticas evidencia a importância da seleção das estatísticas para a detecção de falhas em rolamentos. A identificação das características significativas permite aprimorar os modelos de diagnóstico, diminuindo falsos positivos e aumentando a confiabilidade. Desta forma, a pesquisa contribui para o avanço teórico na seleção de atributos para análise de vibração e manutenção preditiva.

## 6. REFERÊNCIAS

- AL-NAJJAR, Basim. The lack of maintenance and not maintenance which costs: A model to describe and quantify the impact of vibration-based maintenance on the company's business. *International Journal of Production Economics*, v. 107, n. 1, p. 260-273, 2007.
- ANTONINO-DAVIU, Jose. Electrical monitoring under transient conditions: A new paradigm in electric motors predictive maintenance. *Applied Sciences*, v. 10, n. 17, p. 6137, 2020. <https://doi.org/10.3390/app10176137>.
- Ayyappan, GS, Narayanan, NK, RRM, VR Pandi, Angel, TS, and Babu, BR. Electrical Motor Maintenance Techniques and Life Cycle Assessment - A Review with Case Studies. 2019 2nd International Conference on Power and Embedded Drive Control (ICPEDC), Chennai, India, 2019.
- A. Shahidi, LA Gupta, A. Kovacs e D. Peroulis, "Sensor de temperatura e vibração sem fio para monitoramento de condições de rolamentos em tempo real", 2013 IEEE MTT-S International Microwave Symposium Digest (MTT) , Seattle, WA, EUA, 2013, pp. 1-4, doi: 10.1109/MWSYM.2013.6697670.
- Blodt, M., Granjon, P., Raison, B., and Rostaing, G. Models for bearing damage detection in induction motors using stator current monitoring. *IEEE Transactions on Industrial Electronics*, vol. 55, no. 4, pp. 1813-1822, April 2008. doi: 10.1109/TIE.2008.917108.
- Boudraa, A.-O., and Cexus, J.-C. EMD-based signal filtering. *IEEE Transactions on Instrumentation and Measurement*, vol. 56, no. 6, pp. 2196-2202, Dec. 2007. doi: 10.1109/TIM.2007.907967.
- Breiman, L. Florestas aleatórias. *Aprendizado de máquina* 45, 5–32 (2001). <https://doi.org/10.1023/A:1010933404324>
- Brusamarello, B., Cardozo da Silva, JC, Morais Sousa, K. de and Guarneri, GA. Detecção de falhas em rolamentos em motores de indução trifásicos usando máquina de vetores de suporte e grade de Bragg em fibra. *IEEE Sensors Journal*, vol. 23, no. 5, pp. 4413-4421, March 2023. doi: 10.1109/JSEN.2022.3167632.
- Campos, Rodrigo Cesar et al. 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, 2022.
- Case Western Reserve. Rolamentos. 2023. Disponível em: <[www.case.edu](http://www.case.edu)>.
- Chen, Zhuyun; Gryllias, Konstantinos; Li, Weihua. Mechanical fault diagnosis using convolutional neural network and extreme learning machine. *Mechanical Systems and Signal Processing*, v. 133, p. 106272, 2019.
- Cortes, C., Vapnik, V. Support-vector networks. *Mach Learn* 20, 273–297 (1995). <https://doi.org/10.1007/BF00994018>
- DE LIMA, V. F., Rodrigues, M. C., Pinto, G. N., Britto, C. V. C. P., dos Santos Pinto, W. G., & de Oliveira, C. A. S. Estudo sobre Motores Elétricos de Alta Performance, 2022.
- DIONÍSIO, André Luiz et al. Implementando IoT na Gestão de Ativos. *Unisantia Science and Technology*, v. 10, n. 1, p. 27-39, 2023.
- DOU, Dongyang; YANG, Jianguo; LIU, Jiongtian; ZHAO, Yingkai. A rule-based intelligent method for fault diagnosis of rotating machinery. *Knowledge-Based Systems*, v. 36, p. 1-8, 2012. ISSN 0950-7051. Disponível em: <https://doi.org/10.1016/j.knsys.2012.05.013>.
- EL Galvão & Cia. Saiba sobre rolamentos. 2023. Disponível em: <[www.elgalvao.com.br](http://www.elgalvao.com.br)>.
- Fontes Godoy, W.; Morinigo-Sotelo, D.; Duque-Perez, O.; Nunes da Silva, I.; Goedtel, A.; Palácios, RHC. Estimativa da severidade de falhas em mancais em motores de indução trifásicos conectados em linha e alimentados por inversor. *Energies*, 2020, 13, 3481. <https://doi.org/10.3390/en13133481>.
- Flandrin, P., Rilling, G., and Goncalves, P. Empirical mode decomposition as a filter bank. *IEEE Signal Processing Letters*, vol. 11, no. 2, pp. 112-114, Feb. 2004. doi: 10.1109/LSP.2003.821662.

Frosini, L., and Bassi, E. Stator current and motor efficiency as indicators for different types of bearing faults in induction motors. *IEEE Transactions on Industrial Electronics*, vol. 57, no. 1, pp. 244-251, Jan. 2010. doi: 10.1109/TIE.2009.2026770.

GA Pradipta, R. Wardoyo, A. Musdholifah, INH Sanjaya e M. Ismail, "SMOTE para lidar com problemas de dados desbalanceados: uma revisão", *Sexta Conferência Internacional sobre Informática e Computação (ICIC) de 2021*, Jacarta, Indonésia, 2021, pp. 1-8, doi: 10.1109/ICIC54025.2021.9632912. palavraschave:{Avaliaçãodedesempenho;Informática;dadosdesbalanceados;sobreamostragem;SMOTE;Classificação desbalanceada;Dados sintéticos},

G.F. Bin, J.J. Gao, X.J. Li, B.S. Dhillon, Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network, *Mechanical Systems and Signal Processing*, Volume 27, 2012, Pages 696-711, ISSN 0888-3270, <https://doi.org/10.1016/j.ymssp.2011.08.002>.

Guo, Youguang, Xin Ba, Lin Liu, Haiyan Lu, Gang Lei, Wenliang Yin, and Jianguo Zhu. A Review of Electric Motors with Soft Magnetic Composite Cores for Electric Drives. *Energies*, 16, no. 4: 2053, 2023. <https://doi.org/10.3390/en16042053>.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer Science & Business Media.

HOLANDA, Sandra Maria Santos. Aplicação da manutenção preditiva por análise de vibrações em equipamentos de trens urbanos com plano de manutenção proposto. *Dissertação de Mestrado*, Universidade Federal de Pernambuco, 2016.

Huang, N. E., Shen, Z., Long, S. R., et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, v. 454, n. 1971, p. 903-995, 1998.

Huang, NE, Shen, Z., & Wu, MC (2008). "Aplicações da Transformada de Hilbert-Huang na Análise de Sinais Biomédicos." *Proceedings of the IEEE* , 96(5), 1114–1131.

Jin, Xiaohang, Yuan, Fang, Chow, Tommy W.S., and Zhao, Mingbo. Weighted local and global regressive mapping: A new manifold learning method for machine fault classification. *Engineering Applications of Artificial Intelligence*, v. 30, p. 118-128, 2014.

Kopsinis, Y., and McLaughlin, S. Development of EMD-based denoising methods inspired by wavelet thresholding. *IEEE Transactions on Signal Processing*, vol. 57, no. 4, pp. 1351-1362, April 2009. doi: 10.1109/TSP.2009.2013885.

Kudelina, K., Vaimann, T., Rassõlkin, A., and Kallaste, A. Impacto de falhas de rolamento no nível de vibração do motor BLDC. *IECON 2021 – 47ª Conferência Anual da IEEE Industrial Electronics Society*, Toronto, ON, Canadá, 2021. doi: 10.1109/IECON48115.2021.9589268.

Lacey, S. The Role of Vibration Monitoring in Predictive Maintenance. *Asset Management & Maintenance Journal*, 24(1), 42–51, 2011.

LeCun, Y., Bengio, Y. & Hinton, G. Aprendizagem profunda. *Natureza* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>

Lei, Y., He, Z., & Zi, Y. (2013). "Aplicação de EMD e Análise de Envelope para Diagnóstico de Falhas em Rolamentos." *Mechanical Systems and Signal Processing* , 35(1-2), 192–204.

MACEDO, Carlos Castro de. Programa de manutenção na indústria têxtil. 2012.

Manutenção Predial. Análise de vibração, conceito e aplicação. 2023. Disponível em: <[www.manutencaopredial.blog.br](http://www.manutencaopredial.blog.br)>.

Mundo da Elétrica. Principais causas de falhas em motores elétricos. 2023. Disponível em: <[www.mundodaeletrica.com.br](http://www.mundodaeletrica.com.br)>.

MURUGESAN, V. et al. Analysis of an angular contact ball bearing failure and strategies for failure prevention. *Journal of Failure Analysis and Prevention*, v. 18, p. 471-485, 2018.



Narang, A., Singh, K., Gaur, H., Anakiya, A., Kiran, M. B., and Thakur, S. Previsão da vida útil restante de rolamentos de esferas usando técnicas de aprendizado profundo. 2024 14ª Conferência Internacional sobre Computação em Nuvem, Ciência de Dados e Engenharia (Confluence), Noida, Índia, 2024. doi: 10.1109/Confluence60223.2024.10463495.

Natekin A e Knoll A (2013) Gradient boosting machines, a tutorial. *Frente. Neurorobot.* **7**:21. doi: 10.3389/fnbot.2013.00021

Nguyen-Schäfer, Hung. Computational design of rolling bearings. Switzerland: Springer International Publishing, 2016.

N. Zaiets and I. Kondratenko, Desenvolvimento de um sistema inteligente para prever a confiabilidade de motores elétricos. 2019 IEEE 39th International Conference on Electronics and Nanotechnology (ELNANO), Kiev, Ucrânia, 2019. doi: 10.1109/ELNANO.2019.8783564.

PANI, S. R.; SINGH, R.; SINGH, J. K. Fault detection in power transformers using Gradient Boosting algorithm. *IEEE Transactions on Industrial Electronics*, v. 67, n. 6, p. 5254-5262, 2020.

PEDREGOSA, F. et al. *Scikit-learn: Machine Learning in Python*. Journal of Machine Learning Research, v. 12, p. 2825–2830, 2011.

PRUDHOM, Aurelien; ANTONINO-DAVIU, Jose; RAZIK, Hubert; CLIMENTE-ALARCON, Vicente. Time-frequency vibration analysis for the detection of motor damage caused by bearing currents. *Mechanical Systems and Signal Processing*, v. 84, Part A, p. 747-762, 2017. ISSN 0888-3270. Disponível em: <https://doi.org/10.1016/j.ymssp.2015.12.008>.

Pinto Molina, Ines. Empirical mode decomposition of wind speed signals. MS thesis. Universitat Politècnica de Catalunya, 2023.

QUIROZ, Miguel; OLIVEIRA, Thiago; SANTOS, Carlos. Fault detection in induction motors using Random Forest for classification of vibration signals. *Journal of Mechanical Engineering*, v. 65, n. 3, p. 259-270, 2017.

RANI, Parveen; PANDEY, Rajeshwari. Voltage differencing transconductance amplifier based fractional order multiple input single output universal filter. *Solid State Electronics Letters*, v. 1, n. 2, p. 110-118, 2019. ISSN 2589-2088. Disponível em: <https://doi.org/10.1016/j.ssel.2020.01.006>.

Ren, Ye, Suganthan, P. N., Srikanth, N. Ensemble methods for wind and solar power forecasting—A state-of-the-art review. *Renewable and Sustainable Energy Reviews*, v. 50, p. 82-91, 2015.

Riahi, M., and Ansarifard, M. Maintenance improvement of ball bearings for industrial applications. *International Journal of Industrial Engineering & Production Research*, vol. 19, no. 7, 2008.

Rilling, G., and Flandrin, P. One or two frequencies? The empirical mode decomposition answers. *IEEE Transactions on Signal Processing*, vol. 56, no. 1, pp. 85-95, Jan. 2008. doi: 10.1109/TSP.2007.906771.

Rottel Peças em Movimento. Rolamentos. 2023. Disponível em: <[www.rottel.com.br](http://www.rottel.com.br)>.

Schoen, R. R., Habetler, T. G., Kamran, F., and Bartfield, R. G. Motor bearing damage detection using stator current monitoring. *IEEE Transactions on Industry Applications*, vol. 31, no. 6, pp. 1274-1279, Nov.-Dec. 1995. doi: 10.1109/28.475697.

Sheikh, Muhammad Aman et al. A review to diagnose faults related to three-phase industrial induction motors. *Journal of Failure Analysis and Prevention*, v. 22, n. 4, p. 1546-1557, 2022.

SINGH, Sarabjeet et al. Numerical noise generation in modelling bearing vibration signals. In: INTER-NOISE and NOISE-CON Congress and Conference Proceedings. Institute of Noise Control Engineering p. 1309-1318.

Tianqi Chen e Carlos Guestrin. 2016. XGBoost: Um sistema de reforço de árvore escalável. Em Anais da 22ª Conferência Internacional ACM SIGKDD sobre Descoberta de Conhecimento e Mineração de Dados (KDD '16). Association for Computing Machinery, Nova York, NY, EUA, 785–794. <https://doi.org/10.1145/2939672.2939785>

Thomson, W. T., and Fenger, M. Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, vol. 7, no. 4, pp. 26-34, July-Aug. 2001. doi: 10.1109/2943.930988.

Tian, J., Morillo, C., Azarian, M. H., and Pecht, M. Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with K-nearest neighbor distance analysis. *IEEE Transactions on Industrial Electronics*, vol. 63, no. 3, pp. 1793-1803, March 2016. doi: 10.1109/TIE.2015.2509913.

Vapnik, V. (1998) Teoria da aprendizagem estatística. John Wiley & Sons, Chichester.

Vishwakarma, Manish, et al. "Vibration analysis & condition monitoring for rotating machines: a review." *Materials Today: Proceedings* 4.2 (2017): 2659-2664.

Wang, W. Analysis of Fault Detection in Rolling Element Bearings. *IEEE Instrumentation & Measurement Magazine*, vol. 24, no. 3, pp. 42-49, May 2021. doi: 10.1109/MIM.2021.9436098.

Wang, Yung-Hung, Yeh, Chien-Hung, Young, Hsu-Wen Vincent, Hu, Kun, and Lo, Men-Tzung. On the computational complexity of the empirical mode decomposition algorithm. *Physica A: Statistical Mechanics and its Applications*, v. 400, p. 159-167, 2014. <https://doi.org/10.1016/j.physa.2014.01.020>.

WEG. Motores Elétricos. 2023. Disponível em: <[www.weg.com.br](http://www.weg.com.br)>.

Wenxian Yang, Court, Richard. Experimental study on the optimum time for conducting bearing maintenance. *Measurement*, vol. 46, no. 8, pp. 2781-2791, 2013. doi: S0263224113001176.

Wuest, T., Weimer, D., Irgens, C., & Thoben, KD (2016). Aprendizado de máquina na manufatura: vantagens, desafios e aplicações. *Production & Manufacturing Research*, 4 (1), 23–45. <https://doi.org/10.1080/21693277.2016.1192517>

X. Hu, S. Peng e W. -L. Hwang, "EMD revisitado: nova compreensão do envelope e resolução do problema de mistura de modos em sinais AM-FM", em *IEEE Transactions on Signal Processing*, vol. 60, no. 3, pp. 1075-1086, março de 2012, doi: 10.1109/TSP.2011.2179650.

X. Zhang, B. Zhao e Y. Lin, "Diagnóstico de falhas de rolamentos baseado em aprendizado de máquina usando dados da Case Western Reserve University: revisão", em *IEEE Access*, vol. 9, pp. 155598-155608, 2021, doi: 10.1109/ACCESS.2021.3128669.

Y. Kopsinis and S. McLaughlin, Development of EMD-Based Denoising Methods Inspired by Wavelet Thresholding. *IEEE Transactions on Signal Processing*, vol. 57, no. 4, pp. 1351-1362, April 2009. doi: 10.1109/TSP.2009.2013885.

Zhu, L., Dai, W., Luo, G., and Du, R. Diagnóstico de falhas em rolamentos com base em análise de domínio de tempo e frequência e EMD. PHM-Qingdao 2019 Prognostics and Health Management Conference, Qingdao, China, 2019. doi: 10.1109/PHM-Qingdao46334.2019.8942926.