



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

RAUL BERNARDO DE PONTES PIRES

**DIAGNÓSTICO VIA ANÁLISE SONORA DA CONDIÇÃO DE
FUNCIONAMENTO E NÍVEL DE SEVERIDADE EM UM REDUTOR
COROA SEM-FIM UTILIZANDO REDES NEURAS ARTIFICIAIS**

**JOÃO PESSOA
2024**

RAUL BERNARDO DE PONTES PIRES

Diagnóstico via análise sonora da condição de funcionamento e nível de severidade em um redutor coroa sem-fim utilizando redes neurais artificiais

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica. Área de Concentração: Dinâmica e controle de sistema mecânicos

Orientador: Prof. Dr. Marcelo Cavalcanti Rodrigues

João Pessoa – PB

2024

DIAGNÓSTICO VIA ANÁLISE SONORA DA CONDIÇÃO DE FUNCIONAMENTO E NÍVEL DE SEVERIDADE EM UM REDUTOR COROA SEM-FIM UTILIZANDO REDES NEURAIAS ARTIFICIAIS

por

RAUL BERNARDO DE PONTES PIRES
Dissertação aprovada em 18 de dezembro de 2024

Documento assinado digitalmente
 **MARCELO CAVALCANTI RODRIGUES**
Data: 19/12/2024 10:57:58-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcelo Cavalcanti Rodrigues
Orientador – UFPB

Documento assinado digitalmente
 **ABEL CAVALCANTE LIMA FILHO**
Data: 19/12/2024 09:33:55-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Abel Cavalcante Lima Filho
Examinador Interno – UFPB

Documento assinado digitalmente
 **KOJE DANIEL VASCONCELOS MISHINA**
Data: 19/12/2024 10:39:02-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Kojé Daniel Vasconcelos Mishina
Examinador Externo – UFPB

Documento assinado digitalmente
 **ANDERSSON GUIMARAES OLIVEIRA**
Data: 19/12/2024 08:52:46-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Andersson Guimaraes Oliveira
Examinador Externo – UFCG

Catálogo na publicação
Seção de Catalogação e Classificação

P667d Pires, Raul Bernardo de Pontes.

Diagnóstico via análise sonora da condição de funcionamento e nível de severidade em um redutor coroa sem-fim utilizando redes neurais artificiais / Raul Bernardo de Pontes Pires. - João Pessoa, 2024.
158 f. : il.

Orientação: Marcelo Cavalcanti Rodrigues.
Dissertação (Mestrado) - CT/PPGEM.

1. Redutor coroa sem fim. 2. Diagnóstico inteligente. 3. Análise sonora. 4. Redes neurais artificiais. 5. Dano - nível de severidade. I. Rodrigues, Marcelo Cavalcanti. II. Título.

UFPB/BC

CDU 62-531.6(043)

Dedico este trabalho aos meus pais José Bernardo Pires Filho e Severina Xavier de Pontes Pires, aos meus irmãos e toda minha família.

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, por me conceder saúde e determinação para superar todos os desafios ao longo dessa jornada.

Aos meus pais, José Bernardo Pires Filho e Severina Xavier de Pontes Pires, expresso minha gratidão pelo amor incondicional, apoio e incentivo constantes, e por investirem nos meus estudos ao longo de toda minha vida. Esses valores foram essenciais na construção de minha formação moral e acadêmica.

Aos meus irmãos Matheus Bernardo de Pontes Pires e Arthur Bernardo de Pontes Pires, pelo companheirismo e apoio constante.

À minha noiva, Rafaella Caroline Araújo dos Santos, sou profundamente grato pelo amor, paciência e apoio incondicional em cada etapa dessa jornada. Sua presença ao meu lado foi essencial para que eu pudesse enfrentar todos os desafios com mais leveza e determinação.

Lembro com carinho e saudade de meus avôs José Bernardo [in memoriam], Raimunda Mesquita Pires [in memoriam] e Maria das Mercês [in memoriam], que deixaram um legado valioso e contribuíram diretamente para minha formação acadêmica e social.

Expresso meu sincero agradecimento ao meu orientador, professor Dr. Marcelo Cavalcanti Rodrigues, por seus ensinamentos, dedicação e orientação ao longo dessa jornada acadêmica. Seus ensinamentos e conselhos foram fundamentais para o desenvolvimento dessa dissertação e para o meu desenvolvimento como pesquisador.

Por fim, agradeço a todos os professores que guiaram o meu aprendizado e me ajudaram a trilhar esse caminho.

Entrega o teu caminho ao teu Deus, confia nele, e o mais ele fará" (Salmos 37: 5)

RESUMO

Neste trabalho foi desenvolvido um sistema de diagnóstico inteligente para identificação das condições operacionais de um redutor coroa sem fim. Foi construída uma bancada experimental para reproduzir diferentes condições de funcionamento e níveis de severidade, partindo do estado de referência (bom estado). Entre as condições testadas, incluem-se o desalinhamento angular, sobrecarga e lubrificação ineficiente. Na bancada foi implementado um sistema de aquisição de dados para análise de vibrações, utilizando basicamente um Arduino e um acelerômetro MPU 6050, e análise sonora a partir de um smartphone. Os dados de vibração foram utilizados para validar a dinâmica do sistema e realizar a análise comparativa com os sinais sonoros via Transformada Rápida de Fourier (FFT). Já para os sinais sonoros foram feitas análises no domínio do tempo, através de técnicas estatísticas como Curtose, Fator de Crista e RMS; no domínio da frequência por meio da Transformada Rápida de Fourier (FFT) e no domínio tempo – frequência utilizando a Transformada de Wavelet. Um sistema para diagnóstico inteligente foi desenvolvido composto por duas redes neurais: uma responsável pela classificação da condição de funcionamento (estado de referência, desalinhamento angular, sobrecarga e lubrificação ineficiente) e outra para identificação dos níveis de severidades (leve, média e grave). A acurácia obtida para classificação da condição de funcionamento foi de 98,889% e para severidade de 98,045%. Na validação cruzada obteve-se 97,738% de acurácia média para a RNA de condição de funcionamento e 97,403% de acurácia média para a RNA de nível de severidade. A partir dos resultados obtidos, verificou-se que os sinais sonoros em conjunto com a RNA, se mostraram eficazes para a definição das condições operacionais.

Palavras – chave: diagnóstico inteligente, severidade, dano, redutor coroa sem fim, análise sonora, redes neurais artificiais.

ABSTRACT

This work developed an intelligent diagnostic system for identifying the operational conditions of a worm gear reducer. An experimental setup was built to reproduce different operating conditions and severity levels, starting from the reference state (good condition). Among the tested conditions are angular misalignment, overload, and inefficient lubrication. The setup incorporated a data acquisition system for vibration analysis, primarily using an Arduino and an MPU 6050 accelerometer, as well as sound analysis via a smartphone. The vibration data were used to validate the system's dynamics and perform a comparative analysis with the sound signals through Fast Fourier Transform (FFT). For the sound signals, analyses were performed in the time domain using statistical techniques such as Kurtosis, Crest Factor, and RMS; in the frequency domain using the Fast Fourier Transform (FFT); and in the time-frequency domain using the Wavelet Transform. An intelligent diagnostic system was developed, consisting of two neural networks: one responsible for classifying the operational condition (reference state, angular misalignment, overload, and inefficient lubrication) and another for identifying severity levels (mild, medium, and severe). The accuracy achieved for operational condition classification was 98.889%, and for severity classification, it was 98.045%. In cross-validation, the average accuracy obtained was 97.738% for the operational condition neural network and 97.403% for the severity level neural network. Based on the results, it was found that sound signals, in conjunction with the neural network, were effective in determining the operational conditions.

Keywords: Intelligent diagnostics, severity, damage, worm gear reducer, sound analysis, artificial neural networks.

LISTA DE FIGURAS

Figura 1: Curva P-F e tarefas que precedem a falha funcional	25
Figura 2: Tipos de redutores	27
Figura 3: Redutor parafuso sem-fim e coroa	29
Figura 4: Média, valor RMS e pico.	31
Figura 5: Distribuições para os 3 tipos de curtose.....	32
Figura 6: Forma de onda no domínio do tempo e frequência.....	35
Figura 7: Resolução tempo-frequência da (a) STFT e (b) WT.....	38
Figura 8: Processo básico de decomposição Multiresolução (MRA)	42
Figura 9: Decomposição de um sinal (a) sem downsampling e (b) com downsampling	42
Figura 10: Exemplo de filtragem com downsampling com um sinal senoidal	43
Figura 11: Árvore de decomposição da wavelet de um sinal em 3 níveis.....	43
Figura 12: Espectro de frequência de vibração padrão de um rolamento operando em uma condição de baixa lubrificação.	47
Figura 13: Espectro de aceleração indicando quebra do filme lubrificante	48
Figura 14: Lubrificação insuficiente dos mancais do gerador: (a) sinal temporal do mancal 1; (b) espectro de Fourier do mancal 1; (c) espectro de envelope do mancal 1; (d) sinal temporal do mancal 2; (e) espectro de Fourier do mancal 2; (f) espectro de envelope do mancal 2	48
Figura 15: Espectro de frequência com vários níveis de lubrificação em redutor coroa sem fim.....	49
Figura 16: Gráfico FUPAI de severidade de vibração para redutores	53
Figura 17: Classificação e avaliação das máquinas por níveis de severidade de vibração.	54
Figura 18: – Faixas de severidade de vibrações conforme NBR 10082 (Banda de 10 a 1000Hz).	55
Figura 19: a) Espectros do som rotativo de cinco motores saudáveis; b) Espectros do som rotativo de motores defeituosos.....	57
Figura 20: a) Espectro sonoro, mostrando um pico relacionado ao efeito do desalinhamento angular para o valor da frequência de engrenamento encontrado experimentalmente; b) espectro do sinal sonoro após ser inserido um desalinhamento angular de 6 graus no eixo.....	57
Figura 21: O neurônio	58

Figura 22: Rede feedforward de camada única.....	61
Figura 23: Rede feedforward de múltiplas camadas.....	62
Figura 24: Redes recorrentes	63
Figura 25: Efeito do número de camadas ocultas.....	65
Figura 26: Fases de treinamento de uma rede MLP	66
Figura 27: Matriz de confusão simples.....	68
Figura 28: Método de validação cruzada usando k-fold.....	71
Figura 29: Fluxo da metodologia utilizada no trabalho.....	78
Figura 30: Projeto da bancada para reprodução das condições de funcionamento do redutor.....	80
Figura 31: Bancada experimental montada	80
Figura 32: Processo de (a) nivelamento e (b) alinhamento da bancada experimental ...	81
Figura 33: Verificação da frequência de rotação com o tacômetro	83
Figura 34: Condições de funcionamento reproduzidas na bancada experimental.....	84
Figura 35: Condição de referência.....	85
Figura 36: Reprodução da condição de desalinhamento angular	85
Figura 37: Reprodução da condição de sobrecarga	86
Figura 38: Redução do óleo do redutor para reprodução da condição de lubrificação ineficiente	86
Figura 39: Sistema para coleta dos dados de vibração	87
Figura 40: Orientação dos eixos de sensibilidade e polaridade de rotação.	88
Figura 41: Instrumentação para coleta de som do funcionamento do redutor.....	89
Figura 42: Fluxo do script para processamento e análise do sinal de vibração.....	90
Figura 43: Fluxograma do processamento e análise de sinais para os sinais sonoros....	91
Figura 44: Árvore de decomposição da wavelet do sinal sonoro em 11 níveis.....	92
Figura 45: Configuração do sistema de diagnóstico inteligente.....	93
Figura 46: Rede neural para classificação da condição de funcionamento	95
Figura 47: Rede neural para classificação do nível de severidade.	96
Figura 48: Espectro de frequência da análise de vibração para o estado de referência..	99
Figura 49: Espectro de frequência da análise de som para o estado de referência.....	100
Figura 50: Energia dos detalhes da Wavelet para condição de referência.....	101
Figura 51: Espectro de frequência da análise de vibração para desalinhamento angular de 1°	102

Figura 52: Espectro de frequência da análise de vibração para desalinhamento angular de 1,5°.....	103
Figura 53: Espectro de frequência da análise de vibração para desalinhamento angular de 2°.....	104
Figura 54: Espectro de frequência da análise de som para desalinhamento de 1°	104
Figura 55: Espectro de frequência da análise de som para desalinhamento de 1,5°	105
Figura 56: Espectro de frequência da análise de som para desalinhamento de 2°	105
Figura 57: Espectro de frequência 3D para análise sonora do desalinhamento angular	106
Figura 58: Energia dos detalhes da Wavelet para desalinhamento angular.....	107
Figura 59: Curvas de curtose para desalinhamento angular	108
Figura 60: Valores de curtose para desalinhamento angular	109
Figura 61: Valores de RMS para desalinhamento angular	110
Figura 62: Valores de Fator de crista para desalinhamento angular	111
Figura 63: Espectro de frequência da análise de vibração para sobrecarga com torque de 62 N.m gerado pela aplicação de massa de 9 kg na extremidade do braço mecânico ..	112
Figura 64: Espectro de frequência da análise de vibração para sobrecarga com torque de 84 N.m gerado pela aplicação de massa de 12 kg na extremidade do braço mecânico	112
Figura 65: Espectro de frequência da análise de vibração para sobrecarga com torque de 118 N.m gerado pela aplicação de massa de 17 kg na extremidade do braço mecânico	113
Figura 66: Espectro de frequência da análise de som para sobrecarga com torque de 62 N.m gerado pela aplicação de massa de 9 kg na extremidade do braço mecânico	113
Figura 67: Espectro de frequência da análise de som para sobrecarga com torque de 84 N.m gerado pela aplicação de massa de 12 kg na extremidade do braço mecânico	114
Figura 68: Espectro de frequência da análise de som para sobrecarga com torque de 118 N.m gerado pela aplicação de massa de 17 kg na extremidade do braço mecânico	114
Figura 69: Espectro de frequência 3D para análise sonora da sobrecarga	115
Figura 70: Energia dos detalhes da Wavelet para sobrecarga.....	117
Figura 71: Curvas de curtose para sobrecarga.....	118
Figura 72: Valores de curtose para sobrecarga	118
Figura 73: Valores de RMS para sobrecarga	119
Figura 74: Valores de Fator de Crista para sobrecarga	119

Figura 75: Espectro de frequência da análise de som para lubrificação insuficiente com redução de 50% do nível de óleo.....	121
Figura 76: Espectro de frequência da análise de som para lubrificação insuficiente com redução de 75% do nível de óleo.....	122
Figura 77: Espectro de frequência 3D para análise sonora da lubrificação ineficiente	123
Figura 78: Espectrograma de energia da Wavelet para lubrificação ineficiente.....	124
Figura 79: Curvas de Curtose para lubrificação ineficiente	125
Figura 80: Valores de curtose para lubrificação ineficiente	125
Figura 81: Valores de RMS para lubrificação ineficiente.....	126
Figura 82: Valores de Fator de Crista para lubrificação ineficiente	126
Figura 83: Energia nos diferentes níveis de decomposição para as condições de funcionamento reproduzidas.....	127
Figura 84: Curvas de Curtose para as condições de funcionamento reproduzidas	128
Figura 85: Valores de curtose para as condições de funcionamento reproduzidas.....	129
Figura 86: Valores de RMS para as condições de funcionamento reproduzidas.....	130
Figura 87: Valores de Fator de crista para as condições de funcionamento reproduzidas.	131
Figura 88: Matriz de confusão para classificação da condição de funcionamento.	132
Figura 89: Perda de Entropia cruzada ao longo das iterações para rede neural de classificação da condição de funcionamento.....	134
Figura 90: Matriz de confusão para classificação do nível de severidade.....	135
Figura 91: Perda de Entropia cruzada ao longo das iterações para rede neural de classificação da severidade.....	136

LISTA DE TABELAS

Tabela 1: Parâmetros passíveis de medição em manutenção preditiva	26
Tabela 2: Comportamento vibracional devido a desbalanceamento em sistemas rotativos.	45
Tabela 3: Comportamento vibracional devido a desalinhamento em sistemas rotativos	46
Tabela 4: Comportamento da frequência de engrenamento conforme condição de funcionamento	52
Tabela 5: Características do redutor	81
Tabela 6: Características do motor	82
Tabela 7: Características do acoplamento flexível	82
Tabela 8: Curtose, RMS e fator de crista para condição de referência.....	101
Tabela 9: Indicadores de desempenho para a rede neural de classificação da condição de funcionamento.	133
Tabela 10: Avaliação da quantidade de neurônios na camada oculta no desempenho da rede neural da condição de funcionamento	134
Tabela 11: Indicadores de desempenho para a rede neural de classificação de severidade	136
Tabela 12: Avaliação da quantidade de neurônios na camada oculta no desempenho da rede neural de severidade	137

LISTA DE SÍMBOLOS

RMS	Root mean square
Hz	Frequência em Hertz
ψ	Wavelet-mãe
$\psi_{a,b}(t)$	Função de discretização da wavelet
NBR	Norma brasileira regulamentadora
FFT	Transformada rápida de fourrier
DFT	Transformada discreta de fourrier
RNA	Rede neural artificial
CWT	Transformada contínua de wavelet
DWT	Transformada discreta de wavelet
db	Daubechies
STFT	Transformada de Fourier de Tempo Curto
cv	Unidade de potência em cavalos
kg	Massa em quilograma
rpm	Rotações por minuto
F_{cr}	Fator DE CRISTA
X_{pico}	Valor de pico
X_{RMS}	Valor de RMS
k	Curtose
$x(t)$	Sinal contínuo no tempo
$X(j\omega)$	Sinal no domínio da frequência
ω	Frequência do sinal.
$X(k)$	Amplitude da k -ésima componente harmônica
WT	Transformada de wavelet
cA	Coefficientes de aproximação do sinal
cD	Coefficientes de detalhe do sinal
f_e	Frequência de engrenamento
N	Número de dentes

f_r	Frequência de rotação
FUPAI	Fundação de Pesquisa e assessoramento à Indústria
ISO	<i>International Organization for Standardization</i>
VDI	<i>Verein Deutscher Ingenieure</i>
w_{kj}	Peso sináptico
MLP	<i>Multilayer Perceptron</i>
RBF	<i>Radial basis function</i>
VP	Verdadeiro positivo
VN	Verdadeiro negativo
FP	Falso positivo
FN	Falso negativo
DNN	Redes neurais profundas
AE	Sinais acústicos
AWM	análise wavelet multiresolução
PMC	Rede neural Perceptron Multicamadas
WPD	<i>Wavelet Packet Decomposition</i>
DCNN	Redes convolucionais profundas
RUL	Previsão de vida útil
A	Aproximação
D	Detalhes
a	Parâmetro de escalonamento
b	Coefficiente de translação
L	Unidade de volume em litros

SUMÁRIO

1. INTRODUÇÃO	19
1.1 Justificativa	21
1.2 Objetivo geral	22
1.3 Objetivos específicos	22
1.4 Delimitação	23
1.5 Organização da dissertação	23
2 FUDAMENTAÇÃO TEÓRICA	24
2.1 Manutenção preditiva	24
2.2 Redutor de engrenagens	27
2.2.1 Redutor parafuso sem fim e coroa	28
2.3 Técnicas de processamento de sinais	29
2.3.1 Técnicas no domínio do tempo	30
2.3.1.1 Desvio padrão	30
2.3.1.2 RMS	30
2.3.1.3 Fator de crista	31
2.3.1.4 Curtose	31
2.3.2 Técnicas no domínio da frequência	32
2.3.2.1 Transformada de Fourier	33
2.3.3 Técnicas no domínio tempo-frequência	36
2.3.3.1 Transformada de Fourier de tempo curto (STFT)	36
2.3.3.2 Transformada de Wavelet	37
2.4 Análise de vibração em máquinas rotativas	44
2.4.1 Fontes de vibração em máquinas rotativas	44
2.4.2 Vibrações em redutores	49
2.4.3 Carta de severidade FUPAI	53

2.4.4	Normas para análise de vibração	53
2.5	Análise sonora aplicada a máquinas rotativas	56
2.6	Redes neurais artificiais	58
2.6.1	Conceito.....	58
2.6.2	O neurônio	58
2.6.3	Arquitetura de redes neurais artificiais	60
2.6.4	Processo de treinamento de uma RNA.....	63
2.6.5	Redes MLP– <i>Multiple Layer Perceptrons</i>	65
2.6.6	Métricas de desempenho	67
2.6.6.1	Matriz de confusão.....	68
2.6.6.2	Acurácia	69
2.6.6.3	Recall	69
2.6.6.4	Precisão.....	69
2.6.6.5	F1-score	69
2.6.6.6	Validação cruzada	70
3	REVISÃO DA LITERATURA	72
4	METODOLOGIA	78
4.1	Projeto, construção e montagem da bancada experimental	79
4.2	Verificação da frequência de rotação e engrenamento.....	83
4.3	Reprodução das condições de funcionamento da bancada	84
4.4	Coleta de dados	87
4.4.1	Vibração.....	87
4.4.2	Som.....	88
4.5	Processamento e análise dos dados.....	89
4.5.1	Vibração.....	89
4.5.2	Som.....	90
4.6	Desenvolvimento do sistema inteligente	92

4.6.1	Rede neural para classificação de condição de funcionamento.....	94
4.6.2	Rede neural para classificação de severidade.....	95
5	RESULTADOS.....	98
5.1	Análise de vibração e som para condição de referência	98
5.2	Análise de vibração e som para condição de desalinhamento angular	102
5.3	Análise de vibração e som para condição de sobrecarga	111
5.4	Análise de vibração e som para condição de lubrificação ineficiente	120
5.5	Comparação global das condições de funcionamento reproduzidas.....	127
5.6	Análise de desempenho das redes neurais do sistema de diagnóstico	131
5.6.1	Desempenho da rede neural artificial de classificação de condição de funcionamento.....	131
5.6.2	Desempenho da rede neural artificial de classificação do nível de severidade	134
6	CONCLUSÃO	138
6.1	Trabalhos futuros	139
7	REFERÊNCIAS.....	140

1. INTRODUÇÃO

Wan et al. (2017) afirmam que na indústria, a manutenção de equipamentos exerce um papel crucial, influenciando o tempo de operação e a eficiência dos ativos. A detecção e resolução de falhas são essenciais para evitar interrupções nos processos de produção. Conforme salientado por Pereira (2018), a abordagem contemporânea da manutenção não se limita à correção de falhas, mas também busca definir o estágio de potenciais falhas inesperadas na operação do sistema.

Segundo Holanda (2016), através do avanço da tecnologia e o desenvolvimento científico, surgiram diversas técnicas destinadas a acompanhar o estado dos equipamentos e determinar o momento mais apropriado para realizar as intervenções de manutenção. Estas técnicas compõem a chamada “Manutenção preditiva”, que se baseia no monitoramento do desempenho das máquinas e na identificação antecipada da ocorrência de falhas. Conforme destacado por Carvalho et al. (2019), o uso desta ferramenta tem como principal objetivo fornecer suporte à equipe responsável pela gestão da manutenção. O intuito é prevenir paradas não programadas e melhorar a disponibilidade dos ativos por meio de decisões embasadas a partir da estratégia de medição do estado de saúde dos equipamentos. Isso possibilita prever a tendência do comportamento do ativo e identificar potenciais riscos de falhas.

Segundo Figueiredo (2023), estima-se que o ônus financeiro decorrente de uma manutenção realizada tardiamente corresponde a uma parcela que varia de 15% a 60% dos custos totais de operação de toda a produção.

Araújo (2011) destaca que dentre os diversos equipamentos utilizados em indústrias e que requerem certa atenção com relação ao seu monitoramento, pode-se destacar os redutores, que segundo Aquino (2004), são dispositivos mecânicos aplicados na transmissão do movimento que exercem o papel de elemento fundamental de ligação entre máquinas motrizes e operatrizes, sendo essencial para ajustar a velocidade de rotação de saída das máquinas de acionamento para atender às necessidades específicas das máquinas operatrizes. Em aplicações industriais, qualquer falha ou necessidade de manutenção nos redutores pode resultar em interrupções na produção, acarretando consequências financeiras adversas para a empresa. Logo, de acordo com Araújo (2011), estes sistemas, demandam cuidado especial em virtude de problemas comuns, como aquecimento, vibrações, ruídos e lubrificação inadequada ou insuficiente nos seus componentes internos.

Pereira (2018), afirma que o fato da utilização de redutores de velocidade em larga escala na indústria, faz com que haja a necessidade de identificação dos sintomas de falhas de seus componentes ainda na fase inicial. A técnica de análise de vibração é frequentemente utilizada para este caso. Porém, segundo Wu e Chan (2009), sinais de emissão sonora de máquinas rotativas servem como uma alternativa promissora para o diagnóstico de falhas. Perez et al (2011), Khazaei et al (2013), Heydarzadeh et al (2016), Glowacz (2018), Yao et al (2018), Parey e Singh (2019) e Lyra (2019), abordaram métodos de identificação de condições de funcionamento em diferentes máquinas rotativas através da análise sonora.

Nos estudos iniciais, a análise de Fourier predominou como a principal ferramenta para a detecção de falhas em engrenagens. No entanto, a transformada de Fourier, apresenta algumas limitações atreladas a necessidade de os sinais serem periódicos e estacionários, caso contrário, o espectro de Fourier terá pouco significado físico. Os sinais de vibração e sonoros provenientes de caixas de engrenagens muitas vezes não são estacionários, refletindo processos não lineares, com componentes de frequência que variam ao longo do tempo. Para contornar esse problema são utilizados métodos de análise no domínio tempo-frequência, a exemplo da Transformada de Wavelet (OLIVEIRA NETO, 2023). No trabalho de Wang et al (1996), a Transformada de Wavelet foi aplicada ao diagnóstico de falhas em caixas de engrenagens de helicópteros, utilizando sinais de vibração. Chen et al (2019), propuseram um método baseado em Transformada de Wavelet Discreta e rede neural convolucional para diagnosticar falhas em caixas de engrenagens planetárias. Nguyen et al (2024), mostraram em seu trabalho que a Transformada de Wavelet é eficaz no diagnóstico de falhas em caixas de engrenagens operando em condições não estacionárias.

No campo de máquinas rotativas, o uso de algoritmos de Machine Learning tem crescido de forma exponencial, oferecendo soluções para várias questões associadas à operação, manutenção e projeto de máquinas e equipamento. Técnicas como redes neurais artificiais e redes neurais convolucionais, por exemplo, inseridas no contexto do Deep Learning, tornam possível a integração de dados obtidos através da aquisição física dos componentes mecânicos e vibratórios das máquinas. Esses algoritmos de reconhecimento de padrão, permitem prever condições futuras de vibração, identificar eminência de falhas e fornecer insights valiosos para a indústria (VIANA, 2023).

Nesta pesquisa, foi utilizado a análise sonora para identificação do nível de severidade e condições de funcionamento de um redutor coroa sem fim com auxílio de um sistema inteligente composto por duas redes neurais artificiais.

1.1 Justificativa

O diagnóstico de falhas e o monitoramento das condições de funcionamento de sistemas mecânicos, em especial em componentes críticos como redutores, são essenciais para a manutenção da eficiência operacional e da segurança em ambientes industriais. De acordo com Jing et al (2017), uma falha em caixas de engrenagens pode causar paradas não planejadas, perdas de produção e até mesmo acidentes fatais. Por isso a detecção eficaz dessas falhas é essencial para evitar incidentes e garantir a operação segura e eficiente.

Máquinas rotativas, que representam 40% de todas as máquinas industriais, são particularmente suscetíveis a falhas devido ao desgaste de componentes críticos como mancais, engrenagens e rotores (NATH et al, 2021). Métodos tradicionais de análise de falhas, muitas vezes são dependentes de inspeções manuais e experiência de técnicos especializados, sendo, portanto, onerosos, sujeitos a erros humanos e de baixa acuracidade na detecção de falhas incipientes para evitar paradas não planejadas. De acordo com Singh et al (2023), a detecção tradicional de falhas pode ser complexa e, em alguns casos, ineficaz, mas o monitoramento das condições de funcionamento através de inteligência artificial (IA) tem se mostrado eficaz para o diagnóstico automático de falhas, aumentando a precisão e eficiência. A IA permite que as indústrias reduzam a dependência de especialistas, uma vantagem relevante, levando em consideração o aumento de máquinas nas plantas industriais.

O diagnóstico das condições de funcionamento de máquinas rotativas, essencialmente, trata-se de reconhecer padrões associados ao equipamento. Nesse contexto a IA, uma poderosa ferramenta para reconhecer padrões, tem despertado interesse entre pesquisadores e mostrado grande potencial para aplicação na identificação das condições operacionais das máquinas (LIU et al, 2018).

Com base no levantamento de trabalhos aplicados no diagnóstico de falhas utilizando inteligência artificial aplicadas a redutores, grande parte está concentrada na identificação de defeitos relacionados a engrenagem, sem fornecer informações das condições operacionais do equipamento e nível de severidade para melhor guiar a equipe

de manutenção na elaboração de estratégias de atuação e definição do ponto ideal de intervenção. Com base nisso, esse trabalho tem por objetivo desenvolver uma metodologia de diagnóstico de condição de funcionamento e nível de severidade de dano, com auxílio de inteligência artificial e sinais sonoros captados através de um dispositivo comum, como smartphones, em substituição a métodos tradicionais que fazem uso de sensores de custo elevado e alta complexidade de diagnóstico, como a análise de vibração. A abordagem desenvolvida permite a detecção e classificação de falhas de forma prática e acessível.

1.2 Objetivo geral

- Desenvolver uma metodologia de diagnóstico para identificar condições de funcionamento e níveis de severidade de um redutor coroa sem-fim utilizando redes neurais artificiais e análise sonora.

1.3 Objetivos específicos

- Projetar e fabricar bancada experimental para reproduzir condições específicas de funcionamento;
- Reproduzir as seguintes condições de funcionamento do sistema rotativo: estado ideal, desalinhamento, sobrecarga e lubrificação ineficiente;
- Avaliar, através de análise de vibração, a dinâmica do sistema rotativo de acordo com as condições de funcionamento e níveis de severidade;
- Avaliar, através de análise sonora, o comportamento do sistema rotativo de acordo com as condições de funcionamento e níveis de severidade;
- Definir as características/extratores que apresentam variações significativas de acordo com o funcionamento dinâmico da máquina;
- Desenvolver rede neural artificial com eficiência maior que 94% que seja capaz de indicar a condição de funcionamento;
- Desenvolver rede neural artificial com eficiência maior que 94% que seja capaz de indicar o nível de severidade do dano.

1.4 Delimitação

O desenvolvimento da bancada experimental e sistema inteligente para diagnóstico de condições de funcionamento e nível de severidade, ocorreram no laboratório GPII (Grupo de Pesquisa de integridade e inspeção), localizado na Universidade Federal da Paraíba, campus I em João Pessoa – PB.

O sistema desenvolvido é composto basicamente por um motor e redutor do tipo coroa sem fim. Nessa bancada é possível reproduzir as seguintes condições de funcionamento: Estado de referência, desalinhamento, sobrecarga e lubrificação ineficiente. Dois sistemas de coleta de dados foram construídos: um para análise de vibração e outro para análise sonora. A análise de vibração foi utilizada para validar os resultados obtidos através da análise sonora. As características/extratores utilizadas como entrada do sistema inteligente, foram baseadas em métodos estatísticas e na transformada de wavelet. Duas redes neurais foram desenvolvidas: uma para identificar a condição de funcionamento e outra o nível de severidade.

1.5 Organização da dissertação

A estrutura dessa dissertação é organizada de maneira lógica. O capítulo 1 apresenta o tema da dissertação, contextualizando as técnicas existentes para diagnóstico de falhas em redutores através de métodos de inteligência artificial, além de expor os objetivos e justificativa. No capítulo 2 é apresentado a fundamentação teórica, oferecendo uma base teórica sólida sobre os conceitos relevantes atrelados ao experimento. O capítulo 3, denominado de Revisão da literatura, explora pesquisas anteriores relacionadas ao tema. No capítulo 4, Metodologia, há uma descrição dos métodos e procedimentos adotados, incluindo etapas como a construção e montagem da bancada, coleta dos dados, processamento e análise dos sinais e o desenvolvimento do sistema inteligente. No capítulo 5, são apresentados os resultados. Por fim, na conclusão, há a síntese dos principais resultados alcançados e pontos para pesquisas futuras.

2 FUDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados os conceitos básicos para o entendimento do trabalho desenvolvido.

2.1 Manutenção preditiva

A manutenção preditiva, também denominada de Manutenção sob condição ou Manutenção com base no estado do equipamento, é uma abordagem em que as intervenções são realizadas com base nas alterações de parâmetros de desempenho ou condição do equipamento, cujo monitoramento obedece a uma sistemática (KARDEC; NASCIF, 2010, p. 44). Outra definição dada pela Norma NBR 5462 (1994), é:

Manutenção que permite garantir uma qualidade de serviço desejada, com base na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva (ABNT – NBR 5462, 1994).

O principal objetivo desse tipo de manutenção é a prevenção de falhas nas máquinas ou sistemas através do acompanhamento de diversos parâmetros, tornando possível a operação contínua do equipamento pelo maior tempo possível. Essa estratégia de manutenção prioriza a disponibilidade, evitando intervenções nos equipamentos ou sistemas, pois as medições e verificações são efetuadas enquanto o equipamento está em operação (KARDEC; NASCIF, 2010, p. 45). A manutenção preditiva permite prever a ocorrência de falhas e a vida útil restante dos ativos industriais a partir de um histórico de dados coletados, com o intuito de programar ações de manutenção mais assertivas (ABIDI; MOHAMMED; ALKHALEFAH, 2022; NUNES; SANTOS; ROCHA, 2023).

De acordo com Lee, Lapira, Yang e Kao (2013), esse tipo de manutenção oferece diversas vantagens, tais como: uso eficiente das peças, diminuição dos custos, prolongamento da vida útil do equipamento, maior segurança nas instalações, melhoria na qualidade do produto e redução no número de acidentes.

Conforme Arato (2004), a prática da manutenção preditiva engloba três fases: detecção do defeito, estabelecimento de um diagnóstico e análise de tendência.

A detecção do defeito consiste em observar que os valores medidos dos parâmetros de controle apresentam uma evolução mais acelerada do que o desgaste normal do equipamento.

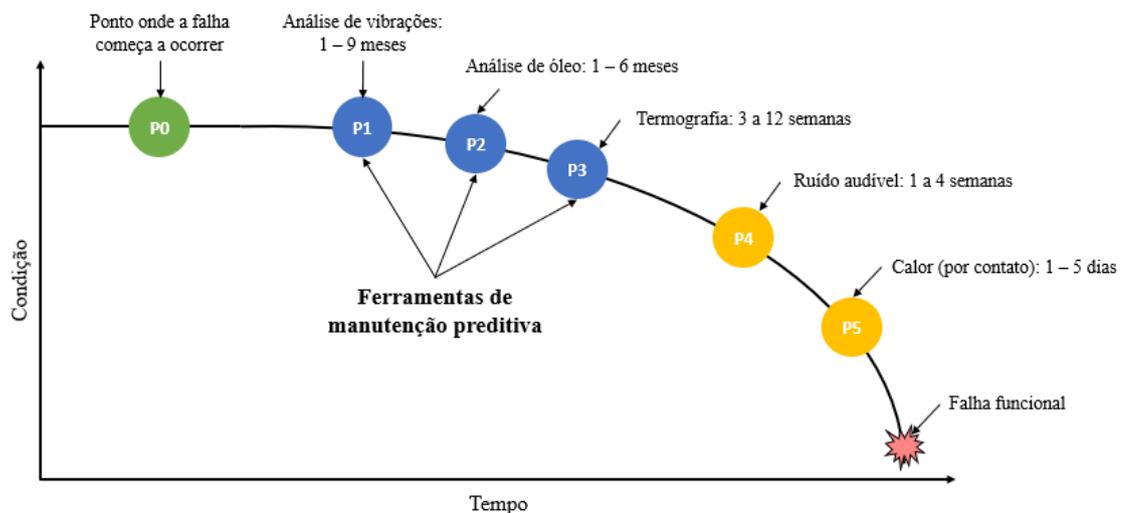
O estabelecimento do diagnóstico resulta da análise dos valores dos parâmetros monitorados, utilizando modelos de desgaste e informações anteriores sobre o equipamento, determinando a origem e a gravidade dos possíveis defeitos.

A análise de tendência complementa o diagnóstico, permitindo estimar o tempo de funcionamento restante antes de uma parada forçada causada por uma falha.

As principais técnicas de manutenção preditiva são: Análise de vibração ultrassom, análise de óleo, termografia e análise de ruído (OLIVEIRA NETO, 2023).

Os modos de falha de um equipamento são precedidos por uma variedade de falhas potenciais, onde cada uma pode ser detectada por uma técnica de manutenção diferente (MOUBRAY, 1997). Na Figura 1 é apresentada a curva PF (Potencial de falha). Ela representa a relação entre a vida útil de uma máquina e o momento em que ela começa a apresentar sinais de falha. Essa curva contribui para o monitoramento da condição do equipamento de acordo com o tempo. Existem dois pontos importantes: P0 (Potencial de falha), onde os primeiros sinais de falha começam a surgir, e o ponto F (Falha funcional), onde o equipamento já não consegue mais desempenhar sua função adequadamente. Nesse gráfico, também é possível identificar as estratégias de manutenção para a detecção precoce da falha (BARBOSA, 2023). A técnica de detecção de falha utilizada nesse trabalho se assemelha a técnica de análise de vibração na curva PF.

Figura 1: Curva P-F e tarefas que precedem a falha funcional



Fonte: Adaptado de Moubray (1997)

Na manutenção preditiva, os parâmetros a serem medidos devem fornecer informações que tragam a possibilidade de inspeção de elementos específicos da máquina

ou tipo de falha. A Tabela 1, mostra alguns exemplos de parâmetros a serem medidos e as respectivas naturezas da falha ou defeito a ser detectado.

Tabela 1: Parâmetros passíveis de medição em manutenção preditiva

PARÂMETRO A SER MEDIDO	NATUREZA DA FALHA OU DEFEITO DETECTADO
Amplitude de deslocamento da vibração	Desbalanceamento, desalinhamento, jogo excessivo, falta de rigidez, acoplamento defeituoso, correias frouxas ou gastas, eixos deformados, desajustes, turbulências etc.
Amplitude de velocidade da vibração	Mancais ou engrenagens deterioradas
Amplitude de aceleração da vibração	Estado mecânico dos rolamentos, atrito excessivo entre componentes, falta de lubrificação, instabilidade do filme de óleo em mancais de deslizamento
Frequência da vibração	Dado complementar à medição de qualquer característica da vibração, indispensável na determinação de qualquer problema detectado.
Fase da vibração	Desbalanceamento dinâmico, folga excessiva, partes frouxas ou soltas.
Nível de ruído	Rolamentos ou engrenagens deterioradas, desgaste, cavitação, turbulência, aumento do atrito.
Fugas	Deterioramento de selos, juntas e gaxetas, perdas de pressão.
Espessura	Corrosão ou erosão em tanques e tubulações.
Temperatura	Lubrificação inadequada, engrenamento, aumento do atrito, sobrecarga, desalinhamento de mancais, produção excessiva de calor em componentes elétricos.
Pressão	Deterioramento de rotores, bloqueio de tubulações, válvulas travadas.

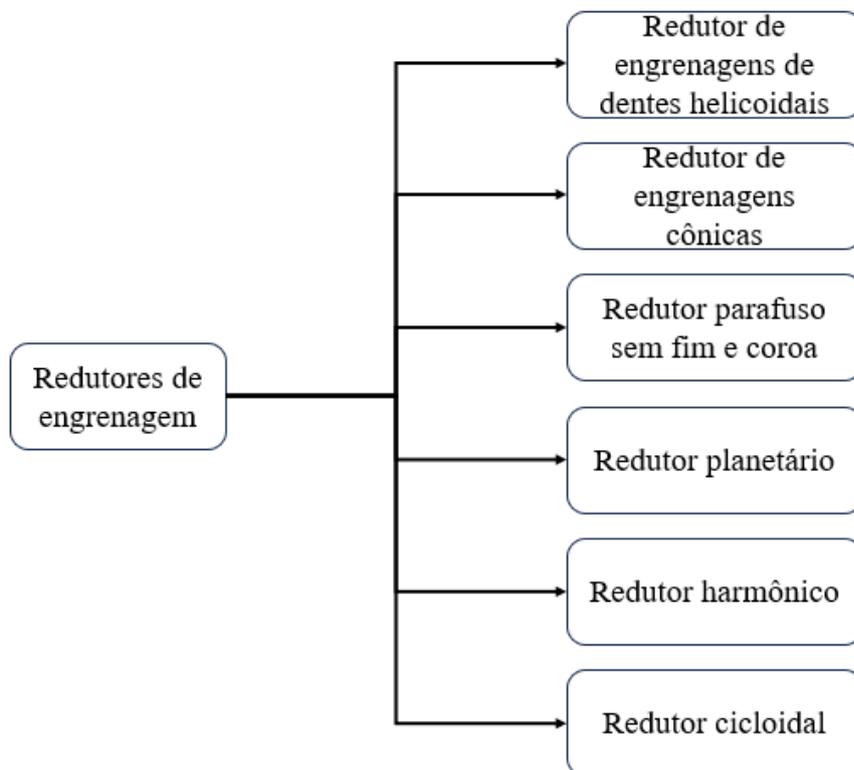
Fonte: Marçal (2000).

2.2 Redutor de engrenagens

Diversas aplicações industriais necessitam de um maquinário acionado por motores convencionais ou elétricos. A fonte de energia geralmente opera de forma mais eficiente em uma determinada faixa de velocidade rotacional. Quando a aplicação exige que a potência seja transmitida a uma velocidade inferior àquela fornecida pelo motor, é utilizado um redutor de velocidade. Esse redutor tem a função de transferir a potência do motor para a aplicação com o mínimo de perda de energia, enquanto reduz a velocidade e simultaneamente aumenta o torque (BUDYNAS; NISBETT, 2016).

Esses equipamentos são compostos basicamente por uma carcaça, engrenagens, eixos e rolamentos. Sua função principal é ajustar a velocidade do motor de acionamento à rotação requerida para o funcionamento do equipamento que será acionado (FAGUNDES SILVA, 2019). Os principais tipos de redutores são apresentados na Figura 2.

Figura 2: Tipos de redutores



Fonte: Autor

No presente trabalho foi utilizado o redutor do tipo parafuso sem-fim e coroa para os experimentos.

2.2.1 Redutor parafuso sem fim e coroa

Os redutores parafuso sem fim e coroa, são amplamente utilizados em guindastes, máquinas têxteis, pórticos, furadeiras radiais, plaina limadora, mesa de fresadoras, comando de leme de navios, pontes rolantes, elevadores etc. (MELCONIAN, 2019, p. 159).

Esse tipo de redutor utiliza um sistema de engrenagem composto por um parafuso sem fim e uma engrenagem sem-fim (também chamada de roda sem-fim, ou coroa). Esse sistema conecta eixos que não são paralelos e não se intersectam, geralmente formando ângulos retos entre si. O sem-fim é, na verdade, uma engrenagem helicoidal com um ângulo de hélice tão grande que um único dente se envolve continuamente ao redor de sua circunferência. O sem-fim pode ser comparado a uma rosca de parafuso, enquanto a coroa é equivalente a uma porca que se encaixa nessa rosca (NORTON, 2013, p. 768).

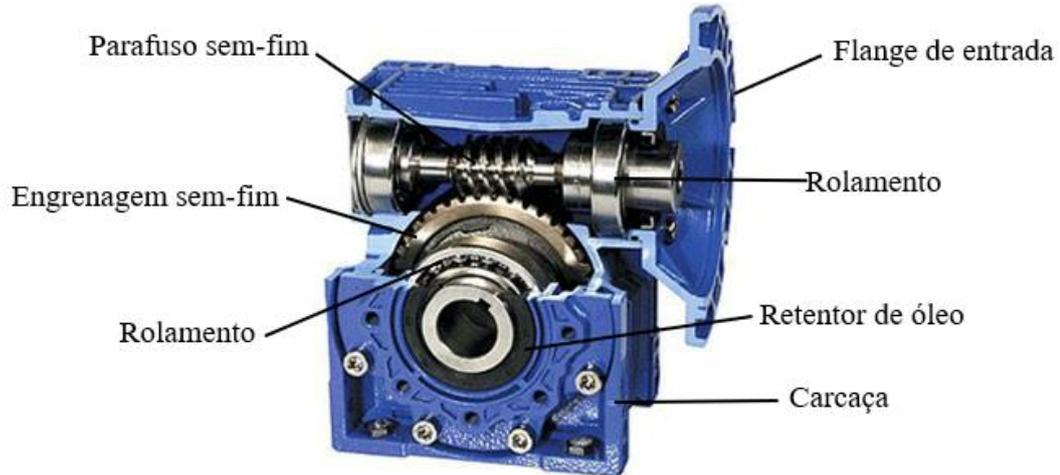
Algumas das vantagens desse tipo de engrenamento são a facilidade de fabricação de fabricação das engrenagens quando comparadas as cônicas e cilíndricas, amortecimento de ruídos e de funcionamento (redutores mais silenciosos) devido ao movimento de escorregamento dos flancos dos dentes e a elevada faixa de relação de transmissão. A relação de transmissão em uma redução de um único estágio pode chegar a 1:100. Quanto menor for a relação de transmissão, maior será o número de entradas do sem-fim. O rendimento desse tipo de sistema diminui à medida que a relação de transmissão se torna maior (MELCONIAN, 2019, p. 159; NIEMANN, 1971, p.21).

Outra vantagem dos engrenamentos sem-fim em relação a outros tipos de engrenagem é a sua capacidade de autotravamento. Se o conjunto sem-fim for autotravante, ele irá impedir o retrocesso, ou seja, o torque aplicado à coroa não será suficiente para girar o sem-fim na direção oposta. Esse engrenamento autotravante, só permite o movimento em uma única direção, do sem-fim para a coroa. Por esse motivo, ele é ideal para suportar cargas, como no caso do levantamento de um carro (NORTON, 2013, p. 769).

A lubrificação nos redutores parafuso sem-fim e coroa é feita através da lubrificação por salpico. Nesse processo, a engrenagem maior mergulha no óleo, transportando-o e salpicando-o sobre o ponto de contato das engrenagens e nos mancais. Manter o nível de óleo correto é essencial, pois, se tiver baixo, pode gerar uma distribuição inadequada e falta de lubrificação; se tiver alto, pode ocasionar agitação excessiva, aumentando o consumo de energia e gerando calor, o que eleva a temperatura e afeta a viscosidade do

óleo (CARRETEIRO; BELMIRO, 2006, p. 189). A Figura 3 apresenta os principais componentes de um redutor parafuso sem-fim e coroa.

Figura 3: Redutor parafuso sem-fim e coroa



Fonte: Adaptado de Global redutores

2.3 Técnicas de processamento de sinais

O processamento de sinais é empregado para extrair informações que podem estar ocultas em uma análise visual simples no domínio do tempo. Quando se trata de diagnóstico de falhas, a escolha da técnica apropriada varia conforme as características do sinal em análise (LYRA, 2019). A manutenção moderna exige a estimativa de indicadores de falhas que apontem tanto a localização quanto a gravidade do problema. Um passo essencial para isso é a aplicação de técnicas de processamento de sinais, que posteriormente serão analisadas por um técnico especialista. A precisão do diagnóstico está fortemente relacionada à facilidade de interpretações dos resultados dessas técnicas e ao nível de conhecimento técnico do usuário. Assim, para reduzir erros de diagnóstico, é recomendável utilizar técnicas de processamento de sinais que gerem poucos parâmetros, mas com alta capacidade de descrever o estado do equipamento (CARVAJAL, 2011). Os sinais podem ser classificados como estacionários e não estacionários. Os sinais estacionários apresentam poucas variações ao longo de um determinado intervalo de tempo, sendo mais comuns em máquinas de indução operando sob carga constante. Por outro lado, os sinais não estacionários possuem componentes dinâmicas com variações transitórias (OLIVEIRA, 2007).

2.3.1 Técnicas no domínio do tempo

O tratamento de um sinal que varia ao longo do tempo é frequentemente realizado através de métodos estatísticos ou processamento no domínio do tempo. A principal vantagem desse método é que ele permite trabalhar com o sinal em sua totalidade, sem que haja perda de informações importantes (CARVAJAL, 2011). As ferramentas estatísticas, em suas diversas aplicações, são capazes de extrair informações relevantes de um conjunto de dados. No caso de um sinal coletado por meio de análise sonora, variações nas diferentes condições de operação de uma máquina podem ser identificadas por métodos estatísticos específicos (OLIVEIRA NETO, 2023). Dentre os principais parâmetros estatísticos aplicados, é possível citar: Valor eficaz ou *RMS* (*Root mean squared*), curtose, fator de crista, desvio padrão, assimetria, o pico a pico entre outros (BELLI NETO, 2023). Neste trabalho, os 3 primeiros foram utilizados.

2.3.1.1 Desvio padrão

De acordo com Virgillito (2017), o desvio padrão representa a média dos afastamentos dos valores observados em relação à média da distribuição. O desvio padrão é dado pela Equação a seguir:

$$\sigma = \sqrt{\sum \frac{(x - \bar{x})^2}{n - 1}} \quad (1)$$

2.3.1.2 RMS

O valor eficaz, ou RMS, é amplamente utilizado no domínio do tempo para representar a energia de um sinal, além de avaliar a condição de funcionamento dos componentes monitorados. Esse parâmetro estatístico é útil para a etapa de investigação do progresso de falhas, pois seu valor tende a aumentar de maneira progressiva à medida que a degradação se torna mais acentuada (MARQUES, 2019). O RMS é dado pela Equação abaixo:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^n (x_i)^2} \quad (2)$$

Onde:

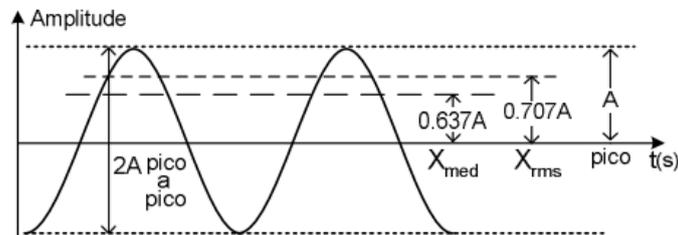
- N é o número de amostras do sinal x ;
- x_i amplitude do ponto i .

2.3.1.3 Fator de crista

O fator de crista (F_{cr}) é dado pela razão entre o valor de pico (X_{pico}) e o valor de RMS (X_{RMS}) (BEZERRA, 2004). O fator de crista fornece a ideia da forma de onda do fenômeno em análise, indicando a sua homogeneidade ao longo do período. Valores elevados do fator de crista sugerem a presença de picos significativos no período, que provavelmente são causados por fenômenos repetitivos com intervalos de tempos regulares. O fator de crista é dado pela Equação (3) (CUNHA, 2005).

$$F_{cr} = \frac{X_{pico}}{X_{RMS}} \quad (3)$$

Figura 4: Média, valor RMS e pico.



Fonte: Bezerra (2004).

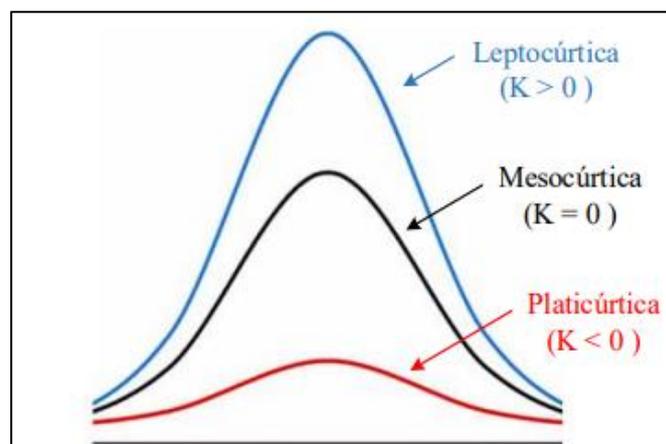
2.3.1.4 Curtose

A curtose, no campo da teoria das probabilidades e estatística, é uma medida que caracteriza o grau de achatamento da distribuição de probabilidade de uma variável aleatória de valor real. Em outras palavras, é um parâmetro que descreve a forma do histograma que representa as ocorrências de valores de um sinal. Para sinais que seguem uma distribuição semelhante à gaussiana, o valor da curtose tende a ser próximo de 3. Quando o valor é maior que 3, indica que os sinais apresentam picos de alta intensidade e bem definidos, ou seja, picos estreitos. Por outro lado, uma curtose menor que 3 é típica

de sinais uniformes, onde não existem extremos bem definidos. Dessa maneira, o excesso de curtose, obtido subtraindo 3 do valor da curtose, possibilita classificar as distribuições em 3 categorias: mesocúrticas (excesso de curtose igual a zero), leptocúrticas (excesso de curtose positivo) e platicúrticas (distribuição com excesso de curtose negativo). Essas distribuições são vistas na Figura (5). A curtose é definida pela Equação abaixo: (MARQUES, 2019).

$$K = \frac{N \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]^2} \quad (4)$$

Figura 5: Distribuições para os 3 tipos de curtose



Fonte: Adaptada de Souza (2022).

2.3.2 Técnicas no domínio da frequência

Um sinal no domínio do tempo contém ruídos e não exibe picos claramente definidos. No entanto, é possível observar que, em determinados momentos, a amplitude do sinal é maior que em outros. Para destacar certas características específicas do sinal, que são imperceptíveis no domínio do tempo, o sinal é transformado para o domínio da frequência (PORTO, 2023). Por exemplo, as máquinas rotativas geram sinais de vibração periódicos devido ao fato de que a posição de seus componentes se repete em intervalos regulares, de acordo com a velocidade do eixo de entrada de potência. Dessa maneira, algumas informações referentes a presença de falhas podem ser identificadas quando

esses sinais são avaliados no domínio da frequência. Uma das técnicas mais utilizadas para essa análise é a Transformada de Fourier (CARVAJAL, 2011).

2.3.2.1 Transformada de Fourier

A representação de um sinal como uma combinação linear de senoides complexas é conhecida como série de Fourier, em homenagem ao matemático francês Jean Baptiste Joseph, que viveu no final do século XVIII e início do século XIX. Qualquer função periódica limitada, relevante para a engenharia, pode ser expressa como uma soma de senoides complexas através da série de Fourier (ROBERTS, 2009).

De acordo com Hayt, Kemmerly e Durbin (2014), dada uma função periódica e contínua $f(t)$, definida por:

$$f(t) = f(t + T) \quad (5)$$

Onde T representa o período, o Teorema de Fourier afirma que $f(t)$ pode ser descrita por uma série infinita, conhecida como série de Fourier expressa por:

$$f(t) = a_0 + a_1 \cos(\omega_0 t) + a_2 \cos(2\omega_0 t) + \dots + b_1 \sin(\omega_0 t) + b_2 \sin(2\omega_0 t) + \dots = a_0 + \sum_{n=1}^{\infty} (a_n \cos(n\omega_0 t) + b_n \sin(n\omega_0 t)) \quad (6)$$

Para sinais não periódicos, o espectro de Fourier é contínuo. Isso significa que o sinal pode ser representado pela soma de senoides ou exponenciais que abrangem todas as frequências em um intervalo contínuo de valores (CURY, 2021).

A Transformada de Fourier é uma técnica que possibilita converter sinais do domínio do tempo contínuo, $x(t)$, para sua representação no domínio da frequência $X(j\omega)$. Ela consiste em calcular o produto interno entre o sinal $x(t)$ e suas funções base, que são senoides complexas dependentes de uma variável de frequência contínua. Os coeficientes $X(j\omega)$ são definidos pela Equação (7), conhecida como Equação de análise. Esses coeficientes mostram a contribuição de cada frequência na formação do sinal, resultando no que é chamado de espectro de frequência (HAYKIN; VEEN, 2001 apud AZEVEDO, 2017).

$$X(j\omega) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi\omega t} dt \quad (7)$$

Onde:

- $X(j\omega)$: Espectro de frequências;
- $x(t)$: Sinal no domínio do tempo;
- ω : Frequência do sinal.

O conjunto de coeficientes $X(j\omega)$ é conhecido como Transformada de Fourier. A integral de síntese, que usa esses coeficientes para expressar o sinal como uma combinação linear de exponenciais complexas, é chamada de Transformada Inversa de Fourier. A Equação de síntese é representada pela Equação (8) (HAYKIN; VEEN, 2001).

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(j\omega) e^{j2\pi\omega t} d\omega \quad (8)$$

Os sinais utilizados em análises de aplicações reais são apresentados em tempo discreto, uma vez que são obtidos através de amostragem (AZEVEDO, 2017). Para este caso é utilizada a Transformada Discreta de Fourier, que se trata de uma técnica que converte os sinais as amostras de um sinal no domínio do tempo em uma representação no domínio da frequência (REGES JUNIOR, 2022).

Entre as representações de Fourier, a Transformada Discreta de Fourier (DFT) é a única que pode ser manipulada computacionalmente. Isso ocorre porque, tanto no domínio do tempo $x[n]$, quanto no domínio da frequência, $X[k]$, há um número finito de amostras, N . As funções de base da DFT, são senoides complexas, cujo tamanho é igual ao número de amostras do sinal, e essas funções dependem de uma variável de frequência discreta (HAYKIN; VEEN, 2001 apud AZEVEDO, 2017).

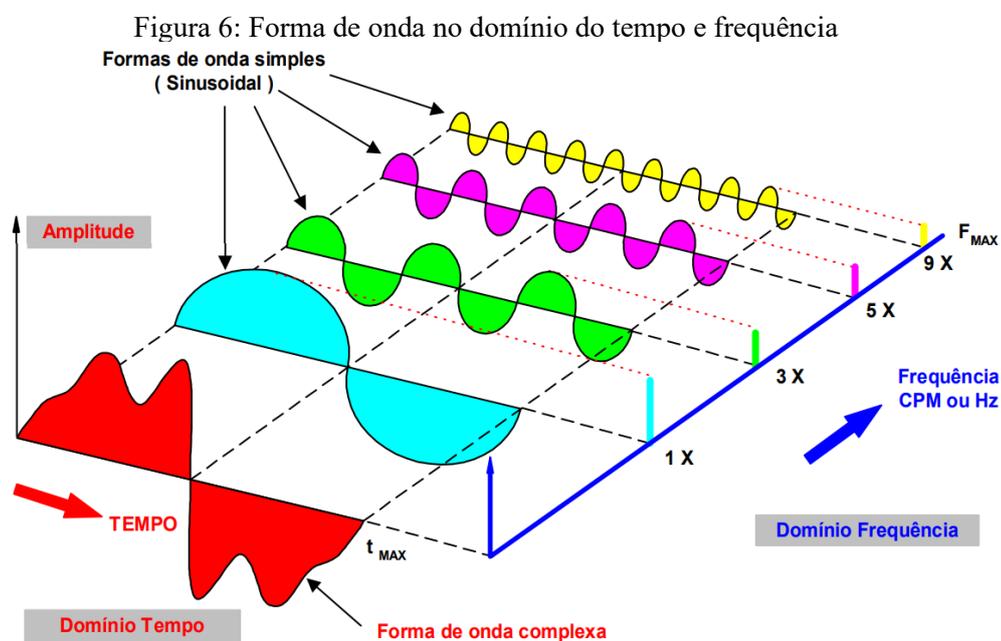
A Transformada Discreta de Fourier (DFT) calcula a sequência discreta $X(k)$ com N coeficientes, que estão relacionados à sequência $x(n)$ pela Equação (9).

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi nk/N} \quad (9)$$

Onde $X(k)$ é a amplitude da k -ésima componente harmônica, com k variando de 0 a $N - 1$ e k/N indica uma fração da frequência de amostragem. Em geral, $X(k)$ é um número complexo, o que significa que possui módulo e ângulo de fase (PACHECO, 2007).

Uma das principais limitações da DFT em aplicações práticas é o grande volume de operações aritméticas necessárias para seu cálculo, especialmente para sequências longas. Esse problema foi parcialmente superado com o desenvolvimento de algoritmos mais eficientes para calcular a DFT, conhecidos como Transformada Rápida de Fourier (*Fast Fourier Transform – FFT*) (DINIZ; SILVA; NETTO, 2014). A introdução dessa classe de algoritmo por Cooley e Tukey em 1965, se mostrou extremamente eficaz para a implementação digital, reduzindo significativamente o tempo necessário para calcular transformadas, em várias ordens de grandeza (OPPENHEIM; WILLSKY; NAWAB, 2010). Isso fez com que as análises de espectro de sinais, a exemplo dos sinais de som e vibração, pudessem ser realizadas de maneira mais fácil (PACHECO, 2007).

Os algoritmos de FFT se baseiam no princípio da decomposição do cálculo da Transformada Discreta de Fourier de uma sequência de tamanho N em várias transformadas menores. Essas transformadas de menor comprimento são, em seguida, combinadas para formar a Transformada de N pontos. Essas transformadas menores podem ser calculadas por métodos diretos, ou podem ser divididas novamente em transformadas ainda menores (OPPENHEIM; SCHAFER, 2013). Na Figura (6) há uma representação do sinal no domínio do tempo e frequência.



Fonte: Sequeira (2012).

A Transformada de Fourier é uma ferramenta que descreve as diferentes frequências presentes em um sinal, porém não indica a localização espacial dessas frequências. A

análise de Fourier é particularmente útil para sinais estacionários, ou seja, aquelas cujas características estatísticas permanecem constantes ao longo do tempo, com o sinal apresentando as mesmas componentes de frequência durante toda sua duração. Nesse contexto, não é necessário saber o momento exato em que cada componente de frequência existe, já que elas estão presentes o tempo todo. Embora a Transformada de Fourier possa ser aplicada para sinais não estacionários, ela mostra apenas quais componentes estão presentes no sinal, porém não fornece informações sobre em que tempo elas ocorrem (SANTOS, 2017).

2.3.3 Técnicas no domínio tempo-frequência

Embora os métodos apresentados até o momento sejam eficazes em alguns casos, eles exigem que a distribuição dos dados seja aproximadamente estacionária ou ciclo estacionária. Isso significa que esses métodos não são adequados para máquinas que operam sob variações de velocidade ou carga (BARSZCZ; RANDALL, 2009; YESILYURT, 2004; LIU; RIEMENSCHNEIDERA; XU, 2006 apud CARVAJAL, 2011). Além disso, esses métodos não são precisos na distinção entre falhas que apresentam sintomas semelhantes (GONZALEZ; FIGUEROA; IRIBARREN, 1996 apud CARVAJAL, 2011). Para estudar transientes, vários pesquisadores propuseram o uso de transformações que permitem descrever o comportamento do sinal tanto no domínio do tempo quanto no domínio da frequência simultaneamente. Entre as técnicas mais utilizadas estão a Transformada de wavelet e a Transformada de Fourier de tempo curto (STFT) (CARVAJAL, 2011; SANTOS, 2017).

2.3.3.1 Transformada de Fourier de tempo curto (STFT)

Quando um sinal apresenta características não estacionárias ou transitórias, é necessário utilizar uma abordagem que considere tanto o domínio do tempo quanto o da frequência. Nesse contexto, a Transformada de Fourier de tempo curto (STFT), também conhecida como Transformada de Gabor, surge como uma adaptação da análise espectral clássica de Fourier, possibilitando uma análise simultânea no domínio tempo-frequência. (SANTOS, 2017).

Nessa adaptação, o sinal é dividido em pequenas partes, de forma que cada uma possa ser considerada estacionária. A aplicação de janelas ao sinal permite isolar essas partes, e a DFT de cada segmento identifica as frequências ali presentes (LYRA, 2019).

A STFT apresenta algumas limitações, uma delas está relacionada à largura da janela para todas as frequências. Uma janela larga (com mais amostras) proporciona uma boa resolução no domínio da frequência, mas uma ruim no domínio do tempo, e oposto também é verdadeiro. Sendo assim, não é possível obter uma simultaneamente uma resolução satisfatória tanto no domínio do tempo quanto no da frequência. Na prática é necessário encontrar um equilíbrio entre as duas resoluções, escolhendo uma janela que possibilite uma a obtenção de informações de ambos os domínios. Essas informações possuem precisão limitada devido a largura da janela. Logo, a Transformada de Fourier de curta duração introduz uma escala, definida pela largura da janela, e analisa o sinal com base nessa escala. Quando o sinal possui detalhes importantes fora dessa faixa, surgem problemas na análise (SANTIAGO, 2004).

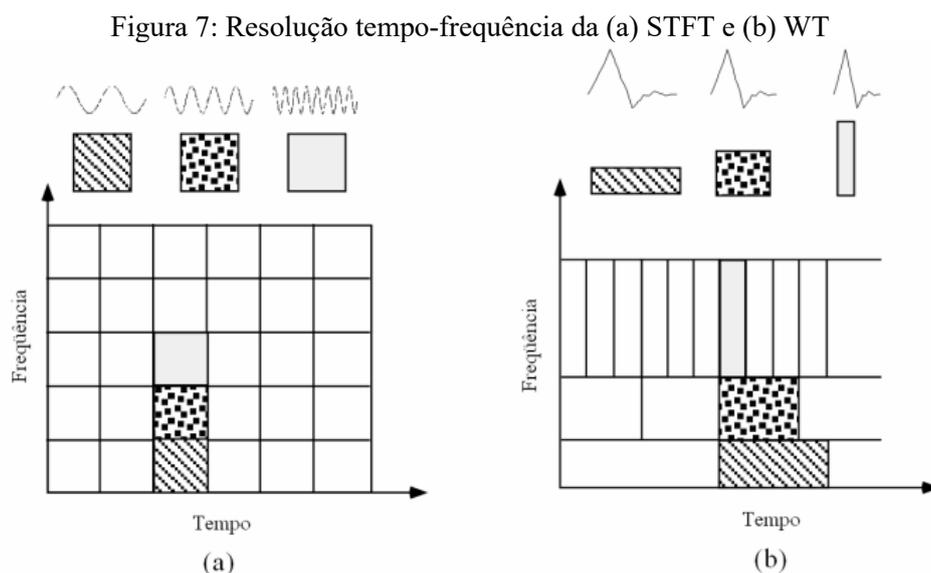
2.3.3.2 Transformada de Wavelet

A Transformada de Wavelet (WT) é uma ferramenta eficiente para a análise de sinais tanto estacionários quanto não estacionários. Essa técnica tem sido amplamente utilizada em áreas como meteorologia, análise de compressão de dados, processamento de sinais e imagens, e de forma notável, no diagnóstico de falhas em máquinas (SANTIAGO, 2004).

Essa técnica matemática decompõe um sinal em componentes chamados *wavelets*. Diferente da Transformada de Fourier, que faz uso de senos e cossenos para representar o sinal, a Transformada de Wavelet emprega pequenas e localizadas funções. As *wavelets* conseguem capturar informações tanto na frequência quanto no tempo, possibilitando uma análise mais detalhada do sinal (VIANA, 2023).

A Transformada de Wavelet foi desenvolvida para superar as limitações da STFT, fazendo uso de uma série de funções oscilatórias com diferentes frequências como janelas. Embora a WT seja semelhante a STFT, ela se diferencia pela resolução que oferece. Na análise pela WT, a resolução depende da frequência do sinal. Em altas frequências, a Transformada de Wavelet alcança boa resolução no tempo, mas baixa resolução em frequência. Em contrapartida, em frequências baixas, a WT oferece uma resolução mais precisa na frequência, mas com menor precisão no tempo. Esse método é eficaz quando

o sinal a ser analisado apresenta componentes de alta frequência e curta duração, além de componentes de baixa frequência e longa duração, como é comum em muitos fenômenos associados a máquinas rotativas (PENG & CHU, 2004 apud AQUINO, 2008). Na Figura 7.a é mostrado a limitação da STFT, onde o valor da largura da janela é constante para todas as frequências. Já na Figura 7.b, é apresentado a resolução para a Transformada de Wavelet, sendo possível observar que um sinal pode ser analisado com boa resolução no tempo e na frequência (SANTIAGO, 2004).



Fonte: Pozzebon (2009).

O problema da resolução está relacionado ao princípio da incerteza de Heisenberg, aplicado no contexto de processamento de sinais. Esse princípio afirma que não é possível definir com exatidão qual frequência existe em um determinado instante de tempo, mas apenas identificar qual banda de frequência há em um dado intervalo de tempo. Isso ressalta a importância de dividir adequadamente o sinal para uma análise simultânea em tempo e frequência. É por esse motivo que diversos pesquisadores preferem a Transformada de Wavelet que proporciona uma resolução variável, em vez da STFT, que fornece uma resolução fixa ao longo do tempo (AQUINO, 2008).

De acordo com Sória (2016), a principal diferença entre a Transformada de Wavelet (WT) e a STFT reside no fato de que na WT o tamanho da janela não permanece necessariamente constante. Possibilitando uma análise com janelas de tamanhos variáveis para diferentes componentes de frequência e tempo dentro de um sinal. Nesse processo, o sinal é comparado a um conjunto de funções modelo, com base no escalonamento e

deslocamento da Wavelet. O escalonamento (scaling) ajusta o tamanho da função Wavelet, permitindo que ela seja alongada ou comprimida. Por outro lado, o deslocamento (shifting), move a janela ao longo do tempo, podendo acelerar ou atrasar o seu aparecimento.

Uma Wavelet é uma pequena onda de natureza oscilatória com energia limitada, e interpreta o sinal com diferentes versões transladadas e escaladas de uma wavelet original, conhecida como wavelet mãe. A principal ideia por trás da Transformada de Wavelet é que ela é uma transformada pontual e proporcional à escala. Isso significa que ela analisa o sinal em várias escalas e se desloca analisando cada ponto do sinal (NÓBREGA, 2015).

A Transformada de Wavelet pode ser encontrada em duas formas, que são: Transformada Wavelet Contínua (CWT) e Transformada Wavelet Discreta.

A Transformada Wavelet Contínua, consiste na integração, ao longo do tempo, do sinal multiplicado por uma versão de wavelet que foi escalonada e deslocada (REIGOTA, 2007). Para a wavelet mãe, ou wavelet protótipo $\psi(t)$, há uma família associada de wavelets denominadas de wavelets filhas $\psi_{a,b}(t)$. Essas wavelets filhas são obtidas através da dilatação e translação da wavelet mãe, conforme estabelecido pela teoria da Transformada Wavelet Contínua. A CWT de um sinal $x(t)$, é definida pela Equação (10) (SANTIAGO, 2004; AQUINO 2008):

$$CWT(a, b) = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}^*(t) dt, a, b \in \mathbb{R}, a \neq 0 \quad (10)$$

Onde:

$$\psi_{a,b}(t) = \left(\frac{1}{\sqrt{a}} \right) \psi \left(\frac{t-b}{a} \right) \quad (11)$$

O símbolo * indica o conjugado complexo da função mencionada.

Na Equação (11), é possível notar que quando $\psi_{1,0}(t) = \psi(t)$, o que corresponde a wavelet base (wavelete mãe) (CHUI, 1992).

O parâmetro b , conhecido como coeficiente de translação, desloca a posição da wavelet ao longo do eixo do tempo t , ou seja, determina a localização da janela de análise. Esse parâmetro controla o movimento da função moduladora $\psi_{a,b}(t)$ sobre o eixo horizontal, com o objetivo de analisar toda a extensão do sinal (NÓBREGA, 2015).

O parâmetro a , denominado de fator de escalonamento, determina o tamanho da função janela, controlando o processo de compressão ou dilatação do sinal. Para valores menores de a , a Transformada de Wavelet aumenta a resolução de pequenos detalhes $x(t)$. A escalas e as frequências de um sinal possuem uma relação inversa: A faixa específica da frequência está associada ao tamanho do detalhe. Por exemplo, ao variar a , a função $x(t)$ pode ser avaliada em diferentes frequências. Quando a escala a aumenta, a wavelet $\psi_{a,b}(t)$ se expande no tempo, capturando fenômenos de longa duração. Se a escala diminui, $\psi_{a,b}(t)$ se contrai, capturando evento de curta duração e transitórios. Assim, uma escala maior oferece uma visão global do sinal, enquanto uma escala menor revela detalhes (DAUBECHIES, 1992). O escalonamento permite comprimir ($a < 1$) ou dilatar ($a > 1$) a wavelet mãe. O fator $\frac{1}{\sqrt{a}}$ nas wavelets filhas é utilizado para garantir que as energias das wavelets escalonadas pelo fator a , permaneçam equivalentes à da wavelet mãe (AQUINO, 2008).

Segundo Sória (2016), a Wavelet deve garantir a condição de admissibilidade apresentada na Equação (12).

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (12)$$

No processo de cálculo da CWT, os parâmetros de escala e posição variam de forma contínua. Entretanto, a determinação dos coeficientes da wavelet para todas as escalas possíveis pode demandar elevado esforço computacional e uma grande quantidade de dados que precisam ser analisados posteriormente. Com o objetivo de reduzir essa sobrecarga computacional, matemáticos desenvolveram a Transformada Discreta de Wavelet (DWT), que minimiza as redundâncias da CWT. A DWT surge com uma alternativa importante, pois possibilita a discretização da wavelet fazendo uso de escalas baseadas em potência de dois, denominadas escalas diádicas. Além de acelerar a implementação computacional, essa estratégia, torna a análise dos dados mais eficientes. Assim, os parâmetros a e b , da Equação (10), são substituídos por 2^j e $k2^j$, respectivamente, resultando na definição da DWT como (CHUI, 1992; SANTIAGO, 2004):

$$DWT(j, k) = \int_{-\infty}^{+\infty} x(t) \psi_{j,k}^*(t) dt, \quad j e k \in Z \quad (13)$$

Onde:

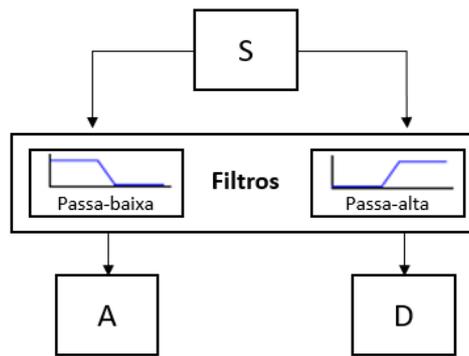
$$\psi_{j,k}(t) = \left(\frac{1}{\sqrt{2^j}} \right) \psi \left(\frac{t - k2^j}{2^j} \right) \quad (14)$$

Sendo elas funções wavelets ortogonais, que formam uma base ortonormal de $L^2(R)$ (DAUBECHIES, 1988).

Um método eficiente para a implementação da DWT, foi desenvolvida por Mallat em 1988, utilizando filtros. O algoritmo de Mallat é um modelo consagrado na área de processamento de sinais, conhecido como codificador de sub banda de dois canais. Esse algoritmo de filtragem, é bastante prático e resulta em uma Transformada Rápida de Wavelet (FWT), onde o sinal é processado de forma eficiente e os coeficientes de wavelet são gerados rapidamente. O algoritmo mencionado também é conhecido como Análise de Multiresolução (MRA) ou algoritmo Piramidal de Mallat (MISITI et al, 2004; SANTIAGO, 2004).

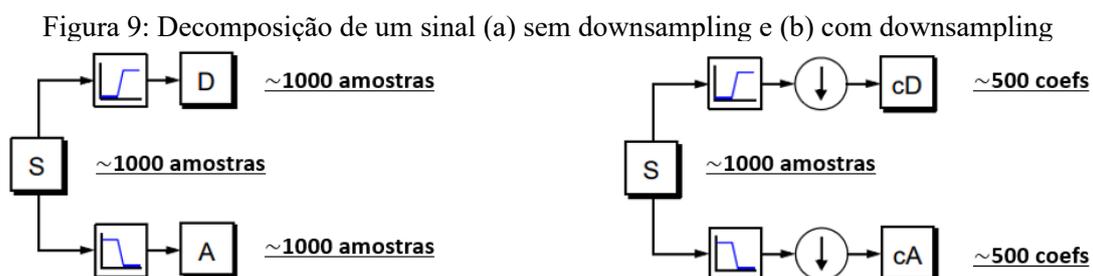
Através da Análise de Multiresolução, um sinal pode ser decomposto em duas partes: aproximação e detalhe, e pode ser reconstruído a partir dessas componentes. A função Wavelet está associada a um filtro passa-alta, responsável por gerar os coeficientes de detalhe. Além disso, há uma função complementar chamada de função de escalonamento, que está associada ao filtro passa-baixa e produz os coeficientes de aproximação. Isso significa que a aproximação possui informações de baixa frequência do sinal original, enquanto o detalhe contém as informações de alta frequência. A Figura 8 apresenta esse processo descrito (NÓBREGA, 2015).

Figura 8: Processo básico de decomposição Multiresolução (MRA)



Fonte: Adaptado de Misiti (2004)

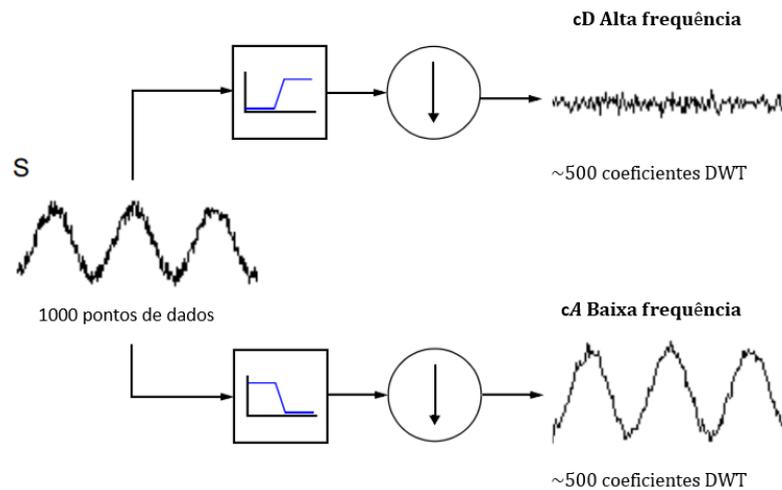
O sinal original, S , passa por dois filtros complementares, resultando em dois novos sinais. Porém, ao aplicar essa operação em um sinal digital real, o número de dados irá dobrar. Por exemplo: se o sinal, S , tiver 1000 amostras, os sinais gerados, A e D , também terão 1000 amostras, totalizando 2000 amostras. Esse aumento desse número de dados tornasse um desafio. Para contornar esse problema, é possível utilizar uma abordagem mais eficiente de wavelet. Ao analisar o cálculo com mais atenção, é possível eliminar metade das amostras de ambos os sinais, A e D , sem perder informações importantes. Essa técnica conhecida como subamostragem (*downsampling*), permite selecionar uma amostra a cada duas. O resultado desse processo são duas novas sequências, cA e cD , que preservam as características do sinal original, mas com uma quantidade menor de dados. Esse processo é mostrado na Figura 9 (MISITI, 2004).



Fonte: Adaptado de Misiti (2004).

Para melhor entendimento sobre a aplicação dessa técnica, é apresentado na Figura 10, o desenvolvimento da DWT de uma etapa em um sinal. O sinal é um senoide puro com ruído de alta frequência.

Figura 10: Exemplo de filtragem com *downsampling* com um sinal senoidal

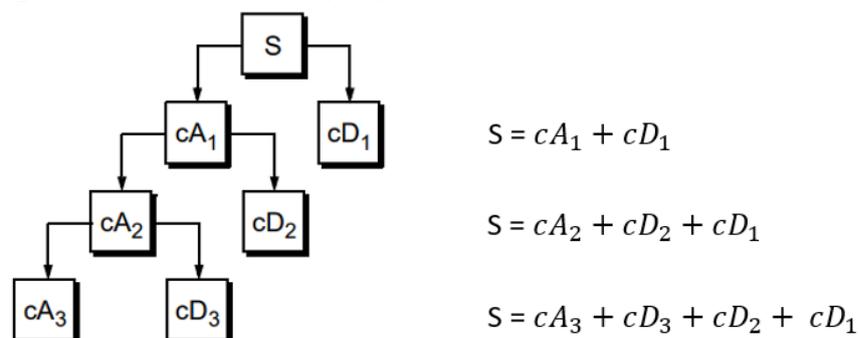


Fonte: Adaptado de Misiti (2004).

É possível observar que os coeficientes de detalhe cD são pequenos e consistem principalmente em ruído de alta frequência, enquanto os coeficientes de aproximação cA possuem menos ruído do que o sinal original (MISITI, 2004).

A teoria de multiresolução, possibilita decompor um sinal como descrito a seguir: Inicialmente, um sinal discreto S , é dividido no primeiro nível em duas partes, representadas por cA_1 e cD_1 , usando um filtro passa-baixa e um passa-alta, respectivamente. O cA_1 é denominado de aproximação do sinal e cD_1 é chamado de detalhe do sinal. No segundo nível, a aproximação cA_1 é novamente decomposta, gerando uma nova aproximação (A_2) e um detalhe D_2 . Esse processo pode ser repetido para o terceiro nível, e assim sucessivamente. A Figura 11 apresenta a árvore de decomposição da wavelet de um sinal até o terceiro nível (SANTIAGO, 2004).

Figura 11: Árvore de decomposição da wavelet de um sinal em 3 níveis



Fonte: Adaptado de Misiti (2004)

2.4 Análise de vibração em máquinas rotativas

A base fundamental da análise de vibração como técnica aplicada à manutenção industrial é: “cada componente ou cada tipo de deficiência mecânica de uma máquina em operação produz uma vibração de frequência específica que em condições normais de funcionamento, alcança uma amplitude máxima determinada” (MARÇAL, 2000). De acordo com Lopo de Carvalho (2023), a análise de vibração possibilita o diagnóstico de falhas mecânicas e estruturais, por meio do conhecimento das frequências de cada componente e da própria estrutura.

A análise de vibração permite tomar decisões sobre a necessidade de intervenção no equipamento, garantindo sua máxima disponibilidade. Isso contribui para a redução de custos, minimiza o tempo de parada, otimiza o estoque de peças e melhora a segurança operacional (LAGO, 2007).

2.4.1 Fontes de vibração em máquinas rotativas

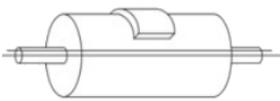
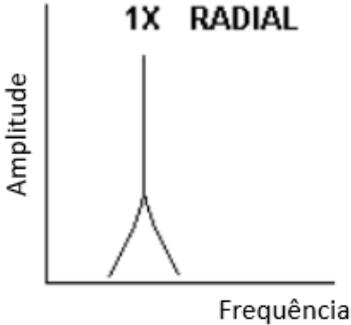
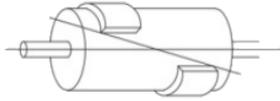
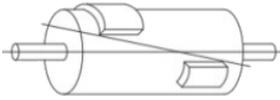
As vibrações em máquinas rotativas podem ser geradas por diversos fatores, sendo os mais comuns: desalinhamento, desbalanceamento, defeitos em engrenagens e rolamentos, folgas mecânicas, atritos, eixos deformados, instabilidade no filme de óleo em mancais e falhas elétricas. Cada falha apresenta uma assinatura específica de vibração (LAGO, 2007; LEITE, 2012).

As falhas podem ser classificadas em duas categorias principais: baixa frequência, como desalinhamento e desbalanceamento, e as de alta frequência, como rolamentos desgastados e falta de lubrificação. Os problemas decorrentes de engrenamento estão associados a componentes de média frequência. Porém, identificar uma falha não se resume apenas a medir a frequência de cada um dos componentes de vibração. Após determinar o valor absoluto, é preciso relacionar a frequência com a velocidade de rotação do eixo (MARÇAL, 2000). No presente trabalho, foram avaliadas as falhas de desalinhamento, sobrecarga e falha de lubrificação. A seguir são fornecidas as características das principais fontes de vibração presentes em máquinas rotativas e o comportamento dos seus espectros de frequência.

- **Desbalanceamento:** Ocorre devido a um esforço extra nos mancais de apoio de peças rotativas, causada por massas desiguais em relação ao eixo de inércia. A vibração resultante é bem definida, com componente predominante na direção

radial, coincidindo com a frequência de rotação do eixo. A amplitude dessa vibração está diretamente relacionada à quantidade de desbalanceamento e aumenta proporcionalmente ao quadrado da velocidade de rotação. As causas mais comuns de desbalanceamento são: Falha de fabricação, desgaste, manutenção incorreta, impregnação de materiais em rotores, armazenagem e transporte (LAGO, 2007). A Tabela 2, mostra os principais tipos de desbalanceamento e suas características.

Tabela 2: Comportamento vibracional devido a desbalanceamento em sistemas rotativos.

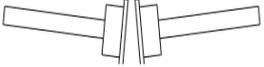
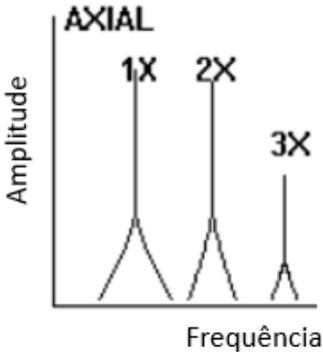
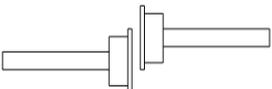
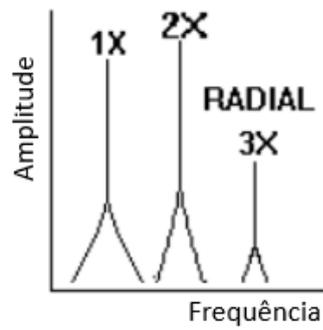
Tipo	Frequências predominantes	Sentido	Espectro de frequência
Desbalanceamento estático 	1x frequência de rotação	Radial	
Desbalanceamento acoplado 			
Desbalanceamento Dinâmico 			

Fonte: Baseado em Mauro de Sá (2000) e Oliveira Neto (2023)

- Desalinhamento:** A condição de desalinhamento é gerada quando as linhas de centro de rotação de dois eixos não estão colineares entre si, resultando em um desvio entre o eixo da peça e o eixo colinear de rotação (MELO, 2018). De acordo com Piotrowsky (2006) citado por Melo (2018), o desalinhamento está relacionado a uma ou várias das seguintes condições: Falha do eixo resultante da fadiga, quebra nos eixos ou próximos aos acoplamento e rolamentos, desgaste excessivo em rolamentos, vedações ou acoplamentos, folga ou perda de parafusos da fundação, parafusos de acoplamentos folgados ou danificados,

superaquecimento dos acoplamentos, elevação da temperatura da carcaça e do óleo perto dos mancais e consumo excessivo de energia pelo equipamento. O desalinhamento pode ser angular, paralelo ou combinado (HOLANDA, 2016). Na Tabela 3 são mostrados os principais tipos de desalinhamento e suas características.

Tabela 3: Comportamento vibracional devido a desalinhamento em sistemas rotativos

Tipo	Frequências predominantes	Sentido	Espectro de frequência
<p>Desalinhamento angular</p> 	<p>1x, 2x frequência de rotação. Entretanto não é incomum que 1x, 2x e 3x sejam predominantes</p>	<p>Axial</p>	
<p>Desalinhamento paralelo</p> 	<p>1x, 2x frequência de rotação.</p>	<p>Radial</p>	

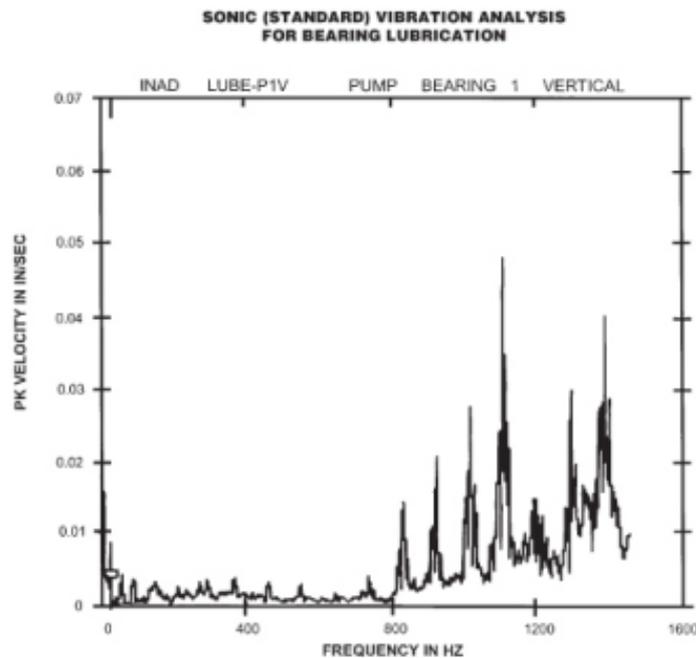
Fonte: Baseado em Mauro de Sá (2000)

- Lubrificação ineficiente:** As falhas de lubrificação são uma das principais causas de problemas em máquinas rotativas, especialmente em componentes como mancais e rolamentos. Elas podem ocorrer tanto por falta quanto por excesso de lubrificante. A causa mais comum, que é a falta de lubrificante, provoca aquecimento e contato direto entre superfícies metálicas, acelerando o desgaste e gerando falhas de forma rápida, especialmente em sistemas de alta precisão como redutores e rolamentos de rotores. Por outro lado, o excesso de lubrificante também é prejudicial, pois causa superaquecimento, rompimento de vedações e,

em motores elétricos, pode resultar curtos-circuitos. Esses fatores reforçam a necessidade de um controle rigoroso da quantidade de lubrificante para garantir o desempenho confiável das máquinas rotativas (MENEZES, 2018).

Conforme destacado por Exxon Mobil (2009), a Figura 12 apresenta o espectro de frequência de vibração de um rolamento em condição de baixa lubrificação, onde o contato entre os roletes e a pista pode excitar frequências ressonantes elevadas de outros componentes do rolamento. As leituras ultrassônicas, por exemplo, são eficazes para identificar lubrificação ineficiente antes que danos ocorram. Em rolamentos lubrificadas de forma inadequada, os problemas de lubrificação acontecem na faixa de 800 a 2000 Hz.

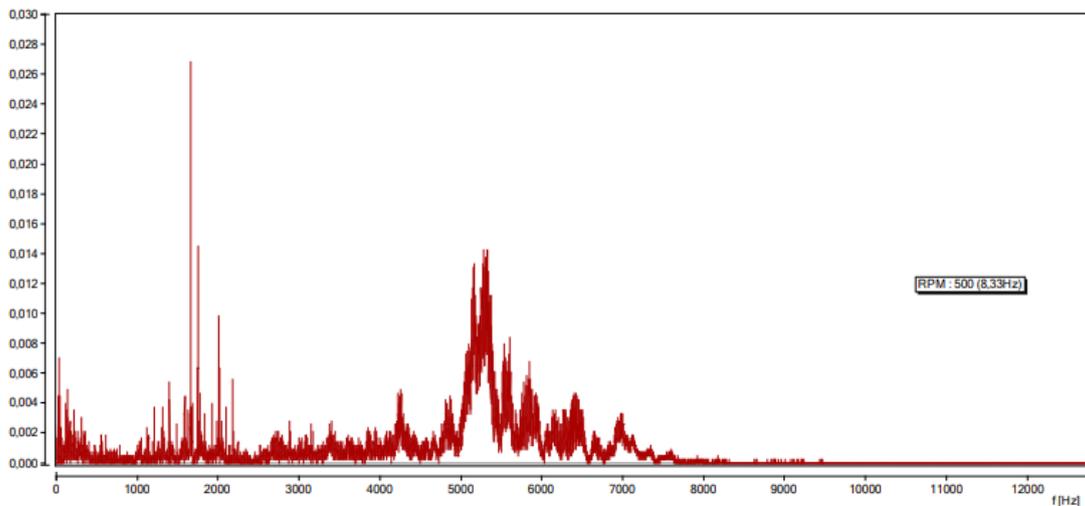
Figura 12: Espectro de frequência de vibração padrão de um rolamento operando em uma condição de baixa lubrificação.



Fonte: Exxon Mobil (2009)

Rosddeutscher Junior (2018), apresenta na Figura 13, o espectro de frequência de aceleração que evidencia a quebra do filme lubrificante, conforme indicado pela região de “carpete” na faixa de 4000 a 7000 Hz.

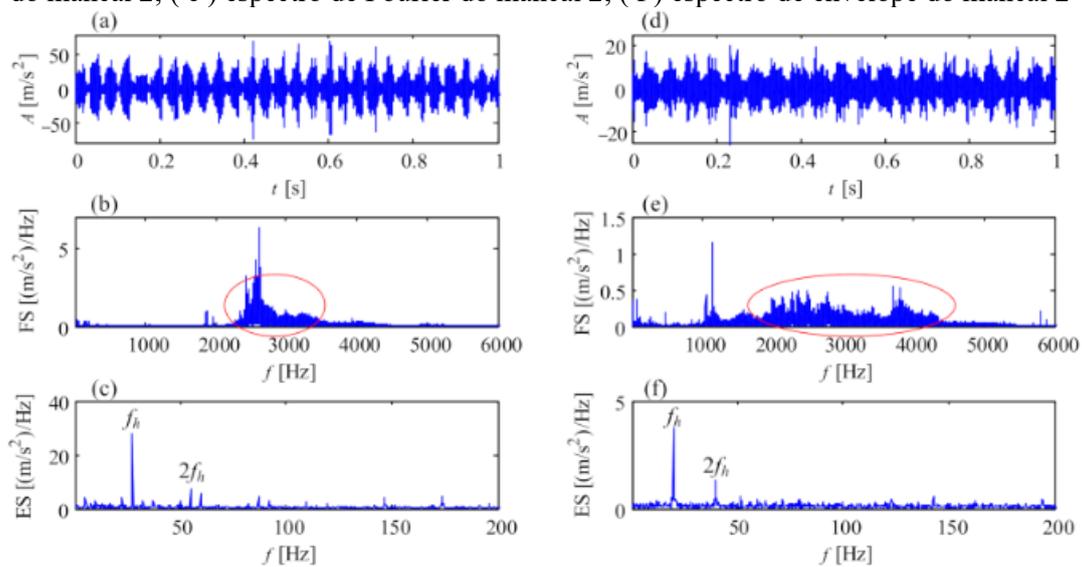
Figura 13: Espectro de aceleração indicando quebra do filme lubrificante



Fonte: Rossdeutscher Junior (2018)

Teng et al (2021), conduziram um estudo detalhado sobre os efeitos da lubrificação insuficiente em mancais de geradores, observando que essa condição provoca um aumento no ruído de fundo no espectro de vibração, especialmente na faixa de 2000 a 5000 Hz. Esse ruído elevado decorre da excitação da ressonância do par de contato, que é afetada tanto pela rigidez do óleo quanto pela rigidez de contato entre os componentes. A Figura 14, mostra o comportamento descrito no mancal 1 (14.a, 14.b e 14.c) e no mancal 2 (14.d, 14.e e 14.f).

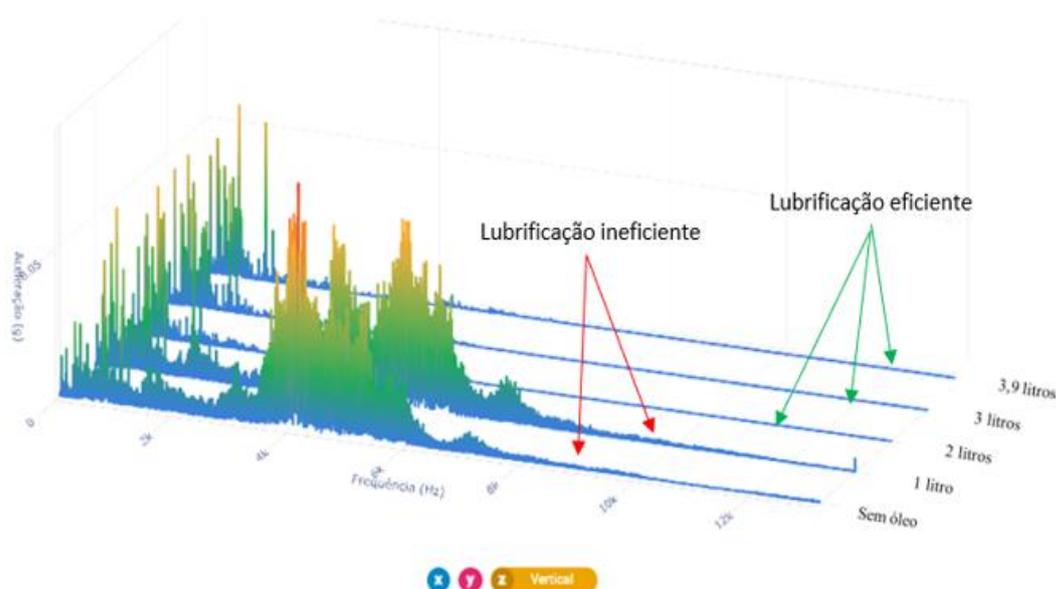
Figura 14: Lubrificação insuficiente dos mancais do gerador: (a) sinal temporal do mancal 1; (b) espectro de Fourier do mancal 1; (c) espectro de envelope do mancal 1; (d) sinal temporal do mancal 2; (e) espectro de Fourier do mancal 2; (f) espectro de envelope do mancal 2



Fonte: Teng et al (2021)

Para evidenciar o comportamento da lubrificação ineficiente em redutores coroa sem fim, objeto de estudo dessa dissertação, foi feita uma análise de vibração em um redutor coroa sem fim com auxílio de um sensor Dynallogger HF+s PO. Na Figura 15, observa-se que em 2 situações: redutor vazio e com 1 litro de óleo, em aceleração RMS verifica-se vibrações aleatórias na região de ressonância do rolamento, entre 2 kHz e 6 kHz, principalmente na direção vertical. Esse espectro é característico de deficiência de lubrificação, visto que essas vibrações sempre acontecem em alta frequência no espectro de aceleração.

Figura 15: Espectro de frequência com vários níveis de lubrificação em redutor coroa sem fim



Fonte: Autor

2.4.2 Vibrações em redutores

As vibrações em uma caixa redutora de velocidade podem ser agrupadas em 3 categorias, que são: sincronizadas e harmônicas, não sincronizadas e as derivadas de impactos repetidos. Entre os problemas associados a vibração sincronizada estão o desalinhamento dos eixos e a excentricidade dos engrenamentos. Já as vibrações não sincronizadas estão relacionadas ao atrito e danos na linha primitiva das engrenagens, como pitting e desgaste localizado. Os danos em rolamentos e dentes, por sua vez, são

impactos repetidos que geram respostas ressonantes próximas da frequência natural do sistema (ARATO JR, 1992 apud CUNHA, 2005).

Conforme Nepomuceno (1989), os níveis de vibração e a silenciosidade de um sistema de engrenagens, são influenciados por diversos fatores. Existem três áreas que impactam significativamente tanto o ruído quanto as vibrações observadas nas engrenagens e sistemas de engrenagens. São elas:

- **Influência do projeto:** Tipo de engrenagem, geometria dos dentes, carga unitária sobre os dentes, rolamentos e materiais utilizados.
- **Influência da fabricação:** Precisão, acabamento superficial dos dentes, carga unitária sobre os dentes, rolamentos e materiais utilizados.
- **Influência da operação:** Velocidade crítica, ressonância natural, condições ambientais, lubrificação, montagem da caixa que abriga o sistema de engrenagens.

As principais frequências observadas no espectro de um sistema de engrenagens são a frequência de rotação do pinhão, da coroa e a de engrenamento da malha. Entretanto, devido à não linearidade do engrenamento, surgem componentes múltiplas da frequência de engrenamento. Além disso, um espaçamento irregular entre os dentes pode fazer com que o engrenamento ocorra fora do diâmetro primitivo, gerando modulações de frequência em torno da frequência de engrenamento. Já as imperfeições na superfície de contato entre os dentes podem provocar variações no carregamento mecânico, levando a modulações de amplitude (IRMÃO, 2002).

Além dessas componentes de frequência citadas anteriormente, o espectro do sinal de engrenagem pode apresentar outras componentes originadas de estruturas periódicas, que aparecem como famílias de bandas laterais e indicam a presença de defeitos (IRMÃO, 2002).

De acordo com Lago (2007), as frequências mais importantes para análise das fontes de vibração sincronizadas de um redutor de velocidade de engrenagens, são a frequência de rotação dos eixos e a frequência de engrenamento. No caso dos redutores do tipo rosca sem fim, as frequências de interesse são: frequência de rotação dos eixos, as frequências ressonantes e as frequências relacionadas ao atrito. A seguir são apresentadas as principais fontes de vibração encontradas em redutores.

- **Frequência de giro dos eixos:** Refere-se a uma frequência, cujo valor corresponde à velocidade de rotação, em giros por segundo, dos eixos que fazem parte do equipamento.

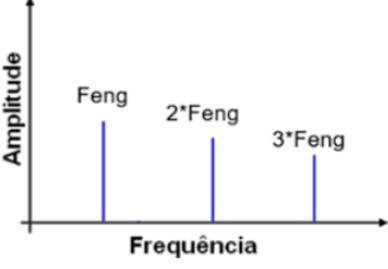
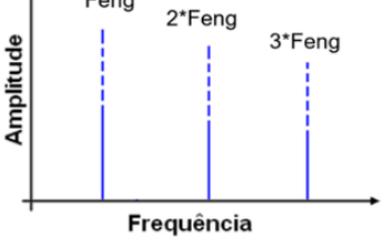
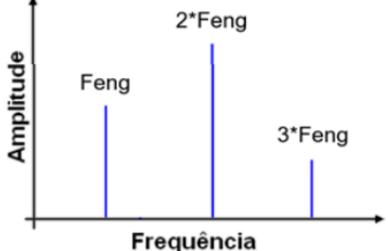
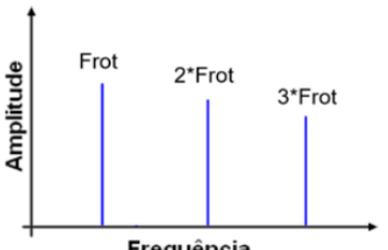
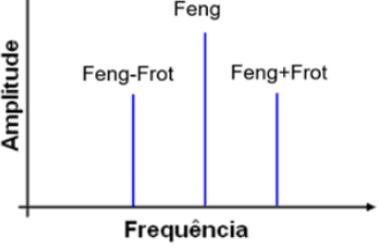
- **Frequência de engrenamento:** Para cada par de engrenagens, há uma frequência associada, resultante das deformações dos dentes durante o processo de engrenamento e imperfeições geométricas desses dentes. A frequência de engrenamento (f_e) é definida pela Equação 15, onde N é o número de dentes e f_r é a frequência de rotação do eixo ao qual está acoplada:

$$f_e = N \cdot f_r \quad (15)$$

- **Atrito:** As vibrações geradas por atrito geralmente possuem uma composição ampla e complexa, sendo identificadas mais pelo ruído do que por seus efeitos, já que a presença de ruído indica uma anomalia que é corrigida em qualquer instalação.
- **Harmônicos da frequência de engrenamento:** Gera componentes espectrais, cujas frequências são duas, três ou até quatro vezes a frequência de engrenamento, apresentando baixas amplitudes. Essas componentes são resultantes de desvios em relação ao perfil dos dentes, provenientes tanto pela deformação dos dentes sob carga quanto por um desgaste irregular.
- **Danos no dentado:** Os danos localizados que podem estar no dentado, incluem: “*pitting*”, trincas e quebra de dentes. Esses defeitos são caracterizados por uma perda localizada de rigidez no dente afetado, ocasionando alterações na amplitude e na fase do sinal de vibração durante o período de engrenamento do dente danificado. Essas alterações ocorrem devido a uma modulação localizada, resultando em um aumento das bandas laterais observadas no espectro. Em casos mais severos, ocorre uma mudança rápida e abrupta na força aplicada ao dente, o que pode excitar as frequências ressonantes do sistema eixo-mancal. Essas ressonâncias, por questões de projeto, geralmente se situam entre a frequência de rotação do eixo e a de engrenamento, acompanhadas de bandas laterais espaçadas pela frequência de rotação do eixo ao qual a engrenagem defeituosa está acoplada.

Na Tabela 4, estão representados os comportamentos da frequência de engrenamento conforma a condição de funcionamento.

Tabela 4: Comportamento da frequência de engrenamento conforme condição de funcionamento

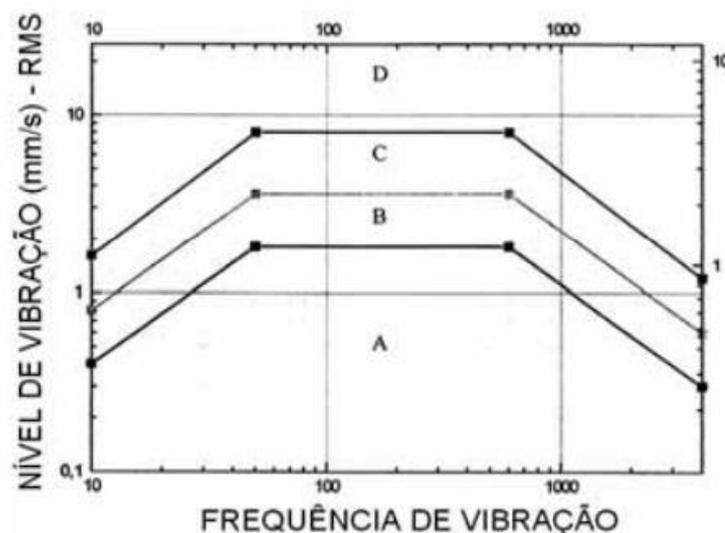
Falha ou condição de funcionamento	Descrição	Espectro de frequência
Condições normais de funcionamento e sem falhas	O sinal coletado em um engrenamento em condições normais de funcionamento e sem falhas pode apresentar a frequência de engrenamento e seus harmônicos bem-dispostos, mas em amplitudes mais baixas quando se comparado a condições indesejadas	
Desgastes nos dentes	Na ocorrência de desgastes nos dentes das engrenagens, surgindo folgas entre eles, a velocidade de rotação não muda, porém passam a surgir choques entre os dentes que se manifestam no sinal com um aumento da amplitude da Feng e seus harmônicos.	
Folga insuficiente entre os dentes (ex.: condições de excentricidade, falha de montagem, falha de projeto etc.)	A folga entre os dentes, mesmo pequena, resulta em esforço extra no engrenamento, assim como no desengrenamento, alterando o espectro e aumentando a amplitude na 2*Feng.	
Dente quebrado	A quebra de um dente causa um choque a cada volta, o espectro de frequência apresenta uma série de picos (harmônicos) da frequência de rotação da engrenagem que se encontra com o dente quebrado.	
Eixo com engrenagem ovalizada	A pressão sobre os dentes sofre uma modulação, conforme ocorre a rotação do eixo. O resultado no espectro é do surgimento de bandas laterais de largura igual a rotação da engrenagem defeituosa ao redor da Feng.	

Fonte: Oliveira Neto (2023)

2.4.3 Carta de severidade FUPAI

De acordo com Almeida (2008), a FUPAI (Fundação de Pesquisa e assessoramento à Indústria), disponibiliza um gráfico de referência para o monitoramento de vibrações. Esse gráfico pode ser utilizado para definir níveis toleráveis ou não de vibração em diversos equipamentos como motores elétricos, bombas, ventiladores, exaustores, compressores rotativos e outros. Nesse caso, as máquinas não são categorizadas por classes, mas apenas pelos níveis de vibração. Para os redutores, a FUPAI emprega o gráfico mostrado na imagem abaixo.

Figura 16: Gráfico FUPAI de severidade de vibração para redutores



Fonte: Almeida (2008).

Onde:

- Nível A: Engrenagens sem defeitos (nível ótimo);
- Nível B: Engrenagens com pequenos defeitos (nível tolerável);
- Nível C: Engrenagens com defeitos (nível permissível);
- Nível D: Engrenagens em perigo (parada imediata, corrigir com urgência – nível em alarme)

2.4.4 Normas para análise de vibração

Na Figura 17, é apresentada uma Tabela, conforme a NBR 10082, para a classificação e avaliação das máquinas através dos níveis de severidade de vibração para

quatro tipos de classes. As faixas de severidade são baseadas na ISO 2372/74 (LAGO, 2007).

Figura 17: Classificação e avaliação das máquinas por níveis de severidade de vibração.

FAIXA DE SEVERIDADE DE VIBRAÇÃO		AVALIAÇÃO DA QUALIDADE PARA CLASSES DIFERENTES DE MÁQUINAS			
FAIXA	VELOCIDADE NOS LIMITES (mm/s)	CLASSE I	CLASSE II	CLASSE III	CLASSE IV
0,28	0,28	A	A	A	A
0,45	0,45	A	A	A	A
0,71	0,71	A	A	A	A
1,12	1,12	B	A	A	A
1,8	1,8	B	B	A	A
2,8	2,8	C	B	B	A
4,5	4,5	C	C	B	B
7,1	7,1	D	C	C	B
11,2	11,2	D	D	C	C
18	18	D	D	D	C
28	28	D	D	D	D
45	45	D	D	D	D
71	Acima de 45	D	D	D	D

Fonte: Lago (2007).

A norma ISO 10816-3, classifica as condições de trabalho em 4 níveis, são eles:

- **Nível A** – Boas condições. Faixa normalmente encontrada após amaciamento, em máquinas novas ou revisadas.
- **Nível B** – Aceitável para operação continuada. Faixa de operação normal das máquinas em boas condições de manutenção e operadas adequadamente.
- **Nível C** – Limite tolerável. Faixa não aceitável para operação continuada. Nesta faixa deve-se operar o equipamento por um período limitado e deve-se programar uma revisão para ajustes ou consertos mais rápido possíveis.
- **Nível D** – Não permissível. A severidade neste nível é considerada danosa para o equipamento. Deve-se parar imediatamente e realizar uma manutenção corretiva.

De acordo com Almeida (2008), a norma alemã VDI2056, fundamentada nos estudos de Rathbone, serviu de base para a elaboração da norma ISO 2372. Ambas classificam as máquinas nas seguintes categorias.

- **Classe I** – Máquinas pequenas, com acionamento por motor elétrico diretamente acoplado, potência máxima de 15 KW.

- **Classe II** – Máquinas médias, do tipo da classe I, com potência maior que 15 KW, até 75KW. Motores ou máquinas montadas rigidamente até 300 KW.
- **Classe III** – Máquinas motrizes grandes e outras máquinas grandes (>75 KW), com massas rotativas montadas sobre fundações rígidas e pesadas, que são relativamente rígidas na direção de medição de vibração.
- **Classe IV** – Máquinas do tipo da classe III, montadas sobre fundações relativamente flexíveis na direção de medição de vibração, por exemplo, conjunto de turbogeradores.

De acordo com a NBR 10082, a Figura 18, apresenta uma Tabela com as faixas de severidade de vibrações para a faixa de frequência que varia de 10 a 1000 Hz.

Figura 18: – Faixas de severidade de vibrações conforme NBR 10082 (Banda de 10 a 1000Hz).

FAIXA DE CLASSIFICAÇÃO	FAIXA DE VELOCIDADE RMS (VALOR EFICAZ DA VELOCIDADE DE VIBRAÇÃO) – mm/s	
	ACIMA DE	ATÉ
0,11	0,071	0,112
0,18	0,112	0,18
0,28	0,180	0,28
0,45	0,28	0,45
0,71	0,45	0,71
1,12	0,71	1,12
1,8	1,12	1,80
2,8	1,8	2,8
4,5	2,8	4,5
7,1	4,5	7,1
11,2	7,1	11,2
18	11,2	18
28	18	28
45	28	45
71	45	71

Fonte: Lago (2007).

Para equipamento rotativos com velocidades entre 600 e 12.000 RPM (10 a 200 Hz), as normas ISO 2372, VDI Richtlinie 2056 e, no Brasil, a NBR 10082, utilizam o valor eficaz da velocidade de vibração, conhecido como velocidade RMS, como a unidade de medida padrão para avaliar a severidade de vibrações (LAGO, 2007).

2.5 Análise sonora aplicada a máquinas rotativas

O diagnóstico de falhas mecânicas utilizando sinais de áudio está ganhando destaque como uma tecnologia para detecção precoce e eficiente de falhas em equipamentos mecânicos. Essa abordagem é particularmente vantajosa, pois permite a aquisição de sinais sem contato, não invasiva e com a capacidade de monitorar máquinas em condições extremas, como altas temperaturas, radiação e ambientes corrosivos, sem afetar o funcionamento do equipamento (TANG et al, 2023).

Entre as principais técnicas de monitoramento estão a análise de vibração, sons, acústica, termografia e análise de detritos de desgaste. Esses métodos são comumente aplicados para avaliar componentes rotativos, como eixos, rolamento, engrenagens e polias. Embora a análise de vibração seja a mais utilizada. A análise de sinais sonoros também é viável para detecção de falhas (SAIMURUGAN; NITHESH, 2018). Os sinais sonoros e de vibração de uma máquina rotativa carregam informações dinâmicas que refletem sua condição operacional. (AMARNATH et al, 2013).

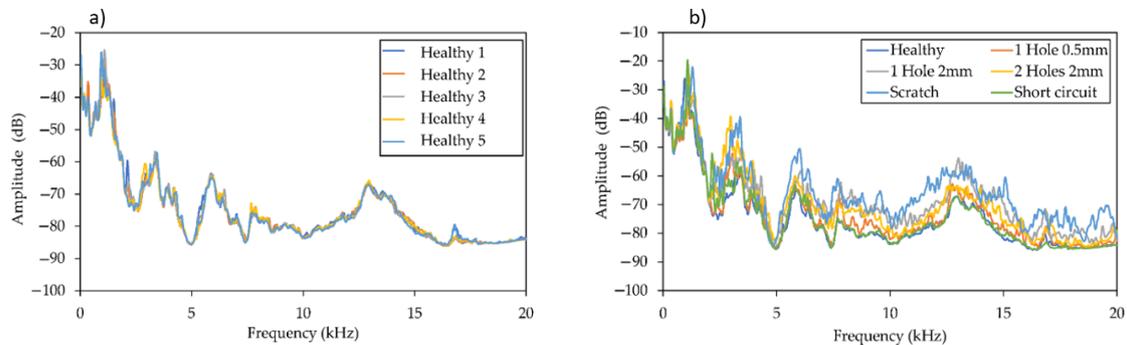
Kiranyaz et al (2024), mostraram em seus resultados que o método de detecção baseado em som demonstra uma robustez superior em comparação ao método baseado em vibração. Essa vantagem se deve ao fato de que ele não é afetado pela posição do sensor, oferecendo um desempenho equiparável ao método de análise de vibração. Além disso, o método de som é mais barato e prático, pois não exige sensores dedicados e sua implementação é simplificada.

O diagnóstico de falhas mecânicas baseado na análise de sinais de áudio utiliza características acústicas de ondas sonoras captadas por um sensor de áudio, como um microfone, em uma faixa de frequência de 20 a 20.000 Hz. Essa técnica permite monitorar o estado operacional dos equipamentos e realizar diagnósticos de falhas, tanto em nível global quanto local (TANG et al, 2023). A frequência sonora é medida em Hertz, indicando o número de ciclos de pressão sonora. O ouvido humano pode detectar frequências entre 20 e 20.000 Hz, com uma gama de pressões sonoras que variam de baixas a altas amplitudes. Um microfone é capaz de capturar frequências sonoras associadas a oscilações específicas a depender da sua resposta em frequência (OSHA, 2013, p. 3).

Conforme observado por Nakamura et al (2021), na Figura 19.a são apresentados espectros de som de 5 motores em boas condições, sendo possível notar uma semelhança entre os espectros desses motores saudáveis. Na Figura 19.b, Nakamura et al (2021),

mostra os espectros de som de cinco motores diferentes com falha, juntamente com o espectro de um motor saudável como referência.

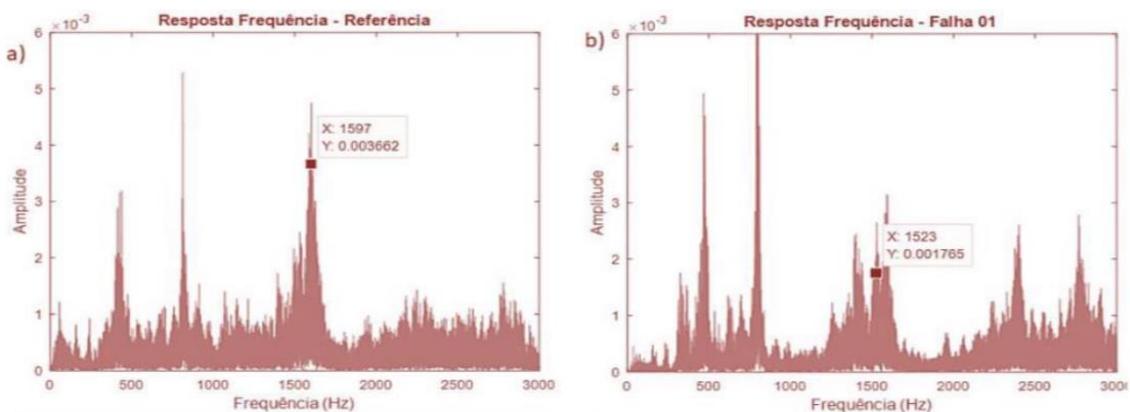
Figura 19: a) Espectros do som rotativo de cinco motores saudáveis; b) Espectros do som rotativo de motores defeituosos.



Fonte: Nakamura et al (2021)

No estudo de Oliveira Neto et al (2019), foi possível identificar desalinhamento em um par de engrenagens de dentes retos através do atraso da frequência de engrenamento e da intensificação das bandas laterais, conforme ilustrado na Figura 20. As amplitudes observadas para as frequências marcadas na Figura 20, indicam a frequência de engrenamento, tanto na condição de referência quanto no desalinhamento. Na condição desalinhada, a redução na velocidade de rotação, causada pelo atrito entre os dentes, levou a um acentuamento das bandas laterais.

Figura 20: a) Espectro sonoro, mostrando um pico relacionado ao efeito do desalinhamento angular para o valor da frequência de engrenamento encontrado experimentalmente; b) espectro do sinal sonoro após ser inserido um desalinhamento angular de 6 graus no eixo



Fonte: Oliveira Neto et al (2019)

2.6 Redes neurais artificiais

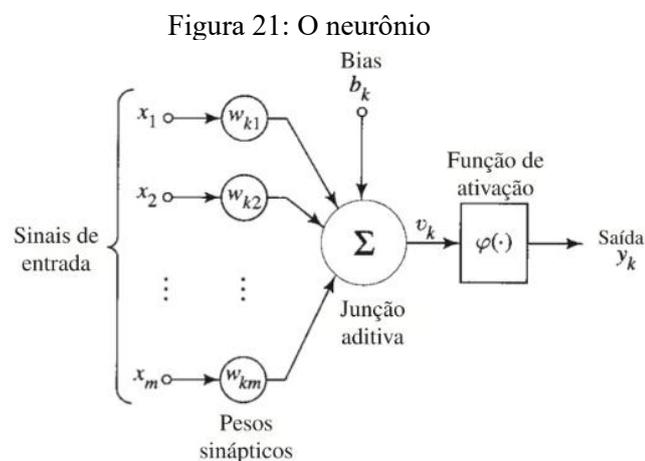
2.6.1 Conceito

As Redes Neurais Artificiais (RNA), são algoritmos sofisticados que, em essência, foram inspirados no modo como o cérebro humano processa informações. Elas consistem em combinações de unidades básicas de processamento, chamadas de neurônios, que estão interconectadas. Assim como os humanos, as RNA passam por uma fase de aprendizado pautada na análise de uma grande quantidade de informações, identificando padrões. O ponto fundamental é que as RNA possuem a capacidade de generalizar o conhecimento adquirido para reconhecer novos padrões, desde que sejam semelhantes aos observados durante a etapa de treinamento (SICSÚ; SAMARTINI; BARTH, 2023).

As redes neurais artificiais são frequentemente utilizadas em diversas aplicações da engenharia, como: classificação e reconhecimento de padrões, aproximador universal de função, agrupamento de dados ou clusterização, previsões, controle de processos com características não lineares entre outras (DIAS, 2019).

2.6.2 O neurônio

De acordo com Haykin (2007), o neurônio é a unidade básica de processamento de informações de uma rede neural. A Figura 21, mostra o modelo de um neurônio, que forma a base para o projeto de redes neurais artificiais. Nela é possível identificar 3 elementos básicos:



Fonte: Haykin (2007)

- Um conjunto de sinapses, cada uma associada a um peso ou força própria. Quando um sinal x_j entra pela sinapse j , que está conectada ao neurônio k , ele é multiplicado pelo peso sináptico w_{kj} . Nesse contexto, o primeiro índice do peso sináptico se refere ao neurônio e o segundo indica o terminal de entrada da sinapse à qual o peso se refere. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos bem como positivos.
- Um somador para agregar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- Uma função de ativação para controlar a amplitude da saída de um neurônio. Essa função, também conhecida como função restritiva, limita o intervalo permissível de amplitude do sinal de saída a um valor finito. Normalmente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o valor unitário fechado $[0, 1]$ ou alternativamente $[-1, 1]$. De acordo com Silva, Spatti e Flauzino (2010), as funções de ativação são divididas em dois grupos principais, que são: função de ativação parcialmente diferenciáveis, caracterizadas por possuírem pontos cujas derivadas de primeira ordem são inexistentes. As funções degrau, degrau bipolar e rampa simétrica, são as 3 principais desse grupo. O outro grupo é o das funções totalmente diferenciáveis que são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos do seu domínio de definição. As quatro principais funções pertencentes a esse grupo são a função logística, a tangente hiperbólica, a gaussiana e a linear.
- Uma bia aplicada externamente, representado por b_k . As bias, ajusta a entrada líquida da função de ativação, podendo aumentar ou diminuir essa entrada, dependendo se ele é positivo ou negativo, respectivamente.

Matematicamente, podemos descrever um neurônio k , a partir das equações 16 e 17:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (16)$$

$$y_k = \varphi(u_k + b_k) \quad (17)$$

Onde, x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio.

2.6.3 Arquitetura de redes neurais artificiais

De acordo com Silva, Splatti e Flauzino (2010, p. 45), a arquitetura de uma rede neural artificial faz referência à configuração de arranjo dos diversos neurônios uns em relação aos outros. Essa organização é definida principalmente pela maneira como as conexões sinápticas entre os neurônios são direcionadas.

Conforme, Silva, Splatti e Flauzino (2010, p. 46), as redes neurais artificiais podem ser divididas em três partes, denominadas de camadas. São elas:

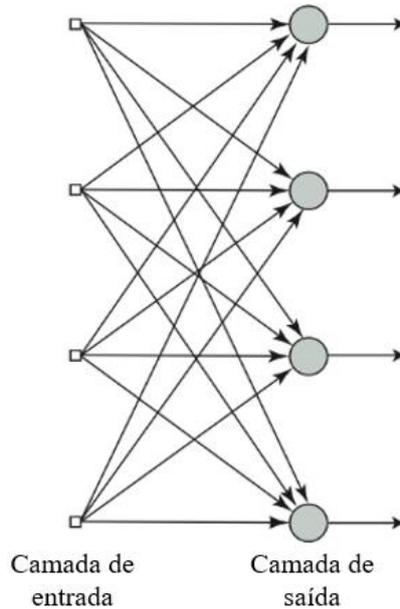
- Camada de entrada: Possui a função de identificação de informações, sinais, características ou medições provenientes do meio externo. Essas entradas (amostras ou padrões) são comumente normalizadas em relação às faixas de variações dinâmicas geradas pelas funções de ativação.
- Camadas ocultas, intermediárias, escondidas ou invisíveis: São formadas de neurônios que possuem a função de extrair as características relevantes do processo ou sistema a ser inferido. A maior parte do processamento da rede é realizado nessas camadas.
- Camada de saída: Composta por neurônios, essa camada é responsável por gerar e apresentar os resultados da rede, que são obtidos a partir do processamento realizado pelos neurônios das camadas anteriores.

Haykin (2007), afirma que as principais arquiteturas de redes neurais artificiais são: *feedforward* de camada única (Rede alimentada adiante com camada única), *feedforward* de camadas múltiplas (Rede alimentada diretamente com múltiplas camadas) e recorrentes.

- Rede *feedforward* de camada única: Nesse modelo de arquitetura de redes neurais artificiais, há apenas uma camada de entrada e uma única camada de neurônios, que, neste caso, é a camada de saída. As informações fluem em uma única direção, ou seja, da camada de entrada para a camada de saída. A quantidade de saídas nessa arquitetura é igual ao número de neurônios. Essa rede é comumente aplicada em problemas de classificação de padrões e filtragem linear. Os principais tipos

de redes que possuem essa arquitetura são a *Perceptron* e o *Andalino* (SILVA; SPATTI; FLAUZINO, 2010).

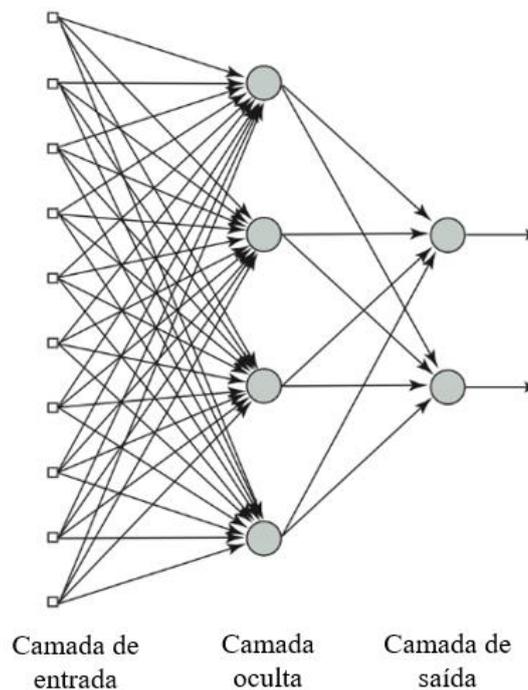
Figura 22: Rede *feedforward* de camada única



Fonte: Adaptado de Haykin (2007).

- Rede *feedforward* de camadas múltiplas: É formada por uma ou mais camadas ocultas, além das camadas de entrada e saída. Essa arquitetura é empregada na solução de problemas relacionados a aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica, controle de processos etc. Entre os principais tipos de rede com essa arquitetura, podemos destacar a Perceptron multicamadas (*Multilayer Perceptron – MLP*) e as redes de base radial (*Radial basis function – RBF*). A quantidade de camadas ocultas e o número de neurônios em cada uma, dependem do tipo e da complexidade do problema a ser modelado pela rede, bem como da qualidade e quantidade dos dados disponíveis sobre o problema (SILVA; SPATTI; FLAUZINO, 2010).

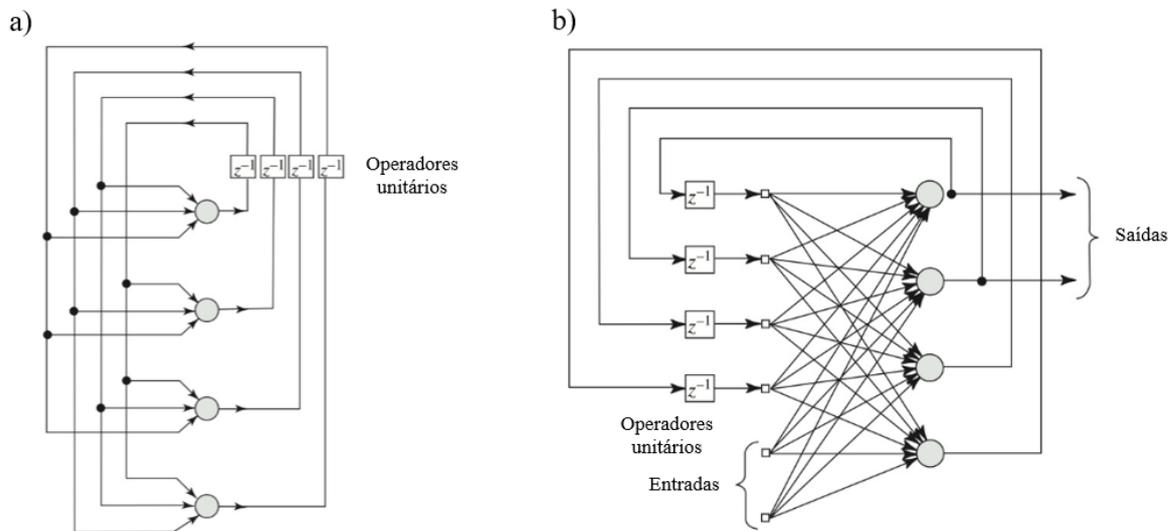
Figura 23: Rede *feedforward* de múltiplas camadas



Fonte: Adaptado de Haykin (2007).

- Rede recorrente: Uma rede neural recorrente difere de uma rede neural feedforward por ter pelo menos um laço de realimentação. Em uma rede neural recorrente, por exemplo, é possível ter uma camada de neurônios, onde cada neurônio envia seu sinal de saída de volta para as entradas de todos os outros neurônios, conforme Figura 24.a. Nessa estrutura representada na Figura 24.a, não existem laços de auto realimentação, que ocorrem quando a saída de um neurônio é direcionada de volta para sua própria entrada. A rede recorrente mostrada na Figura 24.a também não possui neurônios ocultos. Já na Figura 24.b, as conexões de realimentação originam-se tanto dos neurônios ocultos quanto dos neurônios de saída. Os laços de realimentação nas duas estruturas recorrentes impactam significativamente a capacidade de aprendizagem da rede e seu desempenho. Essas conexões de realimentação incluem o uso de ramos particulares compostos de elementos de atraso unitário (z^{-1}), o que leva a um comportamento dinâmico não-linear, admitindo-se que a rede neural contenha unidades não lineares (HAYKIN, 2007).

Figura 24: Redes recorrentes



Fonte: Adaptado de Haykin (2007)

2.6.4 Processo de treinamento de uma RNA

Uma das principais características das redes neurais artificiais é a sua habilidade de aprender a partir de amostras (padrões) que representam o comportamento de um sistema. Após o processo de aprendizado, no qual a rede compreende a relação entre as entradas e saídas, ela se torna capaz de generalizar soluções. Dessa forma, a rede consegue gerar uma resposta próxima da esperada para qualquer novo conjunto de sinais introduzido em suas entradas (SILVA; SPATTI; FLAUZINO, 2010).

O treinamento de uma rede neural consiste na sequência de passos ordenados para ajustar os pesos sinápticos e os limiares dos neurônios, com o objetivo de permitir que a rede generalize soluções para o sistema mapeado. Esse conjunto de passos é conhecido como algoritmo de aprendizagem. Durante o treinamento, a rede aprende a identificar características do sistema a partir de amostras retiradas do seu contexto. Normalmente, as amostras são divididas em dois subconjuntos: um de treinamento e outro de teste. O subconjunto de treinamento, que representa de 60% a 90% das amostras, é usado para ajustar os parâmetros da rede. Já o subconjunto de teste, que contém de 10% a 40% das amostras, é utilizado para avaliar a capacidade da rede em generalizar soluções de forma satisfatória. No treinamento de redes neurais artificiais, uma época de treinamento é definida como uma apresentação completa de todas as amostras do subconjunto de

treinamento, com o objetivo principal de ajustar os pesos sinápticos e os limiares dos neurônios da rede (SILVA; SPATTI; FLAUZINO, 2010).

De acordo com Padovani Neto (2019), pode-se dividir os métodos de aprendizagem em três grupos:

- **Treinamento Supervisionado:** No treinamento da rede, são apresentadas amostras de entrada juntamente com suas saídas correspondentes. Com base nesses dados, a rede aprende e formula hipóteses sobre o comportamento do sistema. Os pesos sinápticos são continuamente ajustados para reduzir os erros entre as saídas geradas pela rede e as saídas desejadas. O treinamento supervisionado pode ser feito por lotes (batch) ou de forma online. Na variante por lotes (batch), o treinamento utiliza todo o conjunto de dados de uma vez, ajustando os pesos sinápticos após a apresentação de todas as amostras. Quando o volume de dados é muito grande, normalmente se divide em lotes menores para reduzir o tempo de processamento computacional. Esse método é adequado para sistemas invariantes no tempo. Já na variante online, o treinamento é feito com a atualização dos pesos sinápticos após cada par de entrada e saída apresentado. Esse método é útil para sistemas que variam com o tempo, pois permite um ajuste contínuo. Após o ajuste, o par de treinamento correspondente pode ser descartado.
- **Treinamento não supervisionado:** Diferente do método supervisionado, o treinamento não supervisionado utiliza apenas os dados de entrada para treinar a rede. Nesse processo, a rede se auto-organiza e tenta identificar subconjuntos nos dados que compartilhem características semelhantes, formando o que se conhece como *clusters*. O número de *clusters* pode ser especificado durante o treinamento da rede.
- **Treinamento com reforço:** No treinamento com reforço, o erro não é medido diretamente, pois não há uma resposta específica a ser alcançada. A rede aprende a partir da interação contínua com o ambiente, avaliando o seu desempenho ao longo do tempo. A rede aprende a tomar melhores decisões observando os seus próprios comportamentos e ajusta suas ações através de um sistema de reforço.

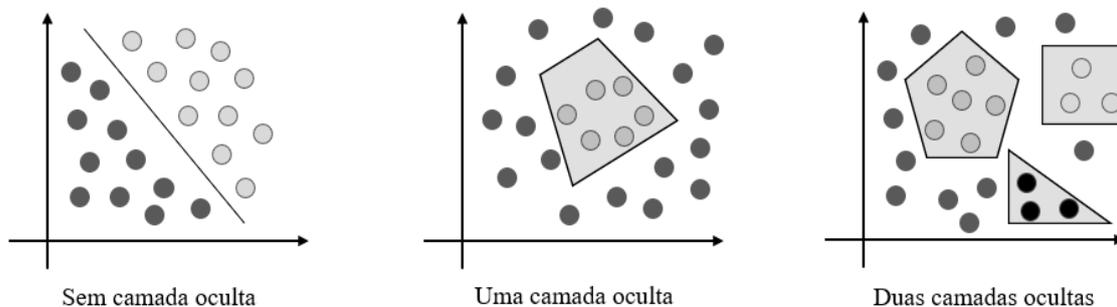
2.6.5 Redes MLP–*Multiple Layer Perceptrons*

As redes MLP são redes neurais *feedforward*, treinadas de forma supervisionada e formadas por uma ou mais camadas ocultas. Essa configuração possui a capacidade de lidar com problemas mais complexos, como a classificação de padrões não lineares, tornando-se, assim, o modelo mais amplamente utilizado (DIAS *et al.*, 2007; SILVA; SPATTI; FLAUZINO, 2010; ALMEIDA, 2011). Segundo Haykin (2007), as três principais características da MLP são as seguintes:

- Função de ativação não linear: O modelo de cada neurônio da rede inclui uma função de ativação não linear e diferenciável.
- Camadas ocultas: A rede apresenta uma ou mais camadas de neurônios ocultos, que não fazem parte da entrada ou saída da rede. Estes neurônios ocultos permitem que a rede aprenda tarefas complexas, extraíndo de forma progressiva, as características mais relevantes dos padrões de entrada.
- Alta conectividade: A rede apresenta alto grau de conectividade, determinado pelos pesos sinápticos.

Se nenhuma camada oculta for utilizada, a rede neural consegue apenas posicionar um hiperplano para separar diferentes classes dos dados. Com a inclusão de uma camada oculta, a rede passa a ter a capacidade de segmentar amostras que caem dentro de uma única região convexa. Com duas ou mais camadas ocultas, a rede pode criar múltiplas regiões de separação para as amostras. Esses cenários são mostrados sequencialmente na Figura 25 (SICSÚ; SAMARTINI; BARTH, 2023).

Figura 25: Efeito do número de camadas ocultas



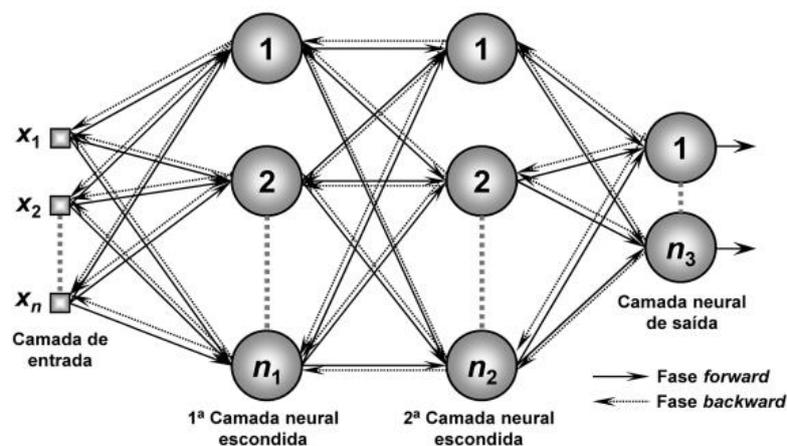
Fonte: Adaptado de Sicsú; Samartini; Barth (2023)

O número de camadas ocultas e a quantidade de neurônios, são alguns dos hiperparâmetros que precisam ser ajustados para otimizar o desempenho do algoritmo. Redes com muitas camadas ocultas ou muitos neurônios resultam em um alto tempo de treinamento, além de levar a um problema conhecido como *overfitting*. Nesse caso, a rede acaba “decorando” os padrões do conjunto de treinamento e perde a capacidade de generalizar, ou seja, de ter bom desempenho com novos dados. O *overfitting* pode acontecer em redes complexas aplicadas a um pequeno conjunto de amostras ou quando os padrões nos dados de treinamento apresentam pouca variação. Por outro lado, redes com poucos neurônios podem apresentar *underfitting* não conseguindo capturar relações complexas entre as variáveis de entrada (SICSÚ; SAMARTINI; BARTH, 2023).

De acordo com Haykin (2007), o algoritmo de treinamento mais amplamente utilizado em redes MLP é o *backpropagation*. Esse algoritmo realiza a atualização dos pesos de trás para frente, ou seja, da saída para a entrada. Essa atualização utiliza o método do gradiente descendente, que é uma técnica numérica utilizada para guiar a busca, passo a passo, pelo ponto de mínimo de uma superfície (SICSÚ; SAMARTINI; BARTH, 2023). Lima (2014), afirma que esse método permite propagar o erro da camada de saída (onde o erro é conhecido) para as camadas ocultas. Dessa forma, é possível ajustar os parâmetros de todas as camadas da rede levando em consideração o erro na saída, buscando sempre a alteração dos parâmetros que minimize o erro na saída da rede.

Segundo Silva, Splatti e Flauzino (2010), a aplicação do algoritmo de treinamento *backpropagation*, pode ser dividida em duas fases conhecidas como *forward* e *backward*. A representação dessas fases é mostrada na Figura 26.

Figura 26: Fases de treinamento de uma rede MLP



Fonte: Silva, Splatti e Flauzino (2010).

Na fase *forward*, os sinais de entrada $\{x_1, x_2, \dots, x_n\}$ de uma amostra do conjunto de treinamento são inseridos na rede e propagados camada a camada até gerar as saídas. O objetivo desta fase é obter as repostas da rede utilizando os pesos sinápticos e limiares de seus neurônios atuais, permanecendo, portanto, inalterados nessa etapa. Após a obtenção das saídas, elas são comparadas com as respostas desejadas, calculando-se o desvio entre o resultado esperado e o produzido. Esses erros serão utilizados na próxima etapa para ajustar os pesos e limiares da rede.

A segunda fase, denominada de *backward*, consiste na propagação reversa. Nessa etapa os pesos sinápticos e os limiares de ativação são ajustados com base nos erros obtidos no passo anterior, visando minimizar esse desvio. Esse processo é repetido a cada iteração, ocasionando uma redução gradativa do erro (PADOVANI NETO, 2019).

Gardner (1998), afirma que o algoritmo de retropropagação (*backpropagation*) pode ser resumido, conforme os passos abaixo:

1. Inicializar os pesos da rede;
2. Apresentar o primeiro vetor de entrada, extraído dos dados de treinamento, à rede;
3. Propagar esse vetor de entrada pela rede para gerar uma saída;
4. Comparar a saída obtida com a esperada e calcular o erro resultante;
5. Enviar o erro de volta pela rede (retropropagação);
6. Ajustar os pesos da rede para reduzir o erro geral;
7. Repetir os passos 2 a 7 com o próximo vetor de entrada, até que o erro geral seja suficientemente pequeno.

2.6.6 Métricas de desempenho

Para avaliar o desempenho das redes neurais artificiais em diferentes aplicações, são empregadas métricas que tornam possível verificar a confiabilidade de uma classificação ou aproximação realizada pela rede neural (PADOVANI NETO, 2019). As métricas de desempenho comumente utilizadas são: Matriz de confusão, acurácia, *f1-score*, precisão e recall (OLSON, 2008).

2.6.6.1 Matriz de confusão

A matriz de confusão registra a quantidade de classificações corretas e incorretas para cada uma das classes presentes no problema de classificação (VIANA, 2023). Na Figura 27, é apresentada uma matriz de confusão genérica. As colunas da matriz representam as previsões feitas pela rede neural durante o treinamento, enquanto as linhas indicam os resultados esperados ou desejados (PADOVANI NETO, 2019). Os valores presentes na diagonal, que vai do canto superior esquerdo ao canto inferior direito, correspondem às classificações corretas tomadas. Já os números foras dessa diagonal indicam os erros cometidos (OLSON, 2008).

Figura 27: Matriz de confusão simples

		Classe predita	
		Positivo	Negativo
Classe verdadeira	Positivo	Verdadeiro positivo (VP)	Falso negativo (FN)
	Negativo	Falso positivo (FP)	Verdadeiro negativo (VN)

Fonte: Autor.

De acordo com Felix (2023):

- Verdadeiro positivo (VP): Refere-se às observações que o modelo identificou como positivas e que de fato eram positivas;
- Verdadeiro negativo (VN): Refere-se às observações que o modelo classificou como negativas e que, de fato, eram negativas;
- Falso positivo (FP): Refere-se às observações que o modelo classificou como positivas, mas que, na realidade, eram negativas;
- Falso negativo (FN): Refere-se às observações que o modelo classificou como negativas, mas que, de fato, eram positivas.

2.6.6.2 Acurácia

A acurácia é determinada através da razão da soma do total de positivos e negativos pelo número total de amostras. Assim, essa métrica pode ser entendida como a taxa de acertos do modelo. No entanto, ao classificar estados anômalos, a acurácia pode ocultar um sistema com taxas consideráveis de falsos positivos (FP) e falsos negativos (FN). A Equação 18 determina a acurácia (OLSON, 2008; REIS, 2021).

$$Acurácia = \frac{VP + VN}{VP + FN + VN + FP} \quad (18)$$

2.6.6.3 Recall

A métrica *recall*, ou também conhecida como sensibilidade, é dada pela Equação (19). Essa métrica indica a proporção de verdadeiros positivos (VP) em relação a todas as classes positivas do conjunto de dados. (REIS, 2021).

$$recall = \frac{VP}{VP + FN} \quad (19)$$

2.6.6.4 Precisão

É a métrica que analisa a proporção de dados classificados como positivos e que, de fato, são positivos. Enquanto o *recall* diminui em casos em que o classificador não identifica corretamente um cenário de falha, a precisão reduz à medida que aumenta a quantidade de falsos alarmes. Através da Equação 20 é possível definir o valor da precisão. (REIS, 2021; FELIX, 2023).

$$recall = \frac{VP}{VP + FP} \quad (20)$$

2.6.6.5 F1-score

É a média harmônica determinada em função da precisão e *recall*. De forma indireta, as métricas precisão e *recall*, indicam se a taxa de falsos positivos e falsos negativos comprometem a classificação. Essa métrica combina essas duas outras citadas anteriormente através da Equação 21. Um valor para o *F1-score* mais próximo de 1,

sinaliza que há um maior sucesso na identificação da classe positiva (REIS, 2021; FELIX, 2023).

$$F1 - score = 2 \times \frac{Precisão \times Recall}{(Precisão + Recall)} \quad (21)$$

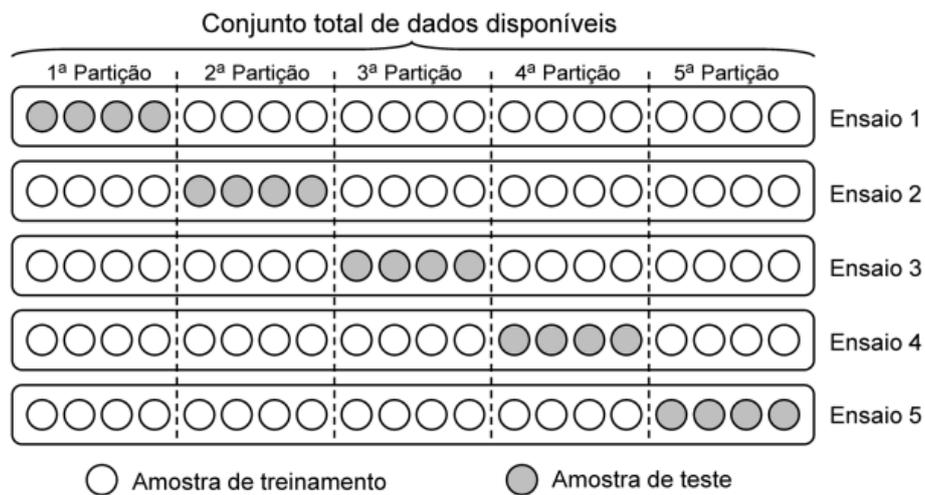
Recall, precisão e *accuracy* não devem ser analisados separadamente, ao invés disso, eles devem ser considerados em conjunto na avaliação do modelo de destino. Um valor elevado de precisão significa que todas as variáveis retornadas foram corretamente classificadas, mas é possível que se tenham perdido variáveis relevantes; enquanto um resultado elevado de recall significa que todas as variáveis relevantes foram encontradas, mas pode haver uma abundância de resultados inúteis. Acurácia é a exatidão geral do modelo sendo considerado, que leva em conta não apenas as classificações verdadeiras positivas, mas também os valores verdadeiros negativos. (NASCIMENTO, 2012 p. 47)

2.6.6.6 Validação cruzada

Uma das técnicas estatísticas amplamente utilizadas para avaliar e escolher as melhores topologias é a validação cruzada (*cross-validation*). O objetivo principal dessa técnica é avaliar o desempenho de cada topologia quando aplicada a um conjunto de dados distinto daquele utilizado no ajuste dos seus parâmetros internos. Três métodos de validação cruzada são geralmente utilizados no processo de seleção de redes MLP, são eles: Validação cruzada por amostragem aleatória (*random subsampling cross-validation*), validação cruzada k-partições (*k-fold cross-validation*) e validação cruzada por unidade (*leave-one-out cross-validation*) (SILVA, SPATTI E FLAUZINO, 2010). O método utilizado neste trabalho foi o *k-fold cross-validation*.

Nesse método, o conjunto total de amostras é dividido em k partições, sendo que $(k-1)$ delas são utilizadas para formar o conjunto de treinamento, enquanto a partição restante será o conjunto de teste. Esse processo de aprendizado se repete k vezes até que todas as partições sejam utilizadas como subconjunto de teste. A Figura 28, ilustra essa estratégia para um total de 20 amostras, considerando $k = 5$, o que resulta em 5 rodadas de validação (SILVA, SPATTI E FLAUZINO, 2010).

Figura 28: Método de validação cruzada usando k -fold.



Fonte: Silva, Spatti e Flauzino (2016).

O valor do parâmetro k depende da quantidade total de amostras disponíveis, sendo geralmente definido um número entre 5 e 10. O desempenho global de cada topologia candidata é então calculado com base na média dos desempenhos individuais obtidos ao aplicar as k partições (SILVA, SPATTI E FLAUZINO, 2010).

3 REVISÃO DA LITERATURA

Nessa etapa do trabalho, foi realizada uma revisão da literatura com o objetivo de analisar trabalhos que abordam o diagnóstico de falhas em sistemas rotativos, principalmente através de análise de som e vibração, bem como a aplicação de redes neurais ou outros sistemas inteligentes. A metodologia aplicada nesse tópico consistiu, basicamente, em um levantamento de publicações acadêmicas, incluindo artigos, dissertações e teses.

Baydar e Ball (2003), estudaram o uso de sinais acústicos, em conjunto com vibrações, para detectar falhas em engrenagens usando transformada de Wavelet. Os resultados mostraram que os sinais acústicos são eficazes na detecção precoce de falhas, como quebra e trinca de dentes.

Rafiee et al (2007), desenvolveram no trabalho intitulado de “*Intelligent condition monitoring of a gearbox using artificial neural network*”, um procedimento experimental para reconhecer falhas em engrenagens e mancais de um redutor, utilizando uma rede neural *MLP - Multilayer Perceptron*. O vetor característica, foi inovado com base no desvio padrão dos coeficientes do pacote Wavelet. As condições da engrenagem foram classificadas como normais, com desgaste leve e médio, dentes quebrados e uma falha geral no mancal, resultando em 5 neurônios na camada de saída para identificação das falhas.

Wu e Chan (2009), propuseram uma técnica de monitoramento de condição e identificação de falhas em máquinas rotativas usando redes neurais artificiais e transformada de wavelet. Nesse estudo, a emissão sonora de um conjunto de engrenagens foi utilizada para avaliar a técnica de diagnóstico proposta. Os sinais foram coletados por meio de um microfone, posicionado próximo ao par de engrenagens com falhas. O conjunto foi operado em velocidade de 300, 600, 900, 1200 e 1500 rpm, testando-se 7 condições de operação, incluindo o estado sem falhas e engrenagens com dentes quebrados. No experimento, uma técnica de transformada de wavelet contínua foi combinada com a seleção de características do espectro de energia para avaliar os sinais no conjunto de engrenagens. Técnicas de redes neurais artificiais, tanto com redes neurais probabilísticas quanto com redes neurais convencionais de backpropagation, foram comparadas. Os resultados mostraram que a emissão sonora pode ser utilizada monitorar a condição do conjunto de engrenagens, atingindo uma taxa de reconhecimento de falhas de 98%.

Saravanan e Ramachandran (2010), apresentaram uma técnica que utiliza a transformada discreta de wavelet com as funções daubechies (db1 a db15) para a extração de características do sinal de vibração de engrenagens cônicas de dentes retos. Essas engrenagens foram avaliadas sob diferentes condições: sem defeito, com dente quebrado, trinca na raiz do dente e desgaste na face dos dentes, variando a carga e a lubrificação. Os sinais coletados por um acelerômetro piezoelétrico foram processados para extrair recursos wavelet em diferentes níveis e inseridos em um classificador baseado em uma rede neural perceptron multicamadas com algoritmo backpropagation, atingindo uma eficiência média de 95%.

Srihari et al (2010), foi desenvolvido um sistema de detecção de falhas com auxílio de uma rede neural artificial utilizando características no domínio do tempo extraídas dos sinais de vibração para dois casos de operação: caixa de engrenagem desgastada e dente trincado. A rede neural possui duas camadas ocultas e o número de neurônios em cada uma foi igual a 9. Foi definido uma taxa de aprendizado de 0,15. O trabalho demonstrou uma acurácia de 100%, utilizando a rede feedforward multicamada.

Khazaei et al. (2013), analisaram engrenagens planetárias de dentes retos, em quatro estágios de falha, desde trincas até desgaste dos dentes. Foi realizada uma análise de vibração e acústica utilizando respectivamente um acelerômetro e um microfone, abrangendo uma faixa de frequência de 20 a 20.000 Hz. AS características dos sinais foram extraídas através da discreta de wavelet até o nível 3, incluindo os coeficientes de aproximação e detalhe, mas sem especificar o tipo de wavelet ou algoritmo da rede neural utilizada. Ao invés de seguir o método clássico, os dados de vibração e acústica foram combinados para treinar a rede neural, com 60 amostras coletadas para cada condição, sendo 45 para treinamento e 15 para testes. A fusão de dados acústicos e de vibração, resultou em uma acurácia de 98,6%, refletindo a eficácia da fusão de dados para detecção e classificação de falhas, representando um aumento de 10% na precisão em relação ao uso individual dos sinais.

Ismon et al (2014), utilizaram técnicas de monitoramento de vibração e temperatura para caracterizar o comportamento vibracional de engrenagens sem fim em função da viscosidade do lubrificante para diferentes velocidades do motor. Lubrificantes de maior viscosidade reduziram as amplitudes de vibração e aumentaram a temperatura, especialmente a 1150 RPM, destacando uma correlação entre viscosidade, vibração e temperatura.

Waqar e Demetgul (2016), apresentaram uma técnica de diagnóstico de falhas em engrenagens sem fim, usando sinais de vibração e som sob diferentes condições de funcionamento. A Transformada Rápida de Fourier foi utilizada para extrair características dos sinais. Um modelo de rede neural artificial MLP foi desenvolvido para classificar esses sinais, enquanto uma câmera térmica monitorou os padrões de aquecimento. O modelo de MLP permite prever a velocidade e o nível de óleo, facilitando o diagnóstico de falhas. Nesse estudo foram analisadas anomalias no redutor através da variação do óleo, variação de velocidade e remoção de material dos dentes. Cada experimento foi repetido 10 vezes, resultando em um total de 160 experimentos. Os dados de som foram coletados através de um microfone em uma faixa de frequência compreendida de 6 a 20 kHz, em duas velocidades de operação diferentes: 1440 rpm e 1920 rpm, e com quatro níveis de óleo distintos: 0 ml, 20 ml, 50 ml e 100 ml. A rede neural apresentou uma acurácia de 99,78%.

Heydarzadeh et al. (2016), utilizaram redes neurais profundas (DNN) para diagnosticar 5 níveis de carga em caixa de engrenagens cilíndricas helicoidais, aplicando três técnicas de monitoramento: análise de vibração, acústica e torque. A transformada discreta de wavelet (DWT) foi aplicada para extrair as características que alimentaram a rede. O estudo utilizou um motor de 250W acoplado a uma engrenagem helicoidal de estágio único, com sensores de aceleração, torque e um microfone para capturar os sinais em diferentes condições operacionais. Foram utilizados 70% dos dados para treinamento e validação, e 30% para teste. A rede neural possui duas camadas ocultas e o treinamento utilizou o algoritmo *mini-batch backpropagation* e uma taxa de *dropout* de 50%. A análise de vibração apresentou a melhor acurácia, seguida pela análise sonora, com 97,31% e 93,24%, respectivamente.

Mechefske e Jin (2019), avaliaram a eficácia dos sinais acústicos (AE) para detecção de falhas em caixas de engrenagem de baixa velocidade. A energia absoluta e o RMS destacam-se como os melhores parâmetros para diferenciar redutores em boas condições dos que apresentam falhas. A análise de frequência indicou picos mais altos em frequências baixas para redutores defeituosos, demonstrando que o AE é eficaz para o monitoramento das condições de funcionamento.

Lyra (2019), propôs um método não invasivo para diagnosticar falhas em rolamentos de motores de indução trifásicos através da análise do som emitido durante o funcionamento do equipamento, por meio de redes neurais artificiais e processamento wavelet. A metodologia está baseada na coleta do som através de um dispositivo

eletrônico, seguida da decomposição do sinal em detalhes e aproximações usando a análise wavelet multiresolução (AWM). Os dados estatísticos extraídos desses detalhes foram utilizados como entrada da rede neural Perceptron Multicamadas (PMC) e a Rede de Função de Base Radial (RBF). Nos testes experimentais foi obtido 97% de acerto com a PMC e 90% com a RBF.

Chen et al (2019), propuseram um método para diagnosticar falhas em redutores planetários de turbinas eólicas, utilizando rede neural convolucional e transformada discreta de wavelet. O método foi testado em 6 condições de operação, com cargas variando de 0,38 A e 0,67 A, e velocidades de rotação de 30 Hz, 40 Hz e 50 Hz. Os sinais de vibração foram coletados com uma frequência de amostragem de aproximadamente 30,72 kHz, totalizando 6,39s de dados por condição de funcionamento. O modelo CNN + DWT atingiu uma acurácia de 99,3% em ambiente silencioso. Em condições ruidosas, com SNR (relação sinal-ruído) de 20 dB, o método alcançou mais de 90% de acurácia, superando o DAS + DWT (84,12%) e o DBN + DWT.

Singla et al (2019), propuseram o uso de sinais acústicos registrados por microfone para detectar falhas em rolamentos, aplicando FFT para avaliar o desgaste.

Dube e Jaybhaye (2020), realizaram um estudo de avaliação de um redutor coroa sem fim, medindo temperatura e vibração em dois estágios, primeiro, sob condições normais sem carga, e segundo, com um aumento de 10 Kg a cada 10 minutos em um ciclo de 70 minutos. O monitoramento mostrou variações nas respostas de temperatura e vibração em função da carga aplicada. Esse trabalho evidenciou a importância do monitoramento para prever a vida útil do equipamento e entender seu comportamento sob diferentes condições de operação.

Agrawal e Jayaswal (2020), apresentaram um estudo sobre diagnóstico de falhas em rolamentos, utilizando redes neurais e SVM. Os experimentos foram conduzidos em uma bancada de testes, e a partir dos coeficientes obtidos com a transformada de wavelet, foram extraídos nove descritores estatísticos: valor médio, RMS, valor de pico, variância, desvio padrão, assimetria, curtose, fator de crista e a velocidade de rotação do eixo. A função wavelet utilizada foi a Morlet. Os resultados expostos pelos autores indicam uma precisão de classificação de aproximadamente 94% para as redes neurais e 96% para o SVM.

Vrba et al (2021), propuseram uma abordagem automatizada para diagnóstico de falhas em caixas de engrenagens, sem a necessidade do conhecimento prévio sobre a construção do redutor de engrenagens, em outras palavras, essa nova abordagem, possui

a capacidade de adaptar os critérios de diagnóstico da caixa de engrenagens de acordo com um modelo específico sem a supervisão de especialistas humanos. Esse método utiliza a análise do erro de previsão gerado por um filtro adaptativo. O desvio padrão desse erro é processado por uma máquina de vetor de suporte, que classifica a condição de funcionamento do equipamento em estudo. O método proposto foi validado através de validação cruzada em um conjunto de dados públicos, composto por 1760 amostras de teste.

Karabacak et al (2022), apresenta um método inteligente de seleção de características e classificação para o diagnóstico de falhas em caixas de engrenagens sob diferentes condições de operação. A detecção e classificação das falhas foram baseadas em dados de vibração, som e imagens térmicas. Foram utilizados classificadores RNA e SVM. Os melhores desempenhos de classificação (99,2% com RNA e 98,7% com SVM) foram alcançados ao combinar os dados de todas as 3 fontes.

Liu et al (2022), propuseram um método de monitoramento de processos baseado em vibração para classificar falhas na retificação de engrenagens. O modelo desenvolvido de *deep learning*, usando Wavelet Packet Decomposition (WPD) e Redes convolucionais profundas (DCNN) apresentou acurácia de 95,83% na classificação dos sinais de vibração. A técnica Grad-CAM foi utilizada para interpretar as decisões da rede neural, correlacionando as áreas de ativação com os parâmetros de fabricação.

Goswami e Rai (2023), abordam os modos de falha de sistemas de engrenagens, fornecendo um resumo desses modos com métodos de detecção. Modelos baseados em modulação e dinâmica para detecção de falhas, além de métodos de análise de severidade de falhas e previsão de vida útil (RUL), são revisados. O estudo também sugere técnicas para simular falhas em laboratório e propõe estratégias de manutenção corretiva e preventiva.

Oliveira Neto (2023), desenvolveu um sistema inteligente para diagnóstico prescritivo da severidade das más condições de funcionamento em um redutor coroa sem fim. As condições de funcionamento foram simuladas em uma bancada experimental e foram: bom estado, desalinhamento, desbalanceamento e sobrecarga. Foram utilizados sinais sonoros, coletados via microfone, para extração de características através da análise Wavelet e ferramentas estatísticas. Uma rede neural artificial multicamada foi treinada para classificar as severidades em leve, média e grave, obtendo 99,7% de acurácia.

Barshikar e Baviskar (2023), realizaram um estudo em um redutor coroa sem fim, simulando falhas no rolamento (pista interna e externa) e na coroa sem fim. Um modelo

de RNA foi desenvolvido para monitoramento das condições com base em sinais de vibração. Os resultados mostraram que a amplitude de vibração varia de acordo com a condição do redutor, especialmente com falhas na pista interna do rolamento. O modelo de RNA treinado com algoritmo *trainscg* e 12 neurônios na camada oculta, obteve acurácia de 92,9%.

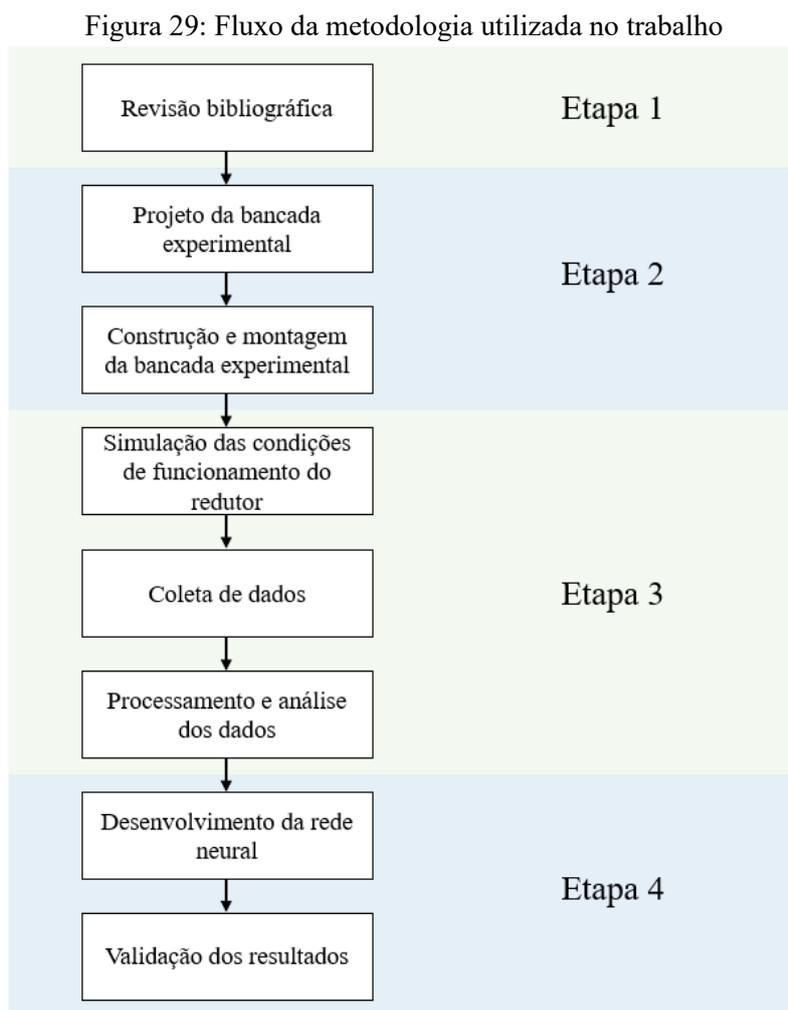
Shubita et al (2023), desenvolveram um estudo para detecção de falhas em uma furadeira utilizando sinais sonoros e aprendizado de máquina (ML). Os sons foram gravados com um smartphone a uma taxa de 48 kHz em diferentes condições da máquina (saudável e com falhas). Após a captura, os dados foram pré-processados usando uma janela Hanning e um filtro passa-banda para reduzir ruídos. Foram extraídos 16 indicadores do sinal, analisados no domínio do tempo e da frequência. O melhor modelo de ML, alcançou 97,4% de acurácia. O dispositivo desenvolvido foi implementado em um dispositivo embarcado, que realiza toda análise localmente, sem processamento na nuvem. A acurácia final do sistema foi de 96,1%.

Shirdel et al (2024), propuseram um método híbrido para detecção de falhas em motores de indução usando sinais sonoros e técnicas de aprendizado de máquinas.

O presente trabalho se distingue pela análise de diversas condições de funcionamento e definição de níveis de severidade para cada uma delas, proporcionando um diagnóstico operacional de redutores mais abrangente. Além disso, essa pesquisa propõe uma solução acessível e de baixo custo ao utilizar sinais acústicos capturados por um celular comum, combinados com técnicas de inteligência artificial, especificamente redes neurais artificiais, para a detecção e classificação de falhas.

4 METODOLOGIA

A metodologia adotada neste trabalho é de caráter experimental, tendo como principal objetivo definir o estado de funcionamento e o nível de severidade de conjunto motor e redutor coroa sem fim, que serve como objeto desse estudo. Para facilitar o desenvolvimento da pesquisa, ela foi dividida em quatro macro etapas, conforme ilustrado na Figura 29.



Fonte: Autor

A etapa 1 é constituída basicamente pela revisão bibliográfica, onde foi feito o estudo para entendimento profundo dos temas relacionados com a pesquisa, como: Funcionamento dos redutores coroa sem fim, tipos e características dos defeitos em redutores, técnicas de processamento de sinais de áudio e vibração e modelos de redes neurais utilizadas para reconhecimento das condições de funcionamento de máquinas rotativas.

A etapa 2, é composta por duas atividades, que foram: Projeto da bancada experimental, onde houve a definição dos requisitos para reprodução dos defeitos, construção do desenho técnico, seleção de materiais e componentes e planejamento da integração dos sistemas de coleta de áudio e vibração. Na atividade de construção da bancada foram realizadas as aquisições dos componentes, usinagem das partes que formam a bancada na oficina da Universidade Federal da Paraíba, alinhamento e nivelamento da bancada e testes preliminares para verificar o seu funcionamento correto.

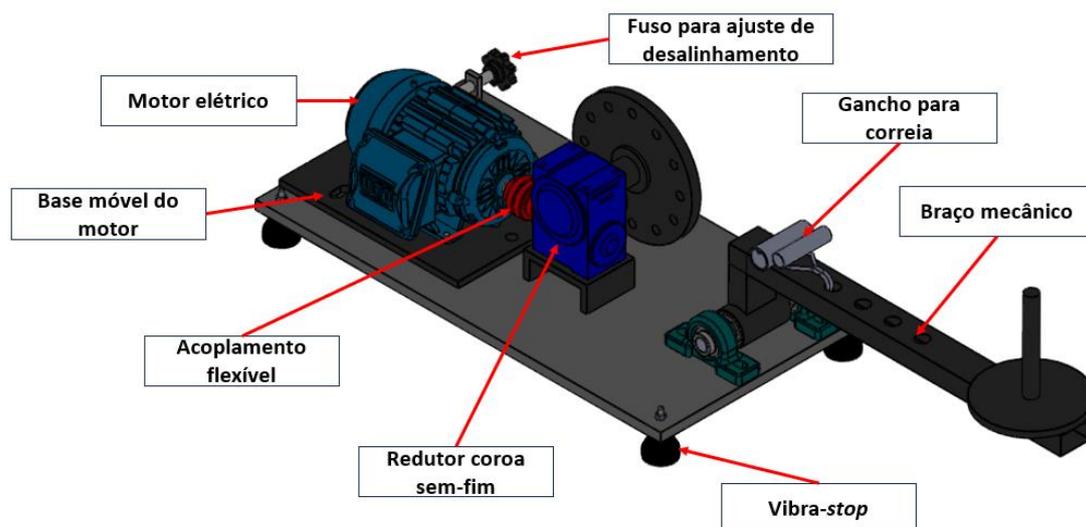
Na etapa 3 foram reproduzidas as condições de funcionamento, sendo elas: desalinhamento angular, sobrecarga, lubrificação ineficiente e bom estado. Além disso, nessa etapa foi realizado a coleta, armazenamento e organização dos dados de vibração e áudio. O processamento dos dados foi a última atividade dessa etapa. Técnicas como Transformada Rápida de Fourier e Transformada de Wavelet foram utilizadas para extração das características (*features*) dos sinais para posteriormente alimentar a rede neural. Em seguida foi feita uma análise dos componentes de frequência e identificação de possíveis padrões associados as condições de funcionamento.

Na etapa 4 foram desenvolvidas duas redes neurais, uma para classificar o nível de severidade e outra para identificar a condição de funcionamento. Os treinamentos das RNAs foram realizados com os dados de áudio de funcionamento do redutor. Além disso, foi avaliado o desempenho das RNAs com base em métricas como: matriz de confusão, acurácia, precisão, recall e *f1-score*.

4.1 Projeto, construção e montagem da bancada experimental

O projeto da bancada experimental foi desenvolvido no software *SolidWorks*. A estrutura da bancada foi projetada de forma a permitir ajustes mecânicos, facilitando a reprodução de diferentes condições de funcionamento encontradas em operações reais. Na Figura 30, é possível observar o desenho da bancada experimental, destacando seus principais componentes, que são: Motor elétrico, redutor coroa sem fim, acoplamento flexível, vibra-stop, base móvel do motor, projetada para permitir ajustes de inclinação, gerando desalinhamento angular, braço mecânico utilizado para suportar as massas adicionadas, que geram sobrecarga, e um gancho que conecta o braço ao flange de saída do redutor através de uma correia.

Figura 30: Projeto da bancada para reprodução das condições de funcionamento do redutor



Fonte: Autor.

Após a definição do princípio de funcionamento e dos componentes principais, detalhados no projeto, avançou-se para as etapas de seleção e aquisição dos materiais, conforme os requisitos funcionais. Em seguida, na oficina da Universidade Federal da Paraíba, foram fabricados componentes, como as bases e braço mecânico. A Figura 31, ilustra o resultado da montagem da bancada para uma condição de funcionamento saudável.

Figura 31: Bancada experimental montada

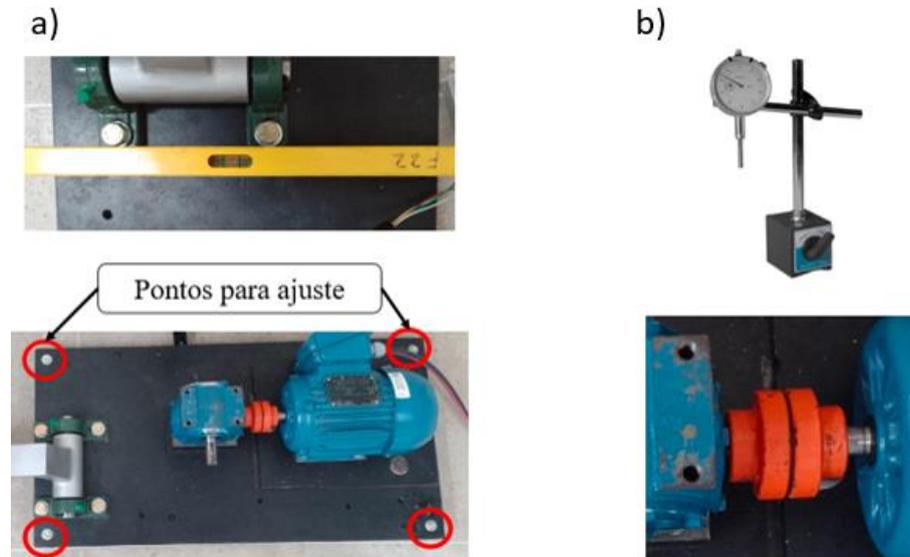


Fonte: Autor.

Para garantir o funcionamento ideal da bancada, foi necessário realizar o nivelamento da sua base através da regulagem dos quatro parafusos localizados nos pés da bancada, devido a irregularidades apresentadas no piso. A aferição do nivelamento, foi feita através de um nível de bolha. Além disso foi feito um alinhamento entre os eixos do

motor e do redutor. Nessa etapa utilizou-se um relógio comparador para verificação de desvios angulares e axiais. A Figura 32, ilustra o processo de nivelamento e alinhamento adotado na montagem da bancada.

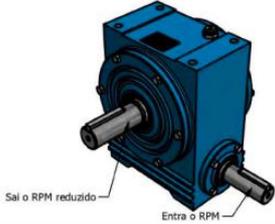
Figura 32: Processo de (a) nivelamento e (b) alinhamento da bancada experimental



Fonte: Autor.

Nas Tabelas 5, 6 e 7, são apresentadas as características do redutor, motor e acoplamento, respectivamente.

Tabela 5: Características do redutor

Redutor	
	
Tipo	Coroa sem fim
Redução	12
Potência máxima	0,5 cv
Torque na saída	16,3 N.m
Quantidade de óleo	0,15 L
Tipo de lubrificante	Óleo ISO-460
Rendimento	0,66
Massa	5 Kg
Nº de dentes na coroa	24

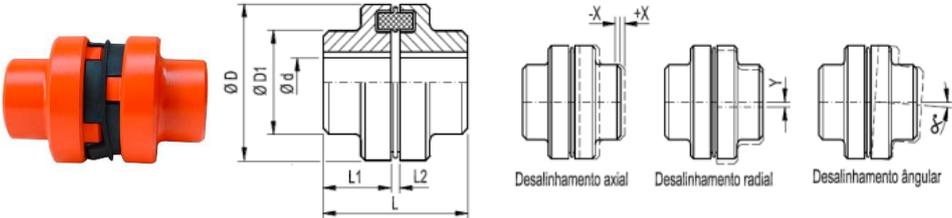
Fonte: Autor

Tabela 6: Características do motor

Motor	
	
Frequência	60 Hz
Tensão	280/320 V
Número de polos	4
Corrente nominal	1,77/1,02 A
Potência	0,5 cv
Fator de serviço	1,25
Rotação nominal	1700 RPM
Grau de proteção	IP55
Massa	11 Kg

Fonte: Autor

Tabela 7: Características do acoplamento flexível

Acoplamento flexível	
	
Descrição	GR 050
D	50 mm
D1	33 mm
d	22 mm
L	54 mm
L1	26 mm
L2	$2,0 \pm 0,5$ mm
Desalinhamento axial $\pm X$	0,5 mm
Desalinhamento radial $\pm Y$	0,5 mm
Desalinhamento angular $\pm \alpha$	$1,5^\circ$

Fonte: Autor

4.2 Verificação da frequência de rotação e engrenamento

Após a montagem da bancada, foi feita a verificação das frequências de rotação e engrenamento. Essas frequências são fundamentais para a análise subsequente das condições de operação do equipamento. A velocidade de rotação do motor foi medida utilizando um tacômetro, sendo ela de 1780 RPM, o que corresponde a 29,67 Hz.

Figura 33: Verificação da frequência de rotação com o tacômetro



Fonte: Autor.

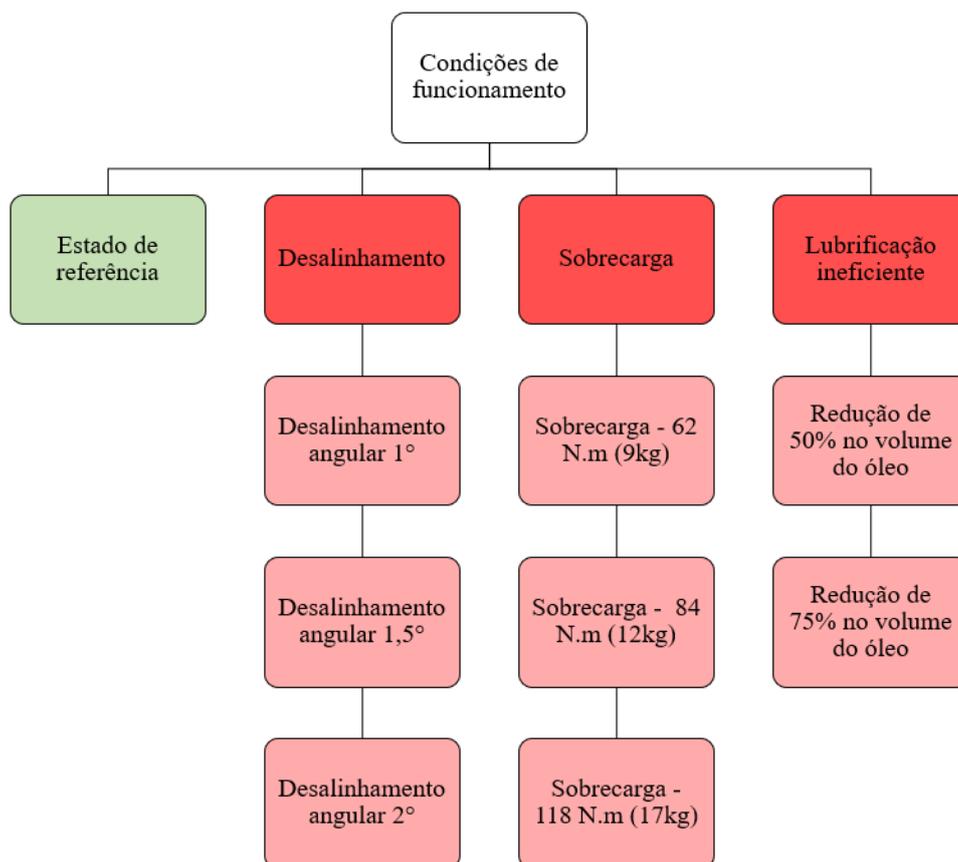
A partir da velocidade rotação medida e dos dados técnicos do redutor, que indicam um fator de redução de 12, conforme apresentado na Tabela 5, podemos calcular a velocidade no eixo de saída, que resulta em 148,33 rpm. Com o número de dentes na coroa do redutor sendo 24, através da Equação (15), é determinado a frequência de engrenamento, sendo ela de aproximadamente 59,33 Hz.

$$f_e = N \cdot f_r = 24 \cdot (148,33) = 3559,92 \text{ rpm} = 59,33 \text{ Hz}$$

4.3 Reprodução das condições de funcionamento da bancada

No estudo experimental em questão, foi realizada a reprodução do estado de referência da bancada, ou seja, representando as condições ideais de operação, além dos testes de condições de desalinhamento angular, sobrecarga e lubrificação ineficiente. Três níveis de desalinhamento angular foram observados, sendo eles: 1° , $1,5^\circ$ e 2° . A sobrecarga também foi avaliada em três níveis distintos através da aplicação das seguintes cargas: 9 kg, 12 kg e 17 kg. Para o estado de lubrificação ineficiente, foram feitos testes através da redução de 50% de óleo no primeiro cenário e redução de 75% de óleo no segundo cenário. A Figura 34, ilustra todos os cenários de condições de funcionamento reproduzidos na bancada experimental.

Figura 34: Condições de funcionamento reproduzidas na bancada experimental



Fonte: Autor.

- **Condição de referência:** Para a reprodução da condição de referência foi feito a verificação do nivelamento da bancada com auxílio do nível bolha e alinhamento dos eixos do motor e redutor com o relógio comparador.

Figura 35: Condição de referência



Fonte: Autor.

- Desalinhamento angular:** O desalinhamento angular foi gerado através da movimentação angular da base do motor com auxílio de um fuso. Os valores de desalinhamento foram estabelecidos com base no limite especificado para o acoplamento, $1,5^\circ$. Assim, foram realizados testes em três condições: desalinhamento angular de 1° , representando uma condição abaixo do limite suportado; $1,5^\circ$, correspondente ao limite especificado; e 2° ; caracterizando uma condição acima do limite tolerado. A Figura 36, ilustra o ensaio de desalinhamento angular na bancada, onde α é o ângulo de desalinhamento.

Figura 36: Reprodução da condição de desalinhamento angular



Fonte: Autor.

- Sobrecarga:** A reprodução dessa condição foi realizada através da aplicação de pesos na extremidade do braço mecânico, fixado por mancais, e que possui um gancho posicionado em um de seus furos, no qual é conectada uma correia. A correia, por sua vez, está acoplada ao flange do eixo de saída do redutor. A aplicação de cargas na extremidade do braço mecânico foi feita para gerar um

torque maior que o torque do eixo de saída do redutor, gerando assim a sobrecarga. Os momentos torcionais gerados foram: 62 N.m, resultante da aplicação de 9 kg; 84 N.m, induzido pela colocação de 12 kg; e 118 N.m produzido pela aplicação de 17 kg. Os pesos foram apoiados na região vermelha do braço mecânico. A Figura 37, ilustra a configuração da condição de sobrecarga.

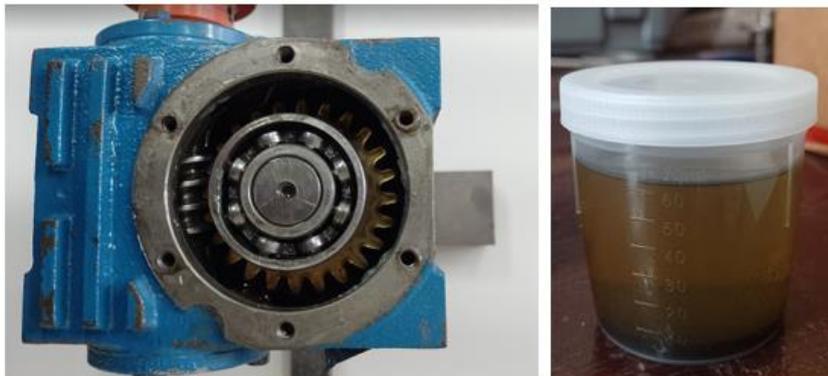
Figura 37: Reprodução da condição de sobrecarga



Fonte: Autor.

- **Lubrificação ineficiente:** A avaliação da lubrificação ineficiente foi feita através da redução do nível de óleo do redutor. O redutor tem a capacidade de 0,15L de óleo. Os níveis de redução de óleo foram definidos com base na quantidade mínima de óleo necessária para manter a lubrificação por salpico. Dois níveis de redução foram avaliados: Redução de 50%, estabelecido como o limite para que o redutor continuasse lubrificando adequadamente por salpico. Já o segundo, com redução de 75% do óleo, foi projetado para comprometer essa lubrificação.

Figura 38: Redução do óleo do redutor para reprodução da condição de lubrificação ineficiente



Fonte: Autor.

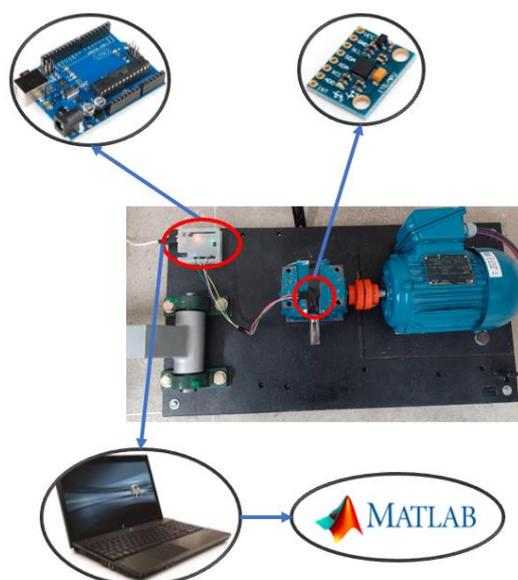
De acordo com Banks et al. (2004), um dos modos de falha mais críticos de um sistema de engrenagens, está relacionado à perda de lubrificação. O sistema de lubrificação é a parte mais crítica de qualquer sistema mecânico, pois desempenha diversas funções, como: Redução de atrito, redução de desgaste, resfriamento e anticorrosão. Uma perda de lubrificação leva a um grande atrito e desgaste.

4.4 Coleta de dados

4.4.1 Vibração

Para a coleta dos dados de vibração, foi construído um sistema de baixo custo utilizando um acelerômetro MPU6050, um Arduino UNO, um Notebook e o MATLAB. Os dados de aceleração foram coletados durante um período de 30 segundos, com uma taxa de aquisição de 408 Hz. De acordo com o teorema de Nyquist, essa taxa de aquisição permite a captura de frequências de no máximo 204 Hz, eliminando o risco de *aliasing*. O fluxo de coleta de dados segue a seguinte sequência: O acelerômetro realiza as medições dos sinais de aceleração, que são enviados para o ARDUINO. O ARDUINO captura os dados ao longo de 30 segundos. Em seguida, os dados coletados são salvos em um arquivo TXT para posteriormente serem tratados no MATLAB. A Figura 39, ilustra a configuração do sistema para coleta dos dados de vibração e seus principais componentes.

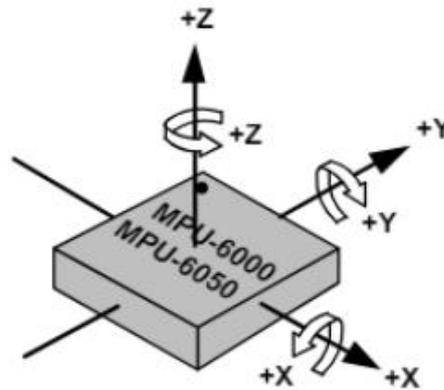
Figura 39: Sistema para coleta dos dados de vibração



Fonte: Autor.

O acelerômetro foi fixado na face superior do redutor utilizando uma fita isolante. Foram coletadas as medidas no eixo x, y e z, porém apenas as do eixo z foram analisadas. Na Figura 40 é possível observar as direções de medição do acelerômetro MPU6050.

Figura 40: Orientação dos eixos de sensibilidade e polaridade de rotação.



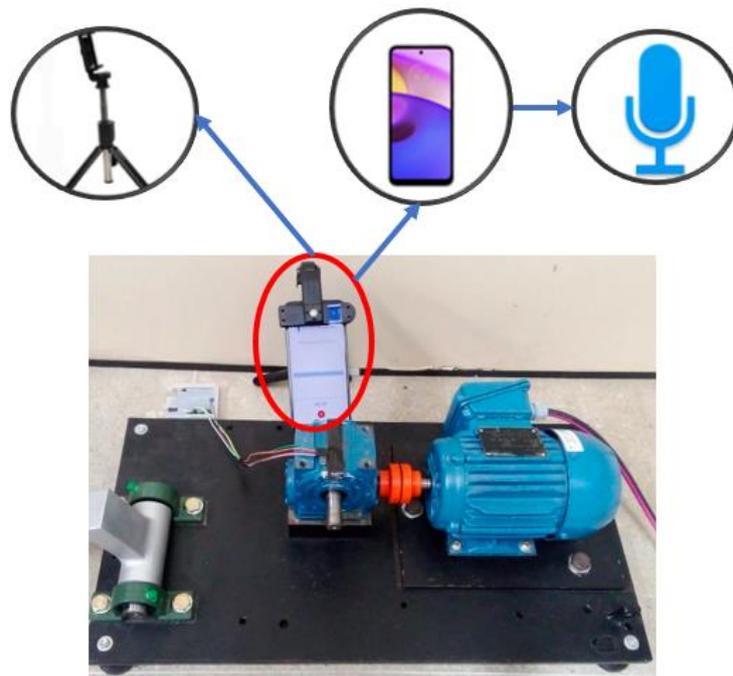
Fonte: InvenSense (2013).

4.4.2 Som

Para a gravação de áudio no experimento foi utilizado um dispositivo móvel modelo Motorola Moto E40. O aplicativo de gravação utilizado foi o “Gravador Fácil”, disponível na Play Store. A seguir, estão descritas as configurações dos principais parâmetros.

- **Ferramenta de gravação:** Celular Motorola Moto E40;
- **Taxa de amostragem:** A taxa de amostragem foi ajustada para 48 kHz;
- **Duração da gravação:** Para cada amostra, o tempo de gravação foi padronizada em 10 segundos;
- **Formato do áudio:** Os dados de áudio foram salvos no formato WAV (*Waveform Audio File Format*). A escolha por esse formato deve-se ao fato da capacidade de armazenar o áudio não comprimido, ou seja, não compactado, preservando a fidelidade do som, fazendo com que não haja perda de informações;
- **Filtro:** Cancelamento de eco (Padrão do aparelho);
- **Posicionamento do celular:** O celular foi posicionado no lado contrário ao eixo de saída do redutor;
- **Fixação do dispositivo:** O celular foi fixado em um suporte.

Figura 41: Instrumentação para coleta de som do funcionamento do redutor



Fonte: Autor.

Para cada condição de funcionamento foram gravados 300 áudios, totalizando 1200 áudios disponíveis para o estudo. O intervalo de resposta em frequência do microfone do celular que apresentou melhor resultado foi o de 250 Hz a 15 kHz.

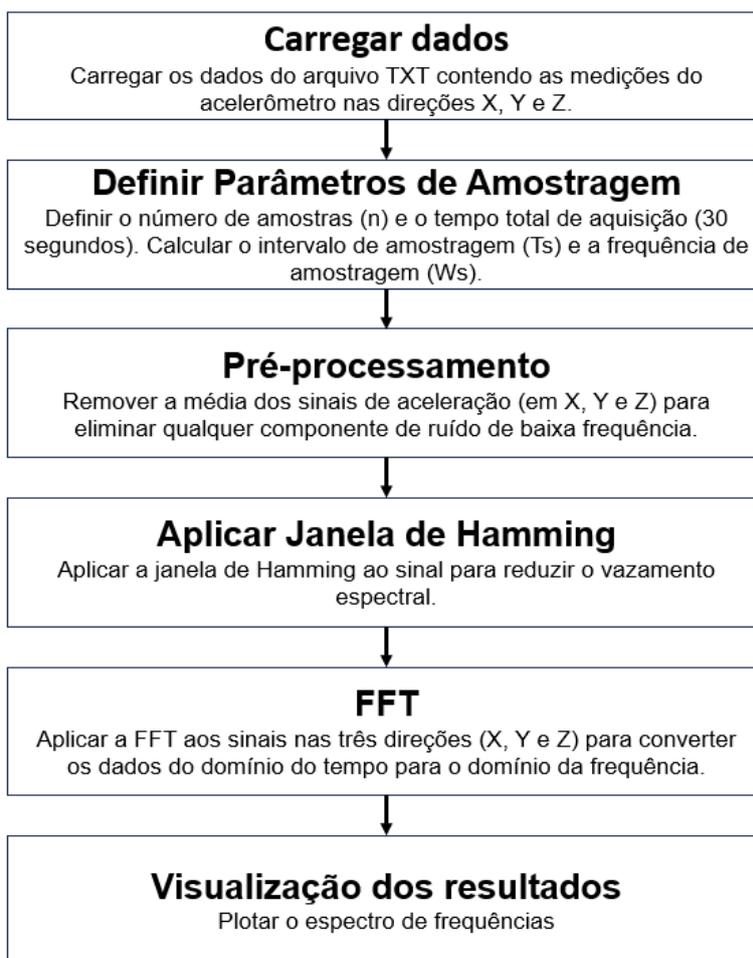
4.5 Processamento e análise dos dados

Nesta etapa, é abordada a metodologia utilizada para o processamento e a análise dos sinais de vibração e som.

4.5.1 Vibração

Para os dados coletado de vibração, nesse estudo, foi realizado um processamento e análise dos sinais no domínio da frequência através da Transformada Rápida de Fourier (FFT), possibilitando a identificação de componentes de frequência que indiquem falhas ou condições anômalas. Para esse processamento e análise de sinais, foi construído um script no MATLAB. O fluxo detalhado desse script, é apresentado na Figura 42. A análise de vibração, foi utilizada para verificar se as condições de funcionamento reproduzidas estavam em consonância com a literatura.

Figura 42: Fluxo do script para processamento e análise do sinal de vibração

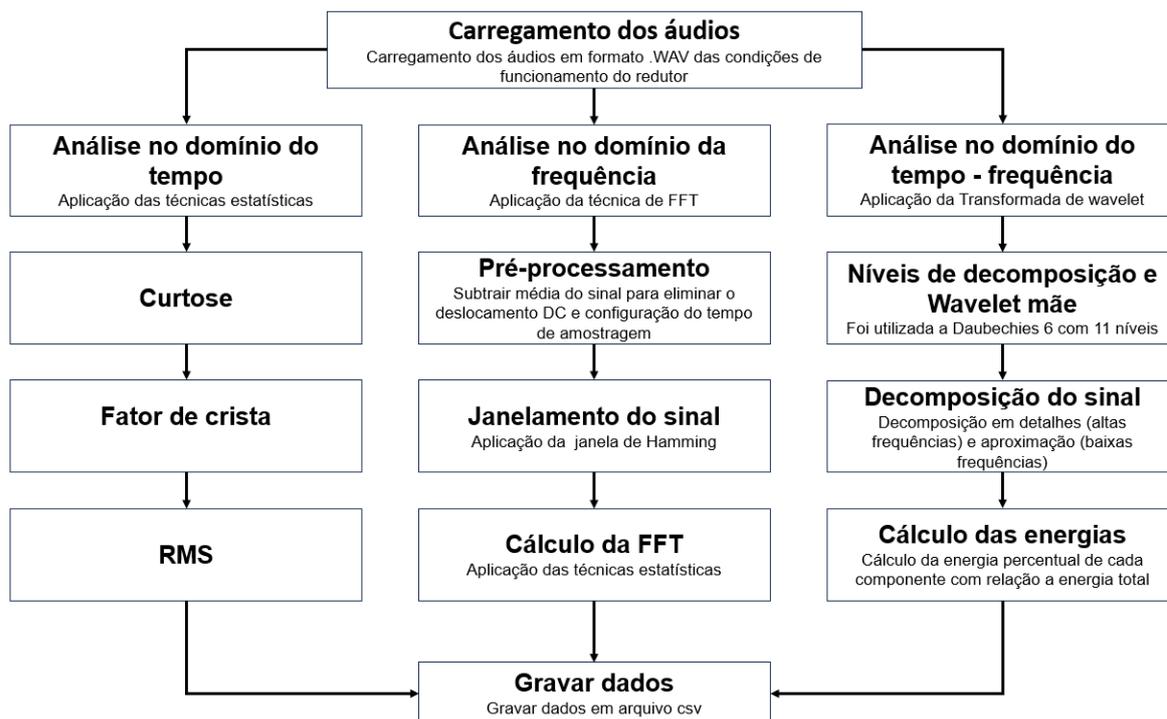


Fonte: Autor.

4.5.2 Som

Para os dados de som foram feitas análises no domínio do tempo, frequência e tempo-frequência. Foi desenvolvido um código em python, para a extração de informações relevantes para a identificação das condições de funcionamento do redutor e do seu nível de severidade. Para o domínio do tempo, foram empregadas técnicas estatísticas, através do uso módulo *scipy.stats*, incluindo curtose, fator de crista e RMS. No domínio da frequência, foi utilizada a Transformada rápida de Fourier (FFT). Já no domínio tempo-frequência, a transformada de Wavelet foi aplicada. A Figura 43, ilustra o fluxograma seguido para construção do código para processamento e análise dos sinais sonoros.

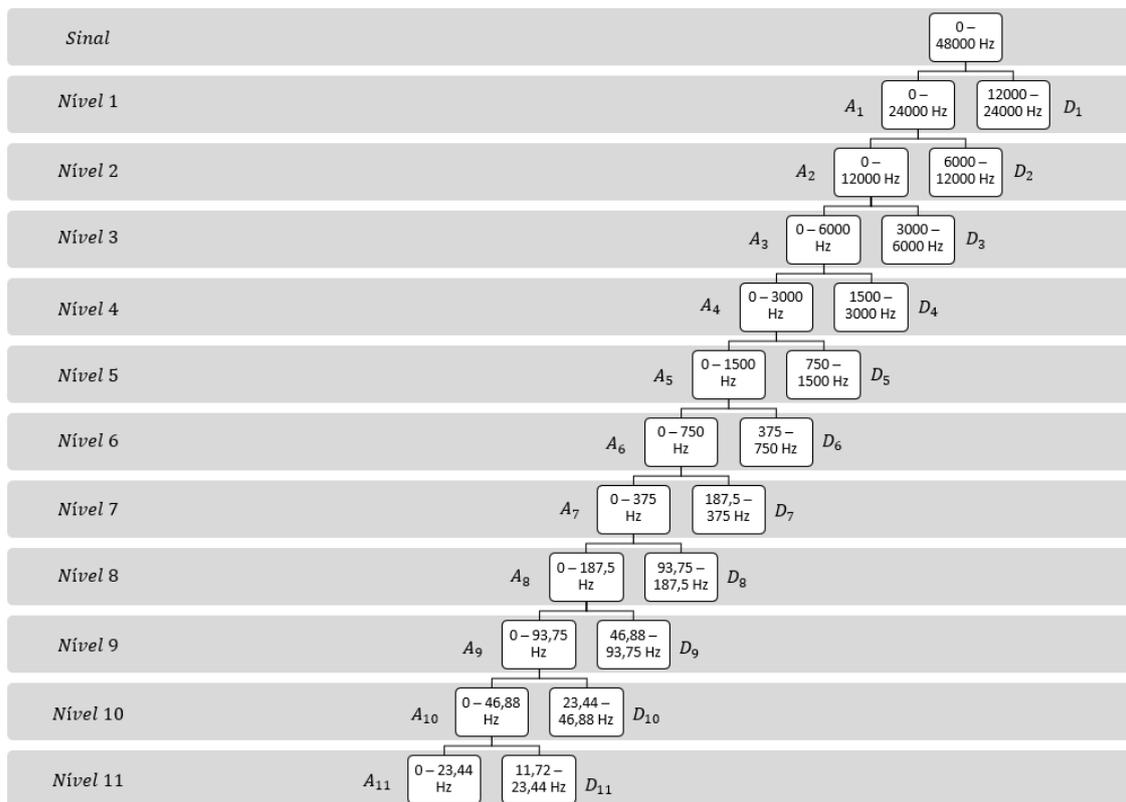
Figura 43: Fluxograma do processamento e análise de sinais para os sinais sonoros



Fonte: Autor.

A aplicação da Transformada Wavelet Discreta (DWT) ao sinal de áudio, utiliza a Wavelet mãe Daubechies 6. O número de níveis de decomposição escolhido foi 11. Em cada nível, o sinal é decomposto em dois componentes: Aproximação (A) e detalhe (D). A componente de detalhe representa frequências mais altas e a de aproximação frequências mais baixas. Para cada nível de decomposição Wavelet é calculado a energia percentual de cada componente (aproximação e detalhe) em relação à energia total do sinal sonoro. Isso possibilitar ter uma visão quantitativa da distribuição de energia ao longo das faixas de frequência. A Figura 44, mostra a árvore de decomposição da Wavelet do sinal sonoro.

Figura 44: Árvore de decomposição da wavelet do sinal sonoro em 11 níveis



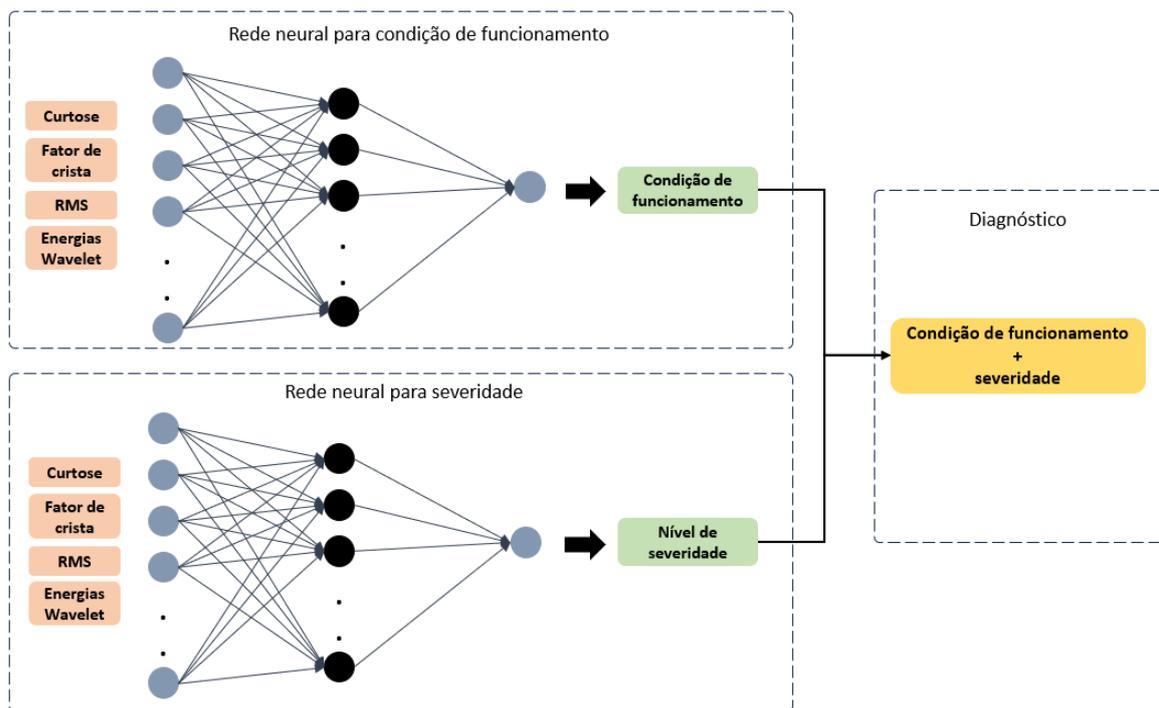
Fonte: Autor.

4.6 Desenvolvimento do sistema inteligente

Nesta etapa, foi desenvolvido um sistema de diagnóstico inteligente para avaliar as condições operacionais e os níveis de severidade do redutor coroa sem fim. O sistema é composto por duas redes neurais artificiais: A primeira é utilizada para classificar as condições de funcionamento do redutor, que podem se estado de referência, desalinhamento angular, sobrecarga e lubrificação ineficiente. A segunda rede neural, classifica os níveis de severidade, os quais são definidos em leve, médio e grave.

A combinação das saídas dessas redes neurais, resulta em um diagnóstico completo do redutor, permitindo definir a estratégia de manutenção mais adequada, de forma a potencializar a confiabilidade do equipamento. Na Figura 45, é apresentado a configuração do sistema citado. Nos tópicos posteriores, será realizado o detalhamento de cada uma das RNAs.

Figura 45: Configuração do sistema de diagnóstico inteligente



Fonte: Autor.

Para o desenvolvimento das redes neurais, os passos abaixo foram seguidos:

1. Carregamento e pré-processamento dos dados:

- a. Carregamento dos dados: Os dados foram carregados a partir de um arquivo CSV contendo as características (*features*) e os rótulos (*labels*). Esse arquivo foi gerado por meio de um código em Python, que se conecta a uma base de dados de áudios armazenados na nuvem. O código é responsável por extrair as características definidas dos áudios e salvá-las de forma estruturada no arquivo CSV;
- b. Separação de *features*: Remoção de colunas que não serão utilizadas para a entrada das redes neurais e separação das *features* dos rótulos;
- c. Dividir os dados em conjunto de treinamento e teste;
- d. Normalizar os dados.

2. Definição da arquitetura da rede neural

- a. Escolha do modelo: Definição do modelo de rede neural, que para ambas as redes neurais desse estudo foi a Perceptron multicamadas. A escolha por esse modelo de RNA é justificada por sua capacidade de modelar padrões

não lineares, seu desempenho em aprendizado supervisionado e sua flexibilidade e simplicidade para lidar com dados complexos como os sinais de áudio;

- b. Camadas das redes: Determinar número de camadas e de neurônios por camada;
- c. Otimizador: Escolha do algoritmo de otimização.

3. Treinamento da rede neural

- a. Configuração dos hiperparâmetros como número de épocas e taxa de aprendizado;
- b. Treinamento incremental: Para cada época o treinamento foi realizado de maneira incremental, utilizando o método *partial_fit*.

4. Avaliação de desempenho e validação

- a. Análise de desempenho através das métricas: acurácia, precisão, *recall*, *f1-score* e matriz de confusão;
- b. Validação da rede neural: Utilização da validação cruzada *k-fold*.

4.6.1 Rede neural para classificação de condição de funcionamento

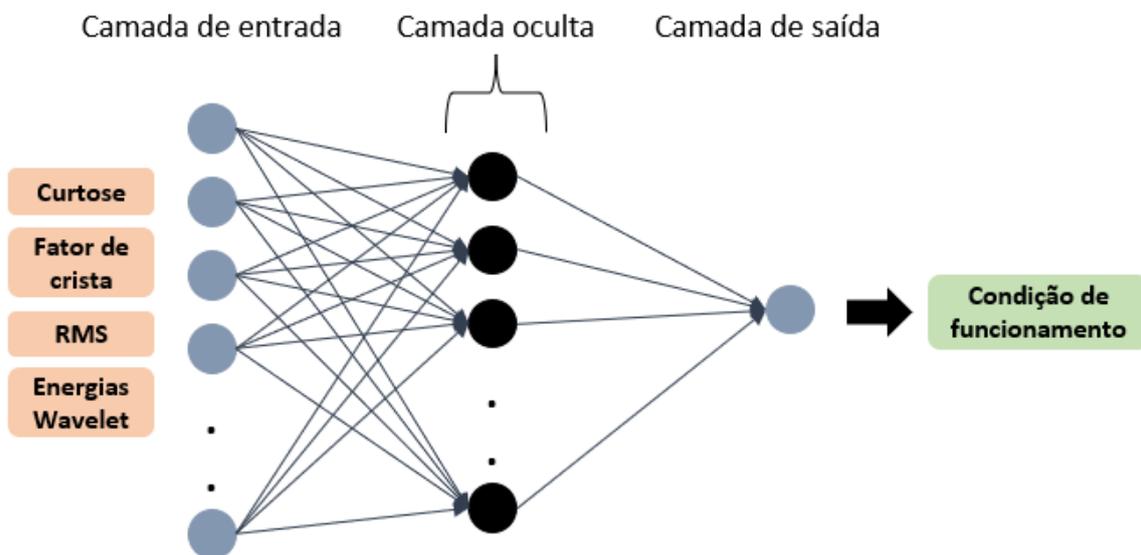
A rede neural artificial utilizada para o problema de classificação da condição de funcionamento foi a do tipo (*MLP - Multilayer Perceptron*), um modelo de rede neural *feedforward*. A arquitetura da RNA se apresenta da seguinte forma:

- **Camada de entrada:** A quantidade de neurônios nesta camada é igual ao número de *features* utilizado. Para este caso temos 9 entradas, que são curtose, RMS, fator de crista e 6 valores de energia Wavelet referentes aos principais detalhes que são: 5, 6, 7, 8, 9 e 10;
- **Camadas ocultas:** Nesse modelo, há uma camada oculta com 15 neurônios. A função de ativação utilizada na camada oculta foi a ReLU;
- **Camada de saída:** A quantidade de neurônios da camada de saída é igual ao número de classes de condições de funcionamento, que são 4: Estado de referência, desalinhamento angular, sobrecarga e lubrificação ineficiente. A função de ativação utilizada nesta camada foi a *softmax*.

O algoritmo de otimização selecionado foi o Adam e a taxa de aprendizado definida foi de 0,01. Essa taxa de aprendizado controla a velocidade com que o modelo ajusta os pesos. A regularização L2 foi aplicada com $\alpha = 0,001$, para evitar o overfitting. Para cada classe foram gravados 300 áudios, onde 70% desse conjunto formou o subconjunto de treinamento e os outros 30% o de teste. O processo de treinamento foi realizado em 14 épocas.

O processo de validação do modelo foi realizado através da técnica de validação cruzada *k-fold* com 6 *folds*. Para essa rede foram utilizadas as métricas de desempenho: Matriz de confusão, acurácia, *recall*, precisão e *f1-score*.

Figura 46: Rede neural para classificação da condição de funcionamento



Fonte: Autor

4.6.2 Rede neural para classificação de severidade

A rede neural artificial utilizada para o problema de classificação do nível de severidade foi a do tipo (*MLP - Multilayer Perceptron*), um modelo de rede neural *feedforward*. A arquitetura da RNA se apresenta da seguinte forma:

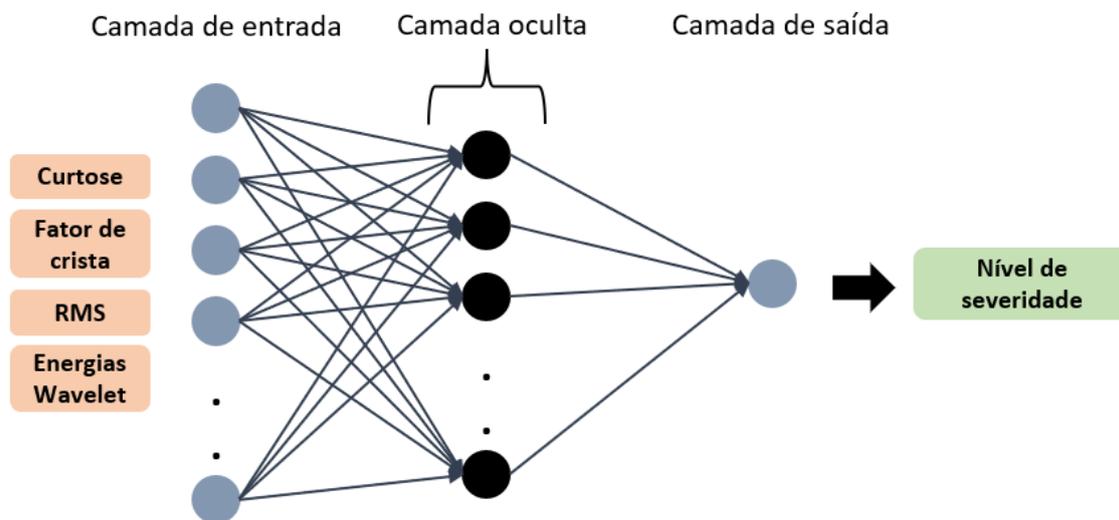
- **Camada de entrada:** A quantidade de neurônios nesta camada é igual ao número de *features* utilizado. Para este caso temos 9 entradas, que são curtose, RMS, fator de crista e 6 valores de energia Wavelet referentes aos principais detalhes que são: 5, 6, 7, 8, 9 e 10;

- **Camadas ocultas:** Nesse modelo, há uma camada oculta com 15 neurônios. A função de ativação utilizada na camada oculta foi a ReLU;
- **Camada de saída:** A quantidade de neurônios da camada de saída é igual ao número de classes do nível de severidade, que são 3: Leve, médio e grave. A função de ativação utilizada nesta camada foi a *softmax*.

O algoritmo de otimização selecionado foi o Adam e a taxa de aprendizado definida foi de 0,01. Essa taxa de aprendizado controla a velocidade com que o modelo ajusta os pesos. A regularização L2 foi aplicada com $\alpha = 0,001$, para evitar o overfitting. O processo de treinamento foi realizado em 22 épocas.

O processo de validação do modelo foi realizado através da técnica de validação cruzada *k-fold* com 6 *folds*. Para essa rede foram utilizadas as métricas de desempenho: Matriz de confusão, acurácia, *recall*, precisão e *f1-score*.

Figura 47: Rede neural para classificação do nível de severidade.



Fonte: Autor.

Os níveis de severidade foram definidos com base no trabalho de Oliveira Neto (2023). Embora a norma ISO 20816-9:2020, defina níveis de severidade para redutores de engrenagem, ela limita a aplicação dos valores estipulados para redutores com potência nominal de 10 kW à 100 kW com velocidade de 0,5 Hz a 200 Hz, logo não se enquadra para o redutor utilizado. A norma da FUPAI, sugere níveis de severidade baseados em valores de RMS, enquanto neste trabalho a medida utilizada para os espectros de vibração é aceleração. A partir do gráfico de severidade de vibração para redutores, fornecido pela

FUPAI, é possível extrair uma informação importante, que é o aumento nas amplitudes de vibração entre 80 Hz e 800 Hz. Devido à falta de normas específicas ao sistema estudado, a determinação dessas classes de severidade se baseou na inspeção visual do comportamento da máquina e ao estudo dos espectros de vibração (OLIVEIRA NETO, 2023).

5 RESULTADOS

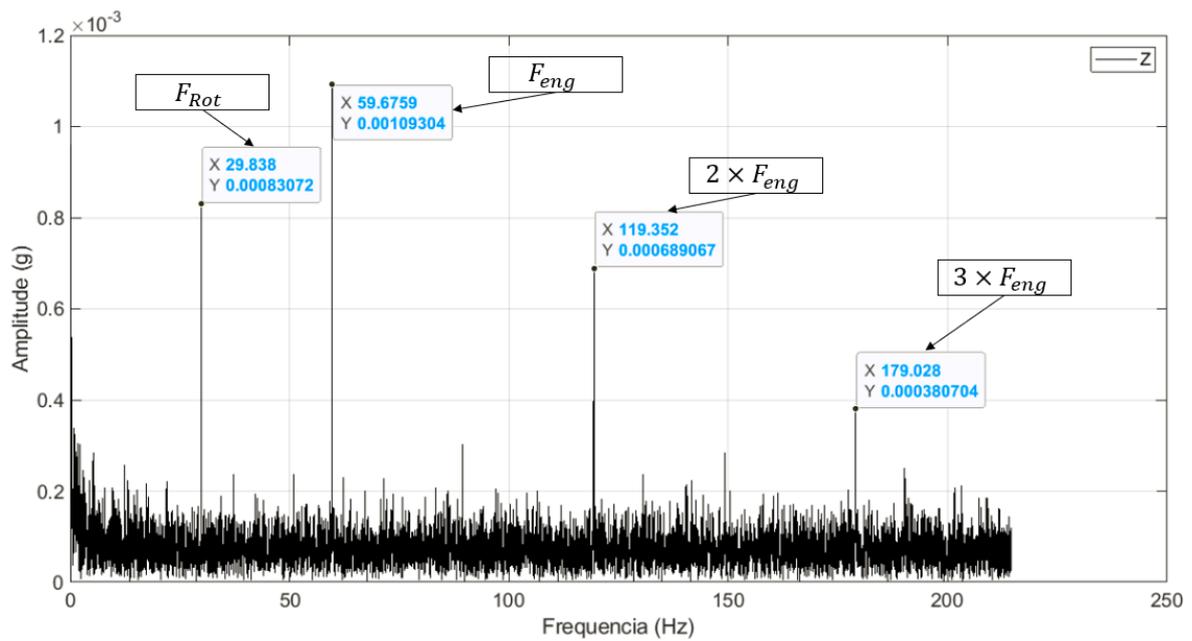
Nesta seção, são apresentados os resultados experimentais para cada uma das condições operacionais avaliadas. A estrutura está organizada em subtópicos, dedicados a cada condição de funcionamento, abrangendo as análises nos domínios do tempo, frequência e tempo-frequência. Para cada condição, as análises no domínio do tempo, utilizou-se as métricas estatísticas de curtose, RMS e fator de crista. No domínio da frequência, será avaliado o espectro de vibração, identificando componentes fundamentais e harmônicos. As análises no domínio tempo-frequência, por sua vez, utilizarão as transformadas de Wavelet para capturar as variações de energia nos detalhes.

Além disso, é incluída uma seção de comparação global entre todas as condições, com o objetivo de realizar uma análise integrada dos resultados e avaliação das tendências observadas. As duas últimas seções são destinadas à avaliação do desempenho da rede neural para classificação e identificação da condição de funcionamento e da severidade. Essa abordagem multidimensional, utilizada nesse trabalho, busca não apenas validar os métodos utilizados, mas também contribuir para o entendimento das interações entre as variáveis analisadas.

5.1 Análise de vibração e som para condição de referência

Na Figura 48, é apresentado o espectro de frequência obtido através da análise de vibração para a condição de referência, correspondente ao bom estado da bancada experimental. Observa-se a frequência de rotação do motor, que é de 29,8 Hz, bem como a frequência de engrenamento, com valor aproximado de 59,6 Hz, sendo ela a de maior amplitude no espectro. Além da frequência de engrenamento, é observado os seus múltiplos harmônicos. As amplitudes dos harmônicos subsequentes, como o segundo ($2 \times F_{eng}$) e o terceiro ($3 \times F_{eng}$), diminuem gradualmente. Esse padrão de declínio progressivo nas amplitudes dos harmônicos é característico de redutores em bom estado de funcionamento. Além disso, não foram observadas bandas laterais, reforçando a condição de operação saudável do sistema. Esse comportamento está em consonância com o exposto na literatura, conforme apresentado na Tabela 4.

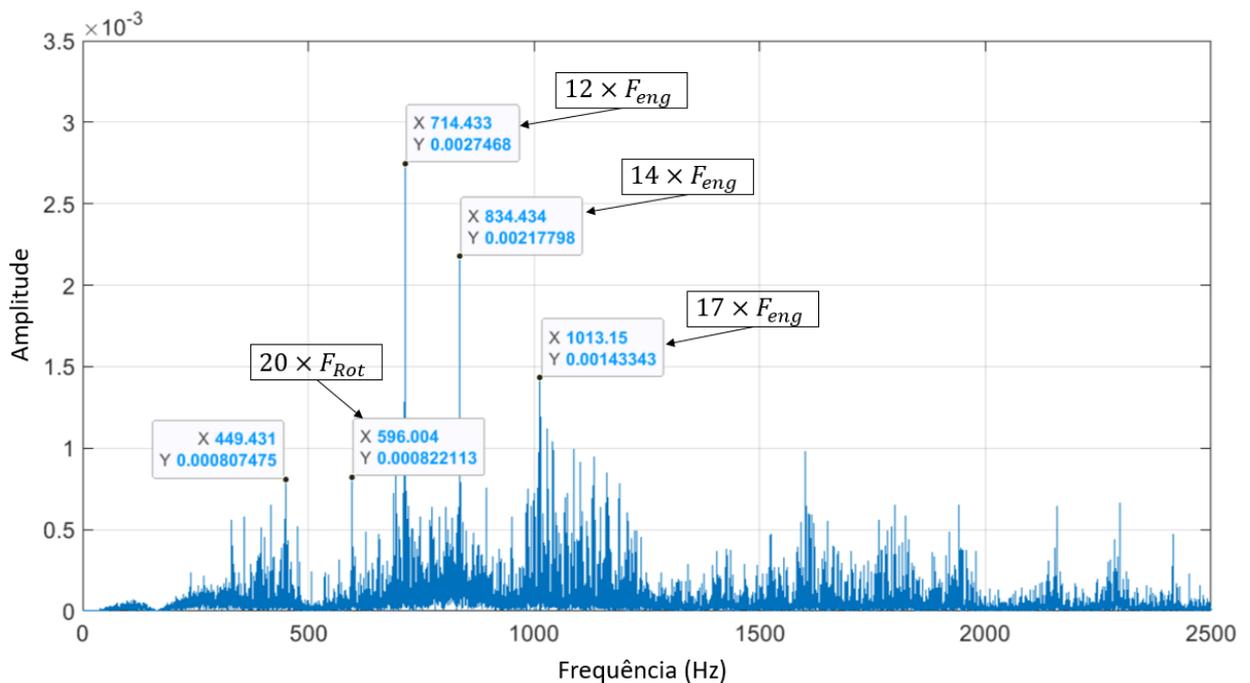
Figura 48: Espectro de frequência da análise de vibração para o estado de referência



Fonte: Autor

Após a análise de vibração, prosseguiu-se com a análise sonora. Para os sinais de áudio adquiridos na condição de referência, foi construído o espectro de frequência correspondente, representado na Figura 49. Nele, não foi possível identificar diretamente as frequências de rotação e de engrenamento, devido a resposta em frequência do microfone do celular, sendo visíveis apenas suas harmônicas. A partir da Figura 49, consegue-se observar essas harmônicas, destacando a presença de componentes como a 20x frequência de rotação e 12x, 14x e 17x a frequência de engrenamento. Esse padrão é característico para a condição de referência, como já mencionado, onde a harmônica de 12x a frequência de engrenamento apresenta maior amplitude, seguida das demais harmônicas.

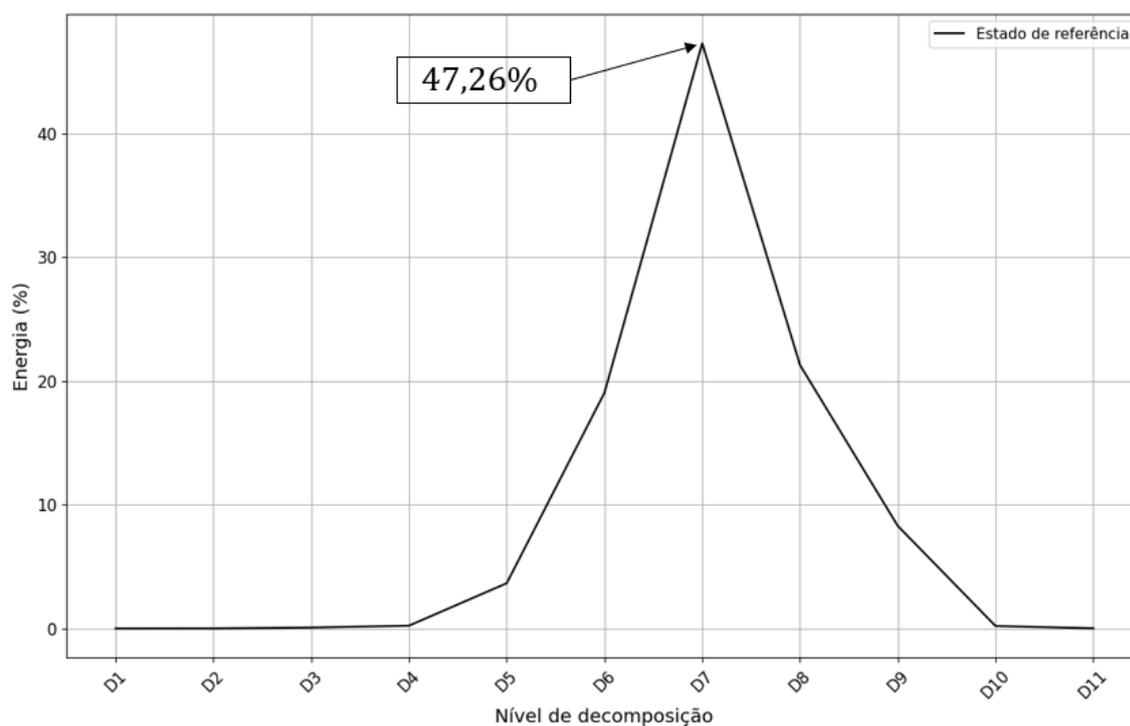
Figura 49: Espectro de frequência da análise de som para o estado de referência



Fonte: Autor

Além da análise do domínio da frequência foi feita análise no domínio tempo-frequência, onde foi construído espectrograma de energia da Wavelet. Na Figura 50, é apresentado o gráfico de energia dos detalhes da Wavelet para a condição de referência. Observa-se que 47,26% da energia está concentrada no detalhe 7 (187,5 – 375 Hz). Esse espectrograma de energia Wavelet para condição de referência, será utilizado para comparação com as demais condições de funcionamento, com o objetivo de avaliar o comportamento evolutivo da energia de acordo os cenários reproduzidos.

Figura 50: Energia dos detalhes da Wavelet para condição de referência



Fonte: Autor

Além das análises no domínio da frequência e tempo-frequência, foi realizada também uma análise no domínio do tempo, utilizando as seguintes técnicas estatísticas: curtose, RMS e fator de crista. A Tabela 8, apresenta os resultados para a condição de referência.

Tabela 8: Curtose, RMS e fator de crista para condição de referência

Curtose	RMS	Fator de crista
1,1893	0,0335	6,4355

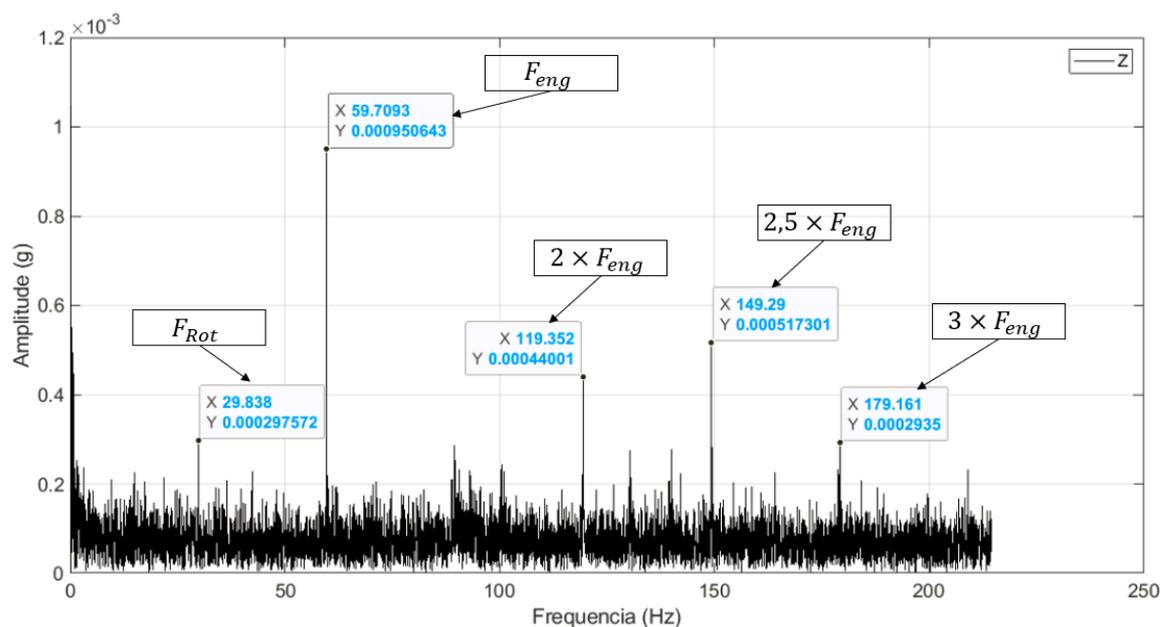
Fonte: Autor

Nas seções posteriores, onde serão apresentados os resultados para as más condições de funcionamento, os valores obtidos através das técnicas estatísticas, serão analisados graficamente com a condição de referência

5.2 Análise de vibração e som para condição de desalinhamento angular

Na Figura 51, é mostrado o espectro de frequência da análise de vibração para a condição de desalinhamento angular de 1° . Observa-se que as frequências de rotação e de engrenamento mantiveram-se praticamente inalteradas quando comparadas à condição de referência. No entanto, há o surgimento da frequência de 149,29 Hz ($2,5 \times F_{eng}$) com amplitude de 0,0005g aproximadamente.

Figura 51: Espectro de frequência da análise de vibração para desalinhamento angular de 1°

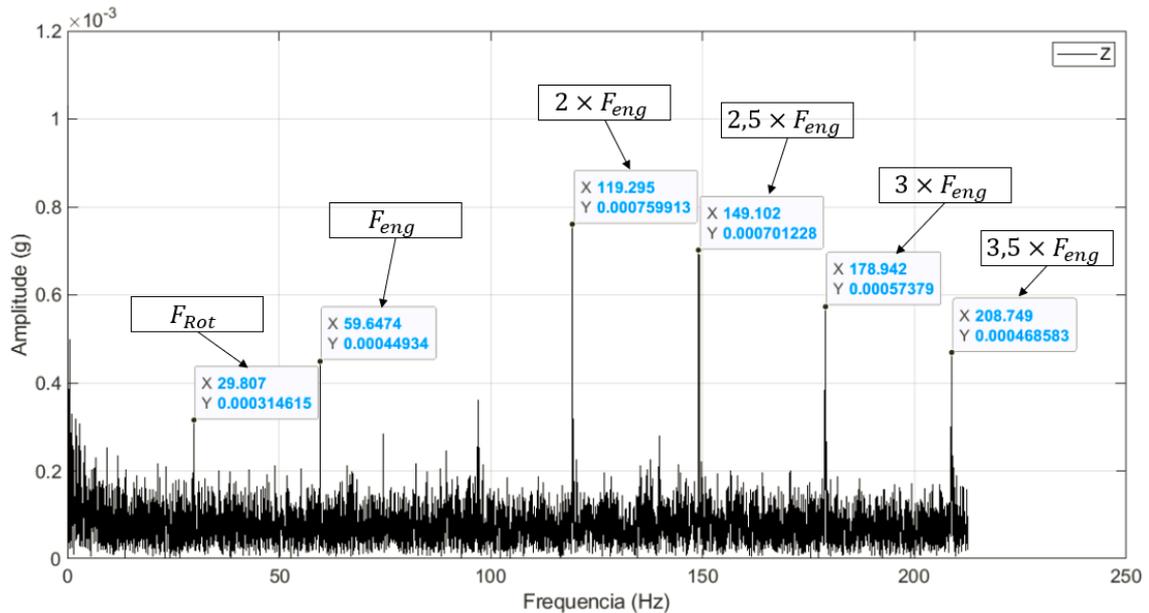


Fonte: Autor

Na Figura 52, nota-se o espectro de frequência obtido através da análise de vibração para a condição de desalinhamento angular de $1,5^\circ$. É possível observar que a frequência de rotação de 29,8 Hz apresenta uma amplitude reduzida de 0,00031g, em comparação com 0,00083 no estado de referência. A frequência de engrenamento de 59,6 Hz mostra diminuição mínima de amplitude, de 0,00109 g na condição de referência para 0,0009g na condição de desalinhamento angular de $1,5^\circ$. Por outro lado, harmônicos, como 119,3 Hz ($2 \times F_{eng}$) e 179,16 Hz ($3 \times F_{eng}$), aumentam suas amplitudes, atingindo 0,00076g e 0,00057g, respectivamente. No espectro de frequência, verifica-se também o surgimento das frequências 149,1 Hz ($2,5 \times F_{eng}$) e 208,7 Hz ($3,5 \times F_{eng}$), com amplitudes de 0,0007

g e 0,00047 g, respectivamente. Esse comportamento indica que a condição de desalinhamento redistribui a energia vibracional para frequências harmônicas.

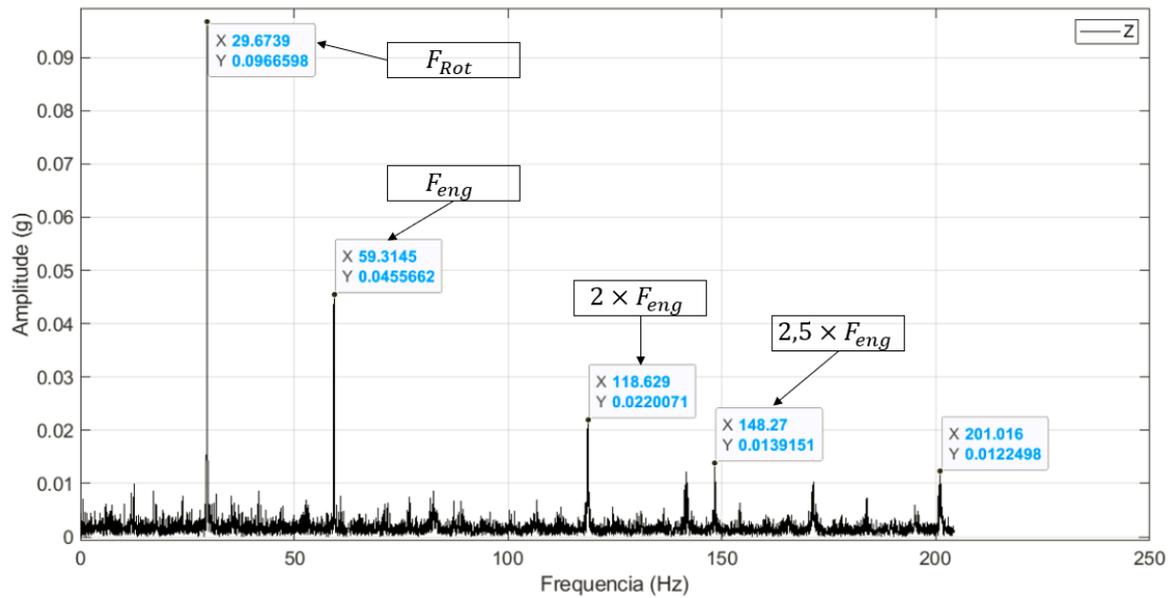
Figura 52: Espectro de frequência da análise de vibração para desalinhamento angular de $1,5^\circ$



Fonte: Autor

Na Figura 53, é apresentado o espectro de frequência correspondente a condição de desalinhamento mais severo, que apresenta um ângulo de desalinhamento de 2° . Ao comparar com a condição de referência, torna-se claro o aumento significativo na amplitude de vibração da frequência de rotação, engrenamento e nas harmônicas dessa última. A frequência de rotação para este caso é a mais proeminente. Esse comportamento está em consonância com o exposto na literatura, onde Mauro Sá (2000) destaca que o desalinhamento angular se manifesta por uma vibração axial elevada, que ocorre 180° fora de fase através do acoplamento. Sendo normalmente, observado que a vibração axial apresenta maior intensidade na frequência de rotação e na sua segunda harmônica.

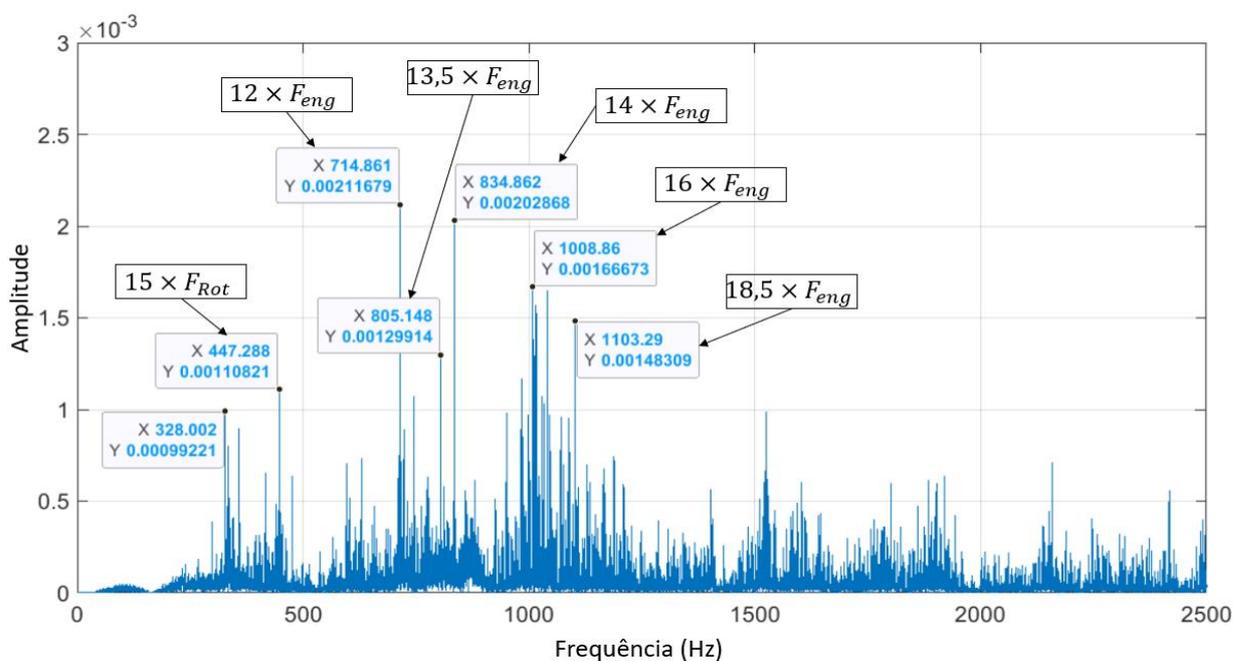
Figura 53: Espectro de frequência da análise de vibração para desalinhamento angular de 2°



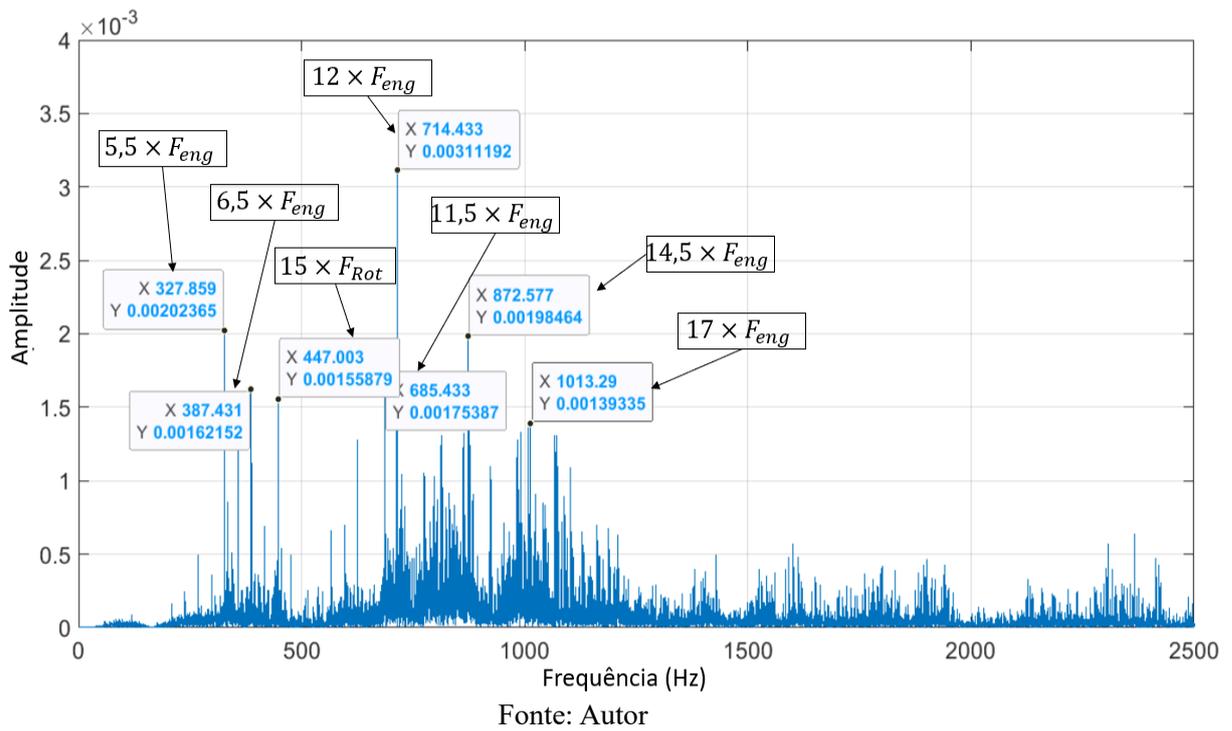
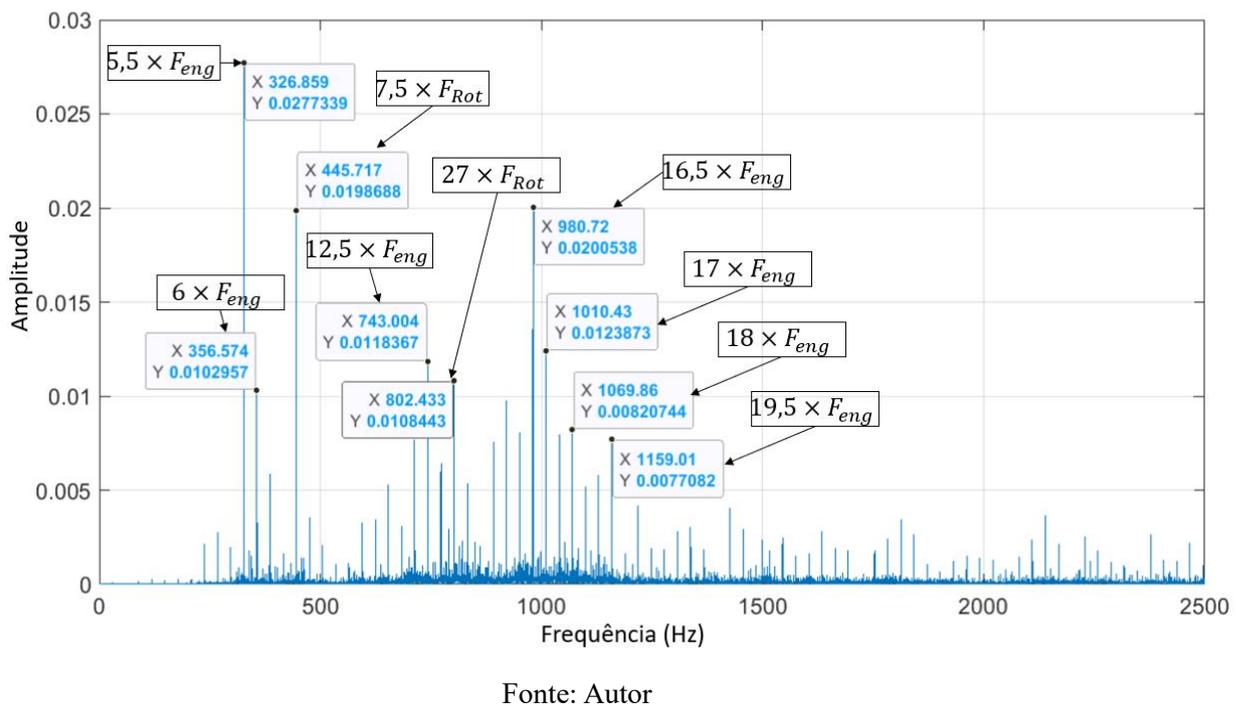
Fonte: Autor

Após a análise de vibração, foi realizado a análise sonora. As Figuras 54, 55 e 56, apresentam, respectivamente, os espectros de frequência para as condições de desalinhamento angular de 1° , $1,5^\circ$ e 2° , respectivamente. A partir da análise desses gráficos, nota-se um aumento significativo nas amplitudes de vibração das harmônicas da frequência de engrenamento, bem como modulação em amplitude.

Figura 54: Espectro de frequência da análise de som para desalinhamento de 1°



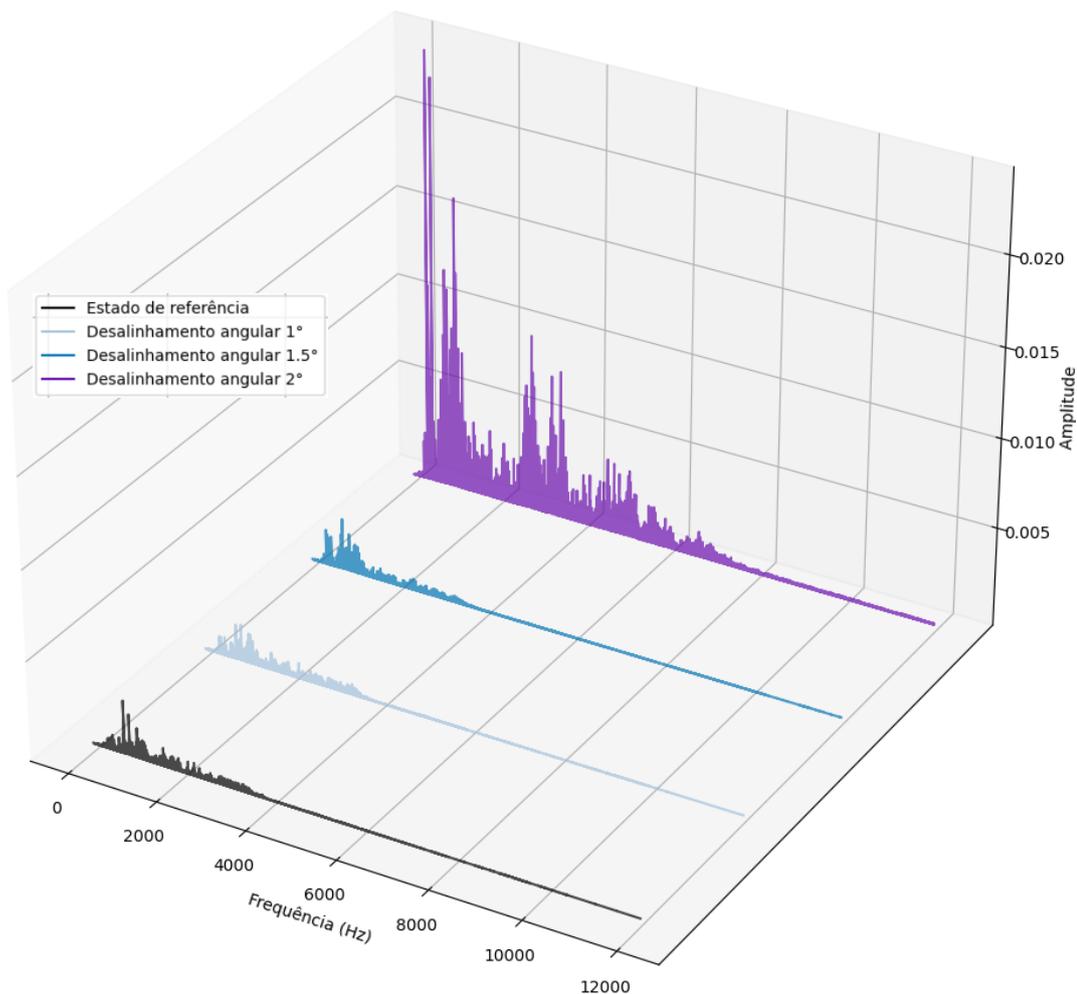
Fonte: Autor

Figura 55: Espectro de frequência da análise de som para desalinhamento de $1,5^\circ$ Figura 56: Espectro de frequência da análise de som para desalinhamento de 2° 

A Figura 57, apresenta os espectros de frequência em 3D para os três níveis de desalinhamento angular, comparados à condição de referência. Essa visualização permite

analisar as variações e evolução da energia vibracional à medida que a severidade do desalinhamento angular aumenta.

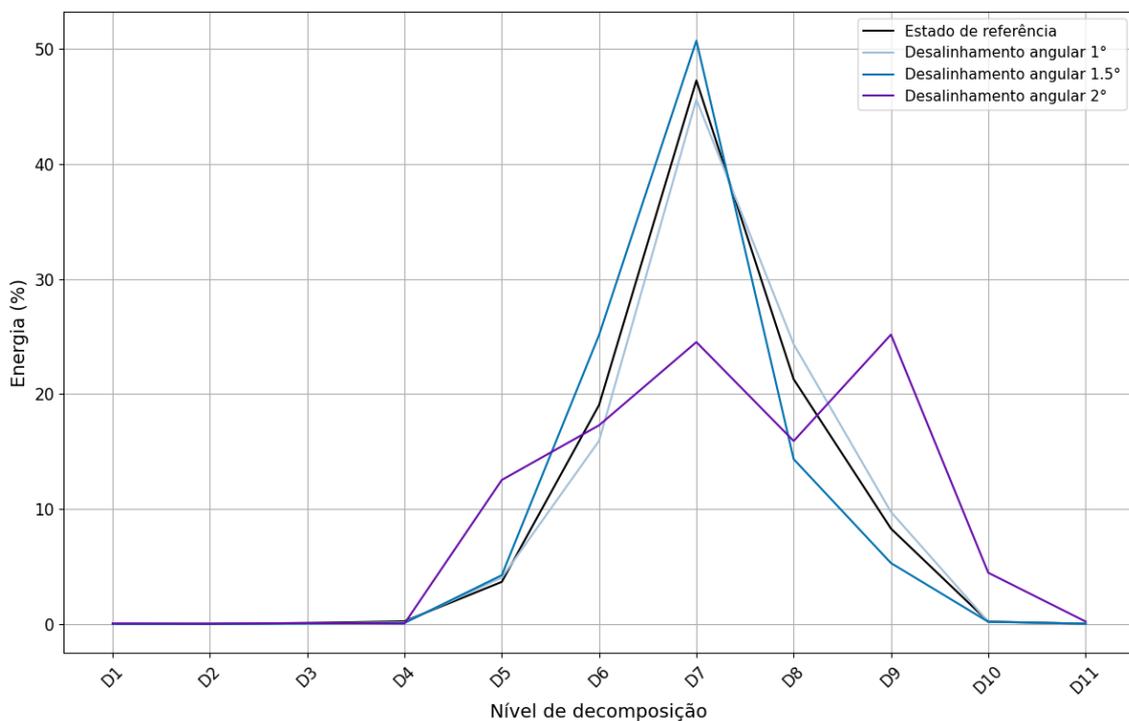
Figura 57: Espectro de frequência 3D para análise sonora do desalinhamento angular



Para a análise no domínio tempo-frequência dos níveis de desalinhamento angular, foi construído o gráfico de energia dos detalhes da Wavelet, representado na Figura 58. A partir do gráfico de energia dos detalhes, observa-se que para a condição de desalinhamento angular de 1° não houve grandes variações do percentual de energia nos seus detalhes, permanecendo com comportamento praticamente idêntico a condição de referência. Esse resultado se deve à propriedade compensatória do acoplamento, que é capaz de suportar desalinhamentos angulares de até $1,5^\circ$. Já para o desalinhamento de $1,5^\circ$, houve um aumento no percentual de energia no detalhe 6 (375 – 750 Hz), passando de 19,04% na condição de referência para 25,13%, e no 7 (187,5 – 375 Hz), saindo de

47,26% na condição de referência para 50,73%. Para a condição de desalinhamento angular de 2° , observa-se que os altos percentuais de energia estão presentes em vários detalhes da análise Wavelet. Os coeficientes de energia, em especial nas faixas de detalhe 5 a 9, mostram percentuais de energia que variam de aproximadamente 12% a 25%, sendo os detalhes 7 e 9 os que apresentam maiores contribuições, alcançando valores próximos de 25%. Esse comportamento descrito, traduz a informação de que desalinhamentos mais leves, como os de 1° e $1,5^\circ$, possuem uma distribuição de energia mais concentrada em detalhes específicos, que neste caso são o 6 e 7, indicando uma operação relativamente mais estável quando comparada ao desalinhamento de 2° , onde a energia está distribuída amplamente em vários detalhes, com altos percentuais. Essa distribuição ampla indica uma resposta vibracional de maior intensidade, resultante dos impactos entre os dentes das engrenagens, levando a aumento nas energias de vibração e no surgimento de harmônicas. No desalinhamento angular de 2° , a energia no detalhe 5 aumentou de aproximadamente 3,5% para 12,5%, no detalhe 9 subiu de 8,3% para 25% e no detalhe 10 foi de aproximadamente 0% para 4,5%. Os desalinhamentos de 1° e $1,5^\circ$ nos detalhes 5 e 10 não apresentaram diferenças significativas com relação ao estado de referência.

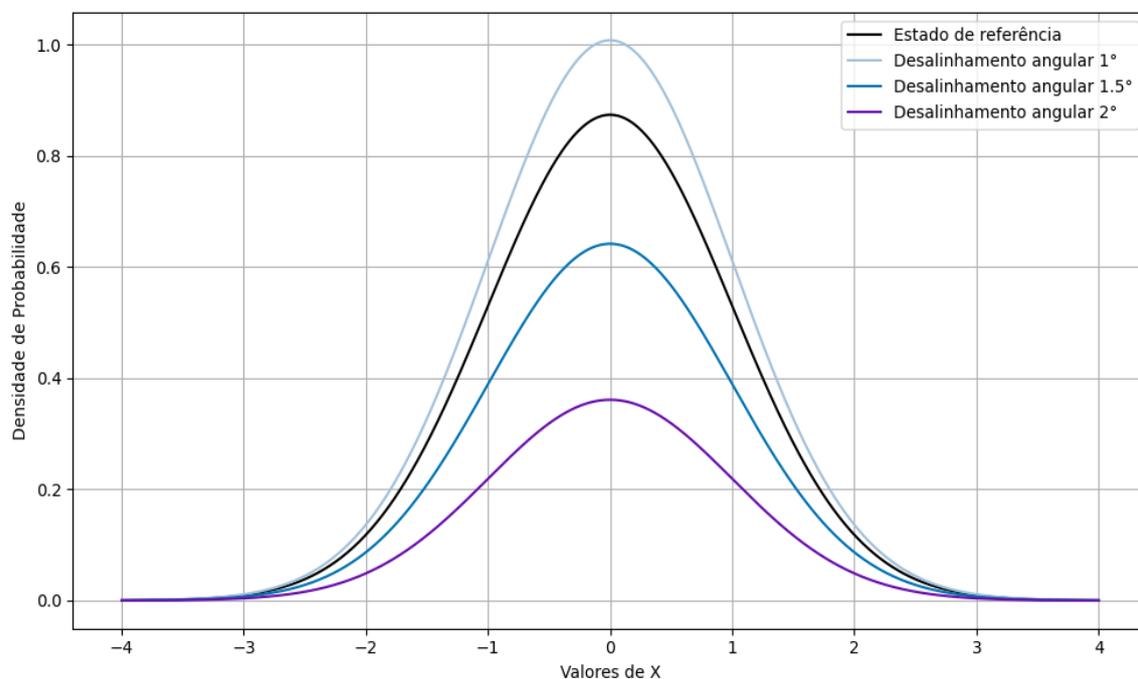
Figura 58: Energia dos detalhes da Wavelet para desalinhamento angular



Fonte: Autor.

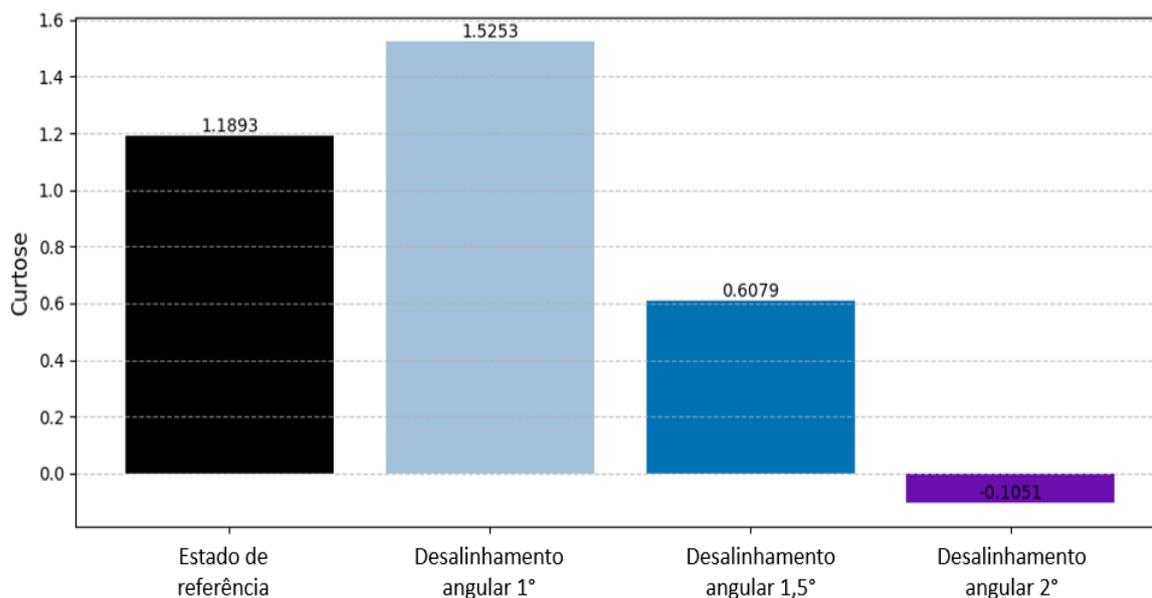
Avaliou-se também o comportamento vibracional, perante a presença da condição de desalinhamento angular, através das métricas estatísticas. As Figuras 59 e 60, apresentam os resultados de curtose obtidos para esse estado de operação. Observando os valores de curtose na Figura 60, nota-se que para o estado de referência, desalinhamento angular de 1° e $1,5^\circ$, tem-se uma distribuição leptocúrtica, já que $K > 0$ e para o desalinhamento angular de 2° uma distribuição platicúrtica, tendo em vista que $K < 0$. Nota-se que a curtose tende a diminuir com o aumento do ângulo de desalinhamento, causando achatamento da curva, conforme mostrado na Figura 59. De acordo com Oliveira Neto (2023), o aumento da severidade do desalinhamento, ocasiona a redução da curtose devido ao fato de haver uma distribuição mais uniforme da energia ao longo do espectro de frequências. Khan et al (2019), também observou que a curtose tende a diminuir com o aumento do desalinhamento, tornando a distribuição mais achata, pois, ao elevar o nível de desalinhamento, o número de pontos de contato entre as superfícies das engrenagens diminui, reduzindo a intensidade de engrenamento e, portanto, a curtose. Para casos severos, como o desalinhamento de 2° , a energia é mais distribuída no espectro.

Figura 59: Curvas de curtose para desalinhamento angular



Fonte: Autor.

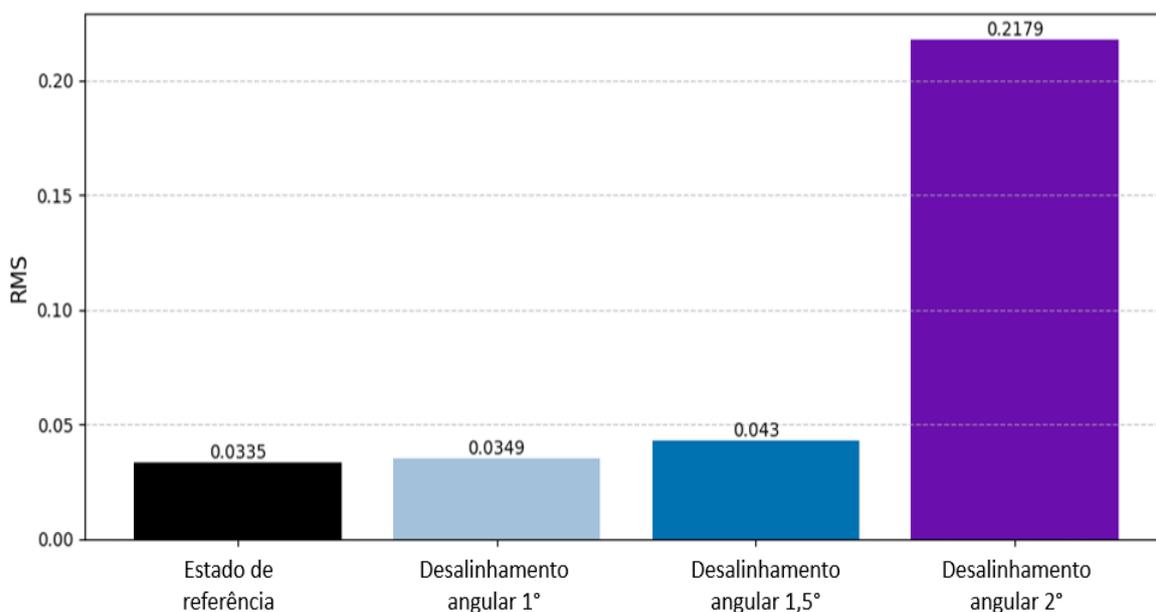
Figura 60: Valores de curtose para desalinhamento angular



Fonte: Autor.

Ao analisar o RMS para os diferentes níveis de desalinhamento, nota-se que há uma intensificação nesse valor à medida que o ângulo de desalinhamento aumenta. Segundo Khan et al (2019), o desalinhamento angular proporciona um maior contato nas bordas dos dentes da engrenagem ao longo da largura da face. Esse aumento nas áreas de contato nas bordas gera um efeito de vibração mais intenso, devido aos impactos constantes nessas regiões, o que contribui para um desgaste acelerado e até lasqueamento das extremidades dos dentes. Essa condição também impõe cargas adicionais sobre os rolamentos e aumenta a energia vibracional refletida no RMS do sinal. Além disso, o RMS da frequência de rotação e de engrenamento aumentam, pois a vibração é intensificada pela intensidade dos choques das bordas.

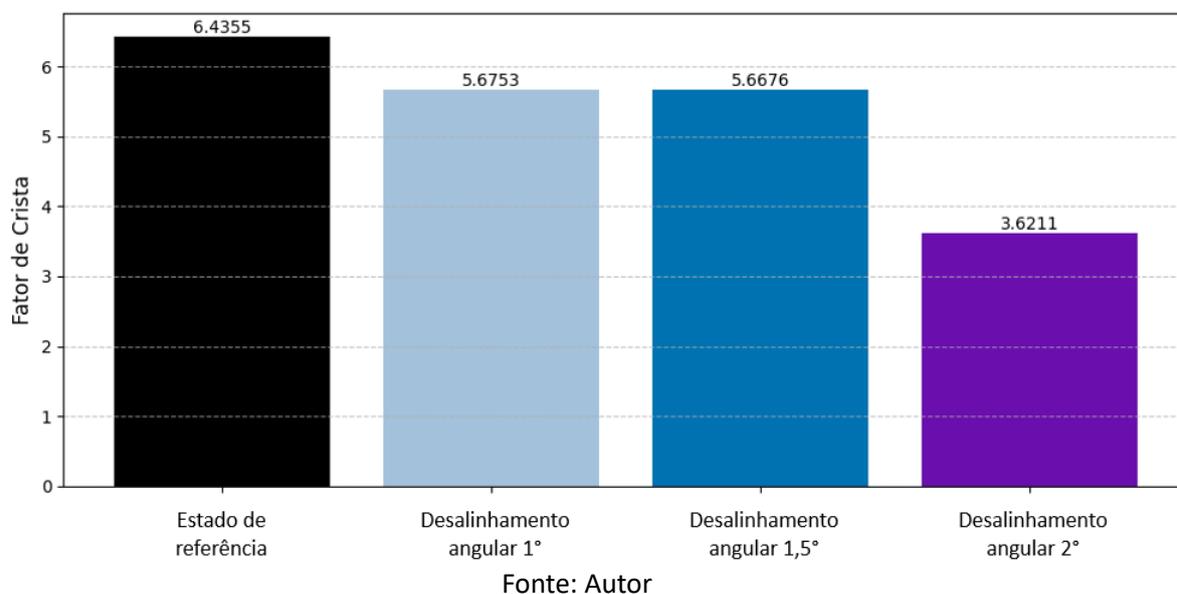
Figura 61: Valores de RMS para desalinhamento angular



Fonte: Autor.

Ao analisar o fator de crista, nota-se uma redução em seus valores, de acordo com o aumento do nível de severidade do desalinhamento. Isso ocorre pois o fator de crista mede a relação entre o pico de amplitude e o valor de RMS. O aumento da severidade do desalinhamento introduz um comportamento vibracional mais uniforme, ou seja, há uma redução dos picos momentâneos, resultando em um sinal de amplitude mais constante. Nos desalinhamentos leves, como o de 1° e 1,5°, ocorrem picos mais irregulares, pois as forças de impacto não se distribuem de forma consistente, gerando valores de pico elevados em relação ao RMS do sinal. No desalinhamento severo, caso do de 2°, essas forças se tornam mais distribuídas, reduzindo os picos e deixando o sinal mais estável. Outro fator que interfere diretamente para o comportamento de redução do fator de crista com o aumento da severidade, deve-se ao fato de que quanto mais intenso for o desalinhamento, maior será o valor de RMS, enquanto o valor de pico não aumenta de maneira proporcional, fazendo com que a relação entre o valor máximo e o RMS, diminua.

Figura 62: Valores de Fator de crista para desalinhamento angular



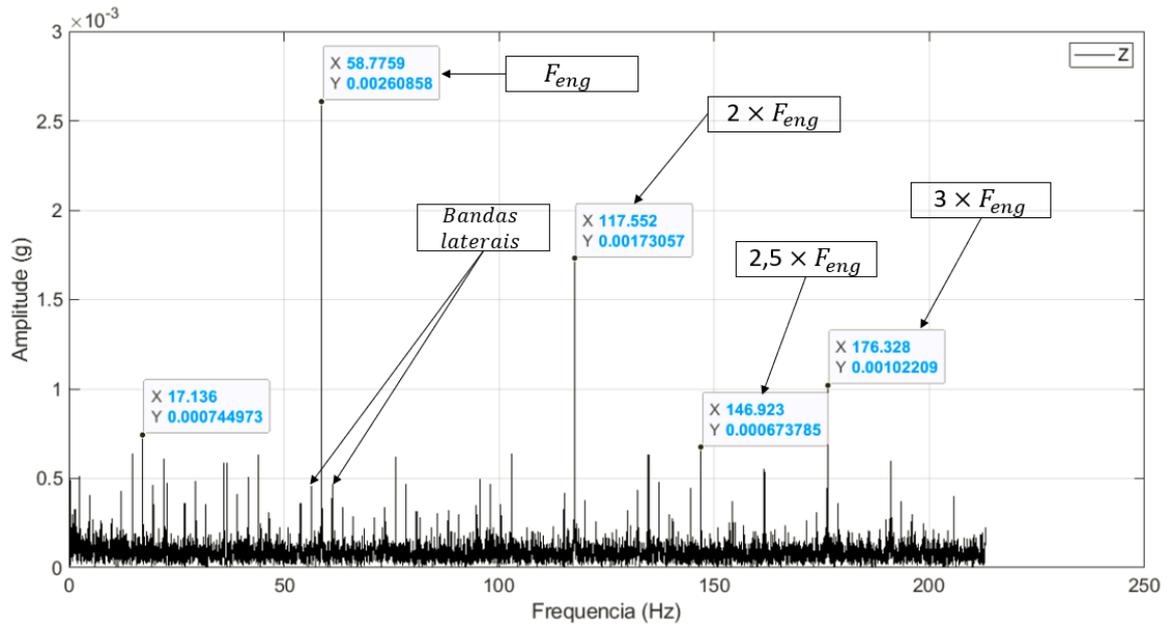
5.3 Análise de vibração e som para condição de sobrecarga

Para a condição de sobrecarga com torque de 62 N.m, o espectro de frequência obtido através da análise de vibração revela um aumento na amplitude da frequência de engrenamento, passando de 0,00109g na condição de referência para 0,00261g. As amplitudes dos harmônicos da frequência de engrenamento também se intensificaram, como observado em 2x frequência de engrenamento, que aumentou de 0,00069g para 0,00173g, e em 3x frequência de engrenamento, que passou de 0,00038g para 0,00102g. Além disso, bandas laterais surgiram. Nas condições de sobrecarga com torques de 84 N.m e 118 N.m, nota-se uma intensificação das bandas laterais à medida que o nível de sobrecarga aumenta. Nas Figuras 63, 64 e 65, são apresentados os espectros de frequência para as condições de sobrecarga com torques de 62 N.m, 84 N.m e 118 N.m, respectivamente.

A análise de vibração realizada demonstrou que a condição de sobrecarga aplicada ao eixo de saída do redutor gerou modulação de frequência, evidenciada pelo aparecimento e intensificação das bandas laterais no espectro de frequência. Observou-se ainda uma redução na velocidade do eixo de saída do redutor sob condições de sobrecarga. A frequência de rotação, que inicialmente estava em 29,8 Hz na condição de referência, reduziu para 29,3 Hz e 29,2 Hz sob condições de sobrecarga com 84 N.m e

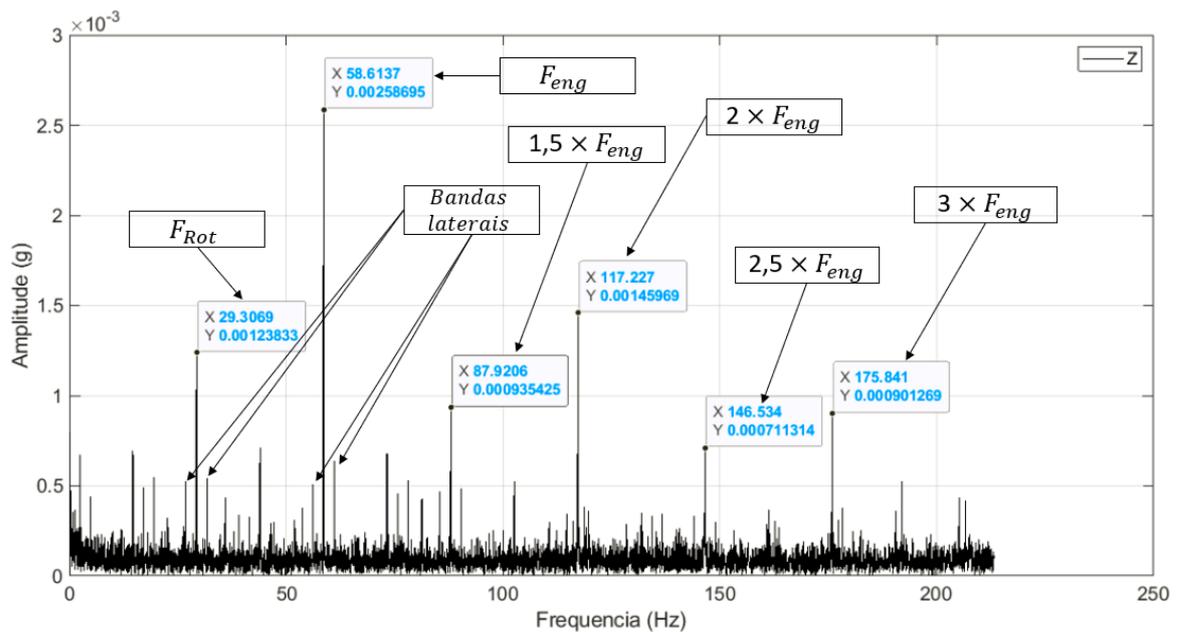
118 N.m, respectivamente. Esses resultados indicam uma resposta dinâmica do sistema que afeta diretamente a velocidade rotacional em função da carga adicional aplicada.

Figura 63: Espectro de frequência da análise de vibração para sobrecarga com torque de 62 N.m gerado pela aplicação de massa de 9 kg na extremidade do braço mecânico



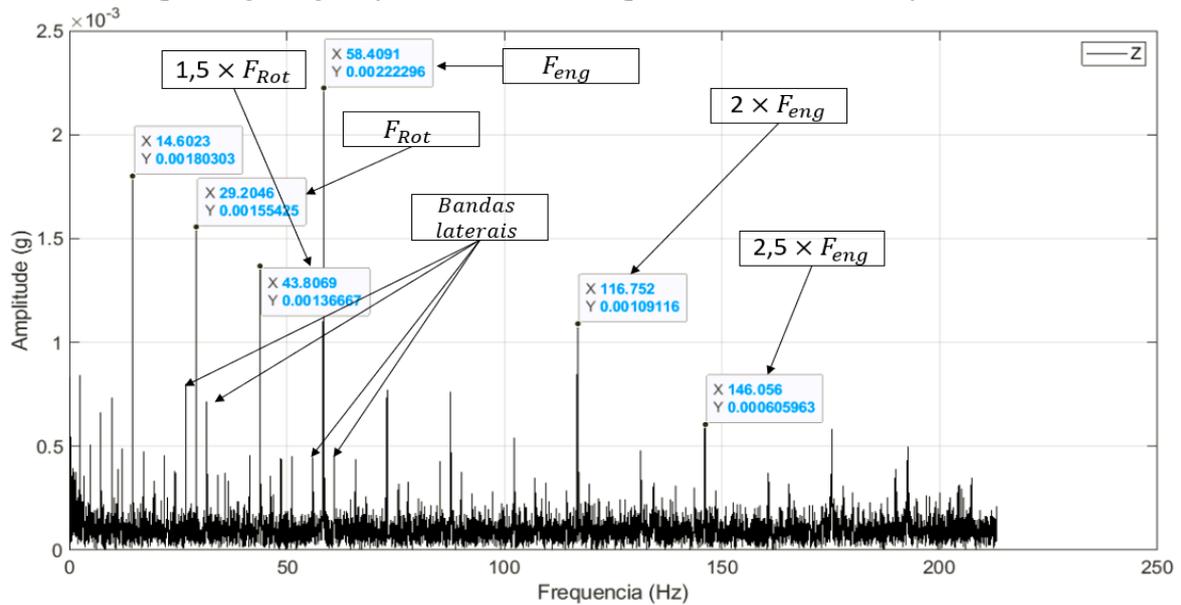
Fonte: Autor.

Figura 64: Espectro de frequência da análise de vibração para sobrecarga com torque de 84 N.m gerado pela aplicação de massa de 12 kg na extremidade do braço mecânico



Fonte: Autor.

Figura 65: Espectro de frequência da análise de vibração para sobrecarga com torque de 118 N.m gerado pela aplicação de massa de 17 kg na extremidade do braço mecânico



Após a realização da análise de vibração, foi feita a análise dos espectros de frequência para os sinais de áudio das três condições de sobrecarga. As Figuras 66, 67 e 68, apresentam os espectros de frequência para a condição de sobrecarga com 62 N.m, 84 N.m e 118 N.m, respectivamente. Nesses 3 cenários, nota-se um aumento nas amplitudes das harmônicas da frequência de engrenamento e intensificação das bandas laterais.

Figura 66: Espectro de frequência da análise de som para sobrecarga com torque de 62 N.m gerado pela aplicação de massa de 9 kg na extremidade do braço mecânico

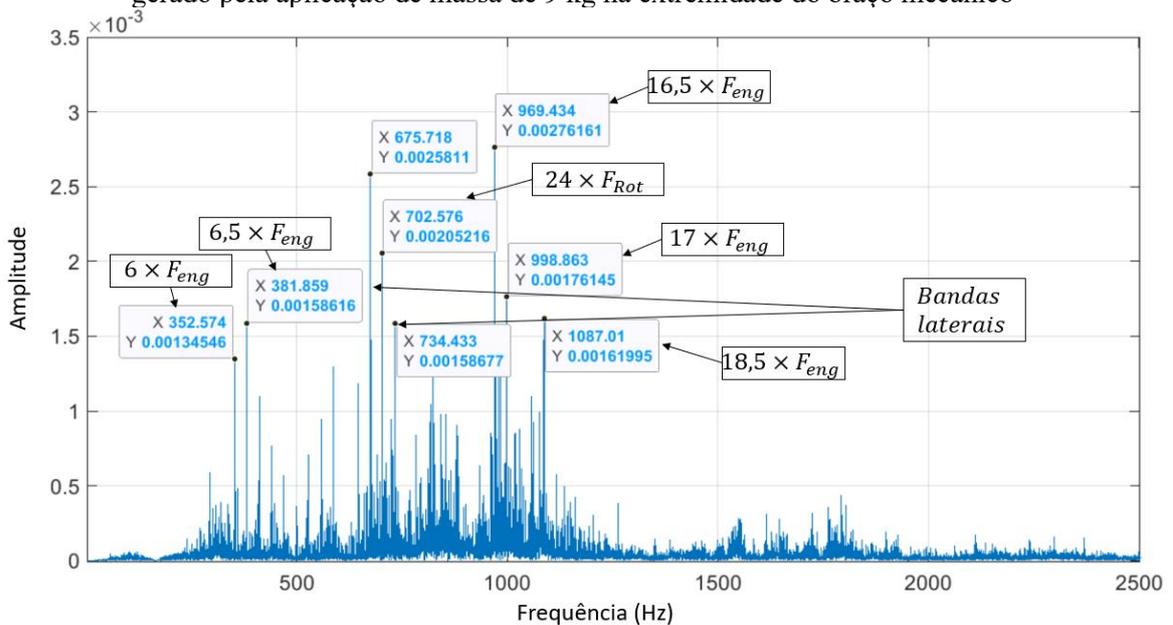
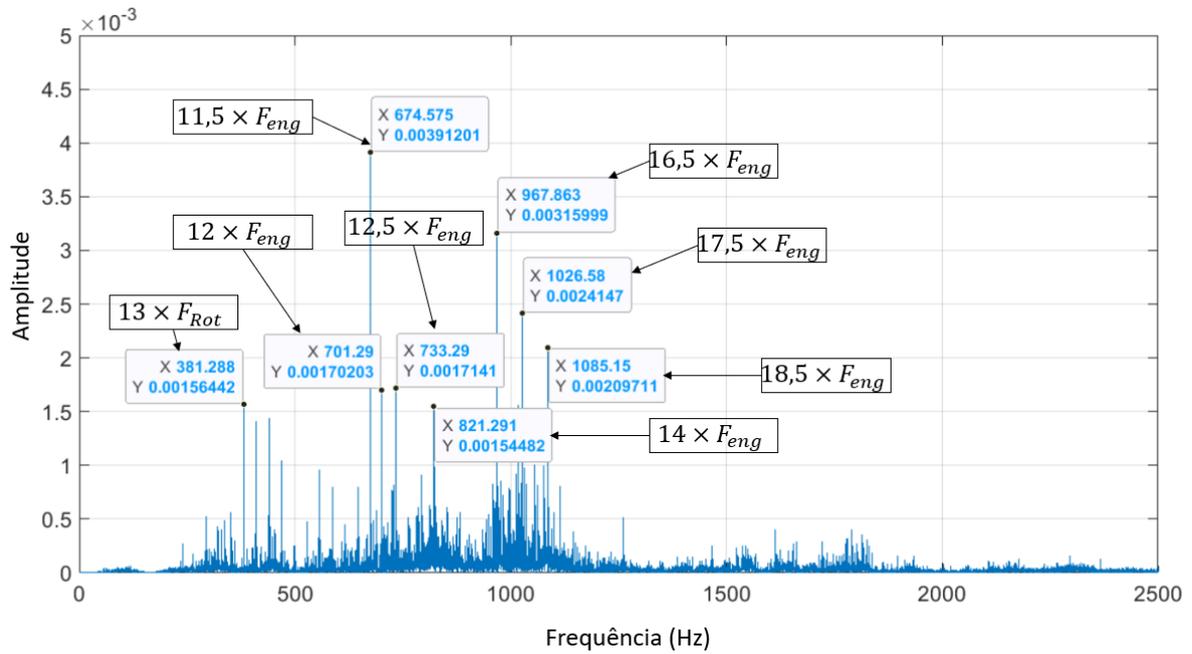
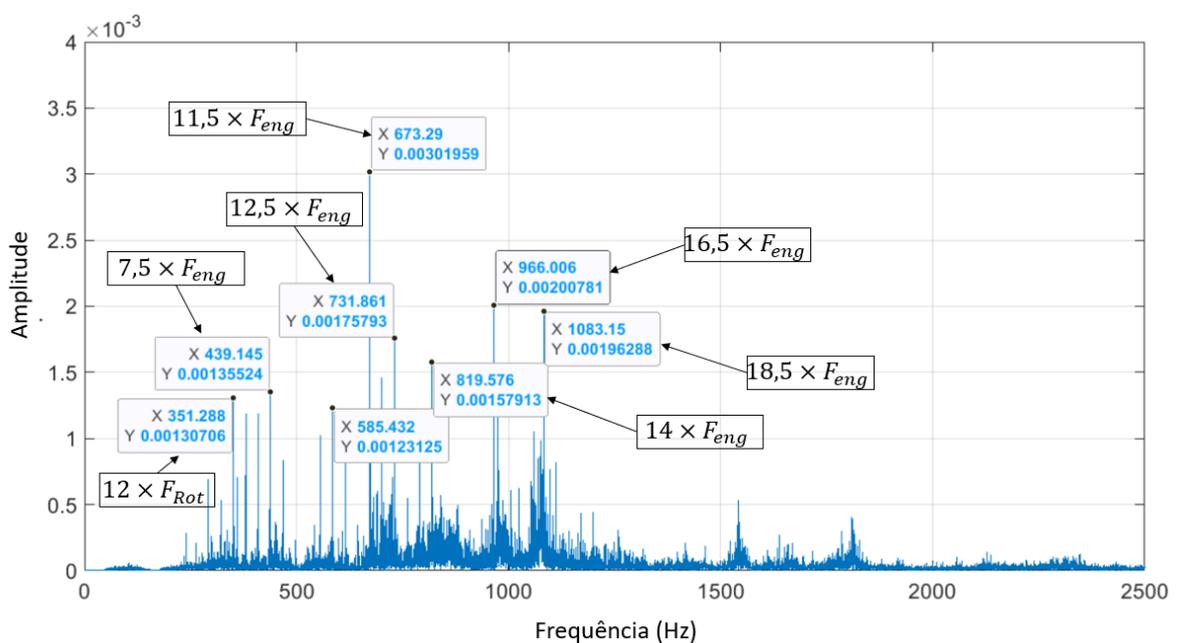


Figura 67: Espectro de frequência da análise de som para sobrecarga com torque de 84 N.m gerado pela aplicação de massa de 12 kg na extremidade do braço mecânico



Fonte: Autor

Figura 68: Espectro de frequência da análise de som para sobrecarga com torque de 118 N.m gerado pela aplicação de massa de 17 kg na extremidade do braço mecânico

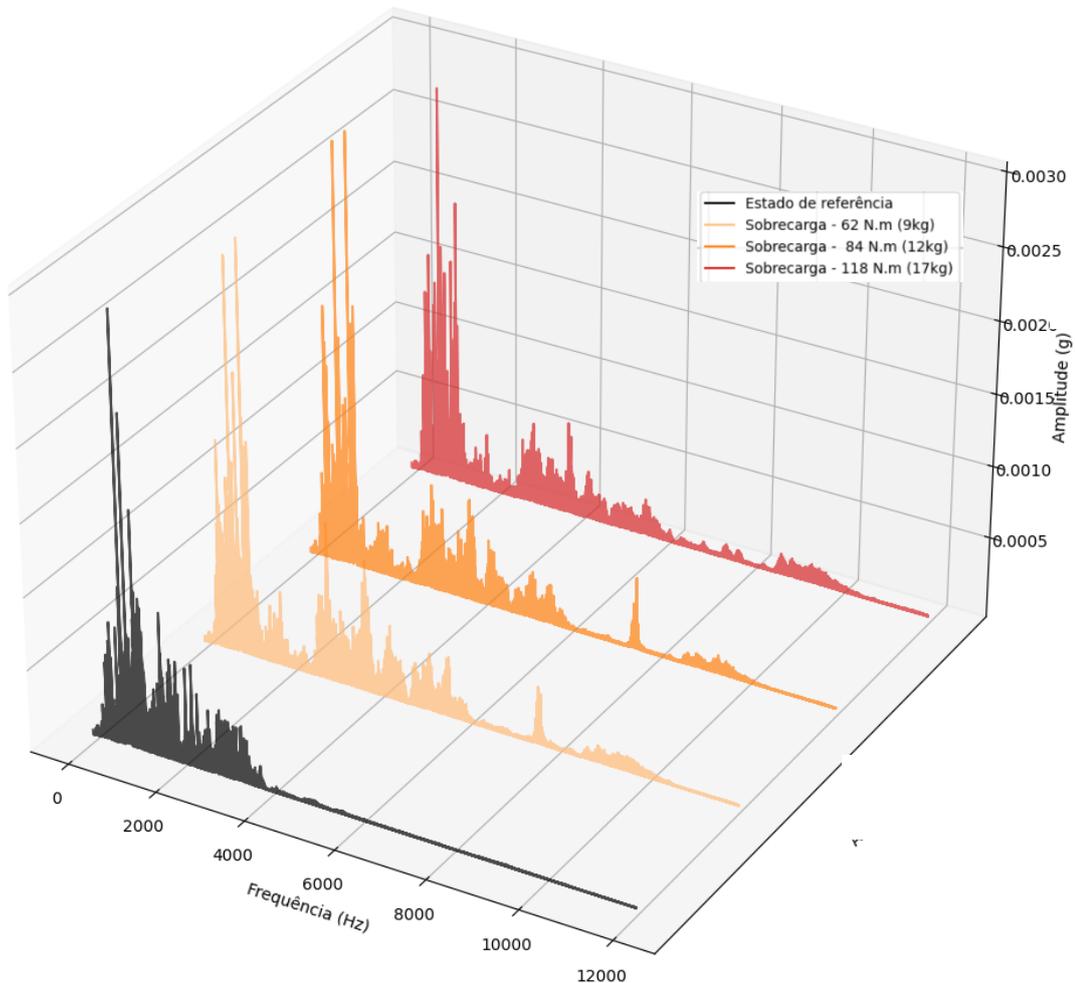


Fonte: Autor

A Figura 69, apresenta os espectros de frequência em 3D para os três níveis de sobrecarga, comparados à condição de referência. Essa visualização permite analisar as

variações e evolução da energia vibracional à medida que a severidade da condição de sobrecarga evolui com o aumento do torque aplicado no eixo de saída do redutor.

Figura 69: Espectro de frequência 3D para análise sonora da sobrecarga



Fonte: Autor

A análise dos coeficientes de energia obtidos pela Transformada de Wavelet para as diferentes condições de sobrecarga são apresentadas na Figura 70 e evidencia padrões de variação nas energias dos principais detalhes, compreendidos entre 6 e 10, indicando uma resposta do sistema rotativo ao aumento do torque aplicado no eixo de saída.

Nos níveis 6 e 7, observa-se uma redução na energia com o aumento inicial da sobrecarga, seguida por uma estabilização. No estado de referência, a energia no nível 6 é 19,04% e no nível 7 é 47,26%. Com uma sobrecarga de 62 N.m, esses valores caem para 15,35% e 32,54%, respectivamente. Com a sobrecarga de 84 N.m, a energia no nível

6 apresenta um pequeno aumento, indo para 16,07% e no nível 7 31,31%, respectivamente, indicando uma oscilação na resposta energética do sistema, enquanto, com 118 N.m, os valores permanecem próximos, sendo 15,35% e 30,64% nos níveis 6 e 7, respectivamente. Esse comportamento indica que esses níveis de detalhe são sensíveis às condições de sobrecarga, mas tendem a se estabilizar em um patamar de energia após certo ponto, independente do aumento do torque.

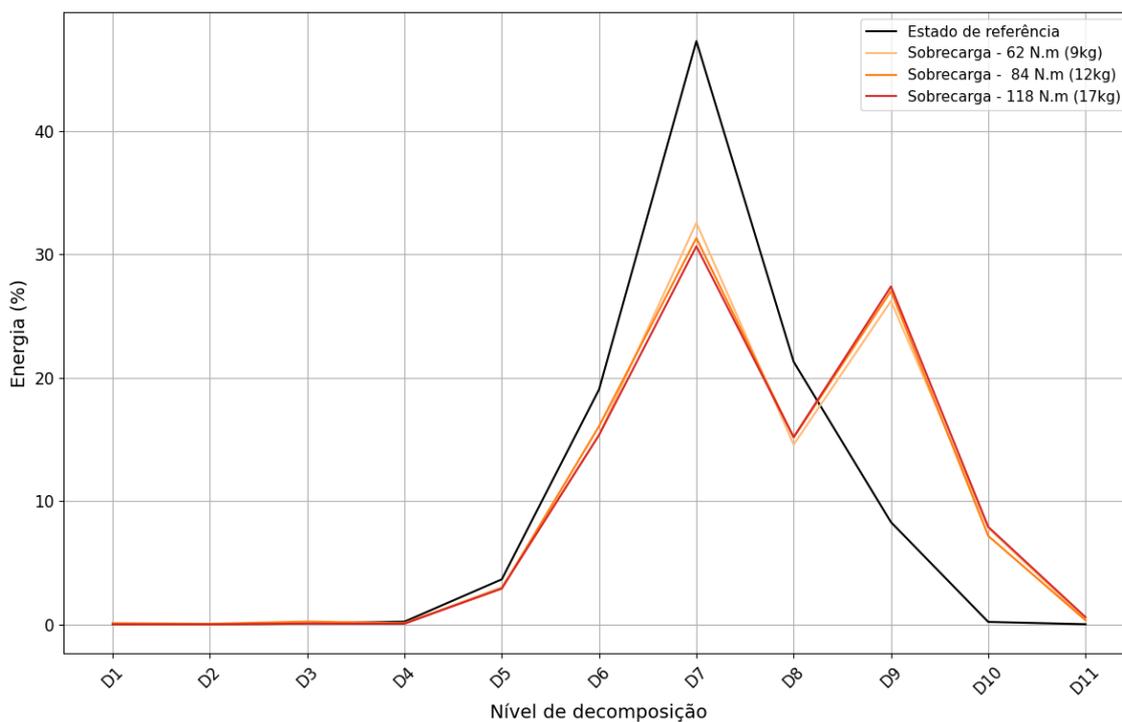
No nível 8, observa-se que no estado de referência, a energia é 21,8%, reduzindo para 14,57% com uma sobrecarga de 62 N.m. Para 84 N.m de sobrecarga, a energia no nível 8 apresenta leve aumento, chegando a 15,14% e se estabiliza em 15,18% com 118 N.m. Essa recuperação sugere que, embora o sistema perca energia com a carga inicial, há uma tendência de acomodação nas condições de sobrecarga de maior severidade.

O nível 9 apresenta o comportamento mais expressivo de resposta ao aumento de sobrecarga. No estado de referência, o valor é de 8,29%, saltando para 26,21% com uma sobrecarga de 62 N.m, elevando-se para 27,02% em 84 N.m e 27,38% em 118 N.m. Esse comportamento, evidencia que o nível 9 é altamente sensível à condição de sobrecarga, mantendo uma resposta energética elevada e se mostrando como um bom indicador para acompanhamento da condição de sobrecarga.

Por fim, no nível 10, também existe um aumento acentuado no percentual de energia mediante a condição de sobrecarga. O nível de energia nesse nível, para o estado de referência, é praticamente zero. Em uma condição de sobrecarga com 62 N.m, o percentual de energia sobe para 7,81% e atinge 7,91% com 118 N.m. Esse aumento reforça que as frequências estão sendo excitadas com a sobrecarga, sugerindo modulação do sistema.

Todas essas variações sugerem que, o aumento da sobrecarga induz uma resposta modulada em frequências específicas, refletidas nos detalhes de 6 a 10. A análise wavelet indica que o comportamento energético nos níveis 9 e 10 é válido para monitoramento das condições de sobrecarga. Nota-se também que o aumento as sobrecargas acabam gerando uma estabilização após um ponto crítico de torque aplicado ao sistema rotativo.

Figura 70: Energia dos detalhes da Wavelet para sobrecarga



Fonte: Autor

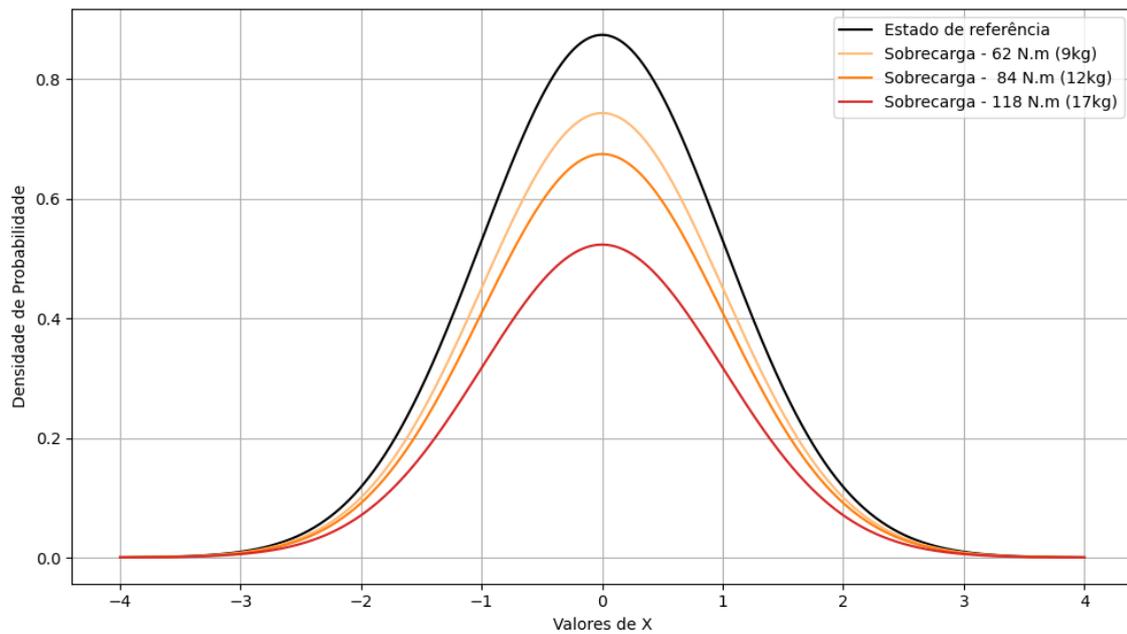
O comportamento vibracional sob condição de sobrecarga também foi avaliado utilizando métricas estatísticas. Nas Figuras 71 e 72, observa-se os resultados para a curtose. A partir da Figura 72, nota-se que os valores de $K > 0$, indicando uma distribuição leptocúrtica para todas as condições de sobrecarga avaliadas.

A análise de curtose para as diferentes condições de sobrecarga, revela uma tendência de queda à medida que o nível de sobrecarga aumenta. No estado de referência a curtose é de 1,1893. Com a aplicação de uma sobrecarga de 62 N.m, a curtose diminui para 0,8618, indicando uma suavização nos picos do sinal e possivelmente uma redistribuição de energia.

Quando a sobrecarga sobe para 84 N.m, a curtose apresenta mais uma redução, chegando a 0,6901, indicando que o sinal apresenta uma curva de curtose mais achatada, com menos picos significativos e uma distribuição de energia mais homogênea.

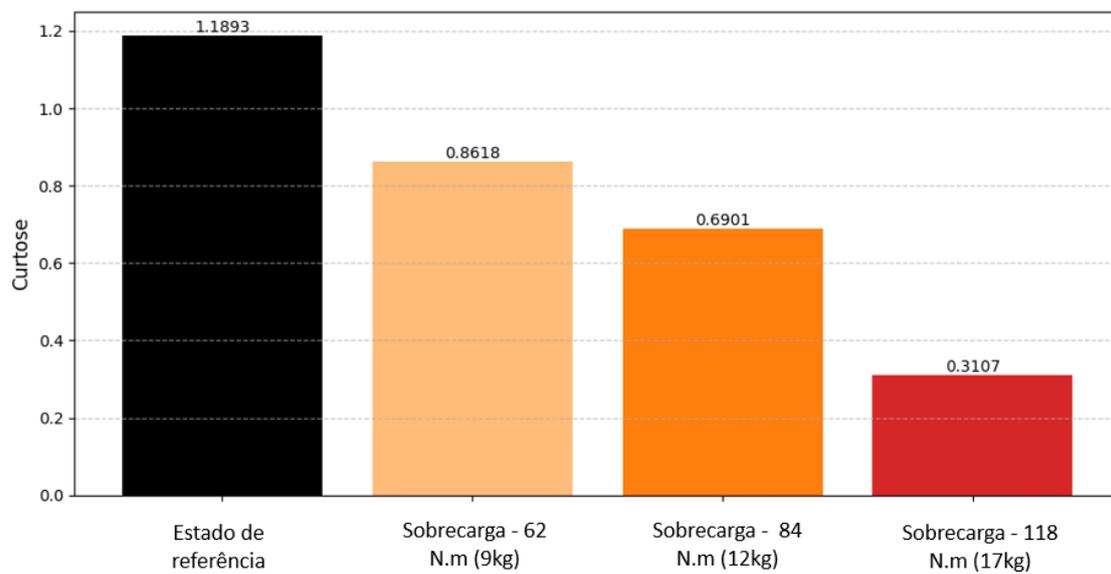
Por fim, para a condição de sobrecarga com 118 N.m, a curtose atinge 0,3107, valor mais baixo observado, indicando um sinal com uma curva de distribuição ainda mais achatada, conforme apresentada na Figura 71, indicando menores intensidades nas flutuações.

Figura 71: Curvas de curtose para sobrecarga



Fonte: Autor

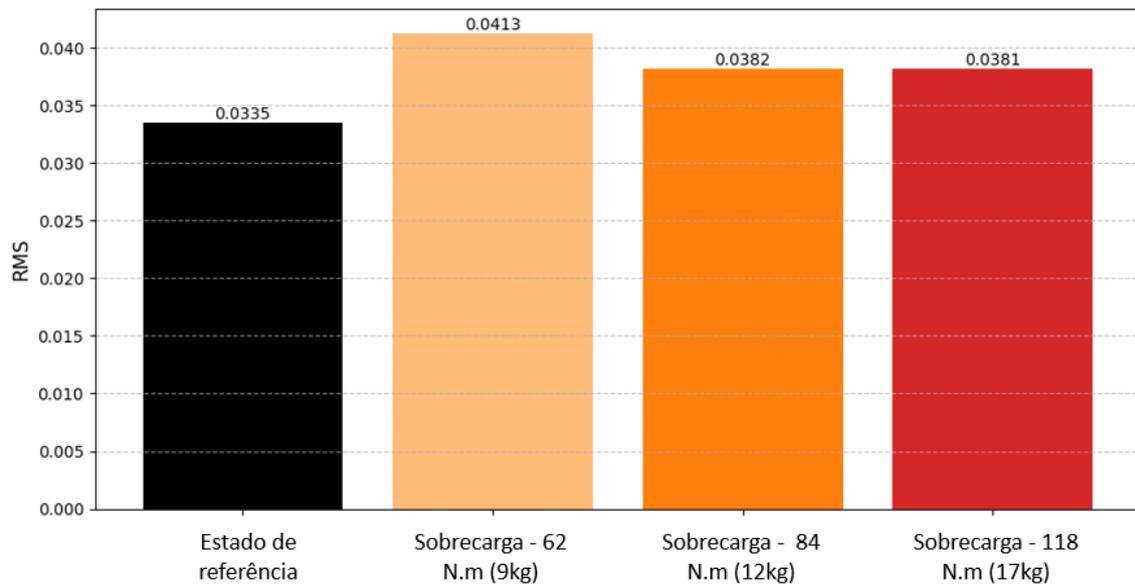
Figura 72: Valores de curtose para sobrecarga



Fonte: Autor

Com relação ao RMS, como pode ser observado na Figura 73, a um aumento de energia para as condições de sobrecarga quando comparadas a condição de referência. Para a condição de referência o RMS atinge 0,0335, enquanto para as condições de sobrecarga com 62 N.m, 84 N.m e 118 N.m, chega-se aos valores de 0,0413, 0,0382 e 0,0381, respectivamente.

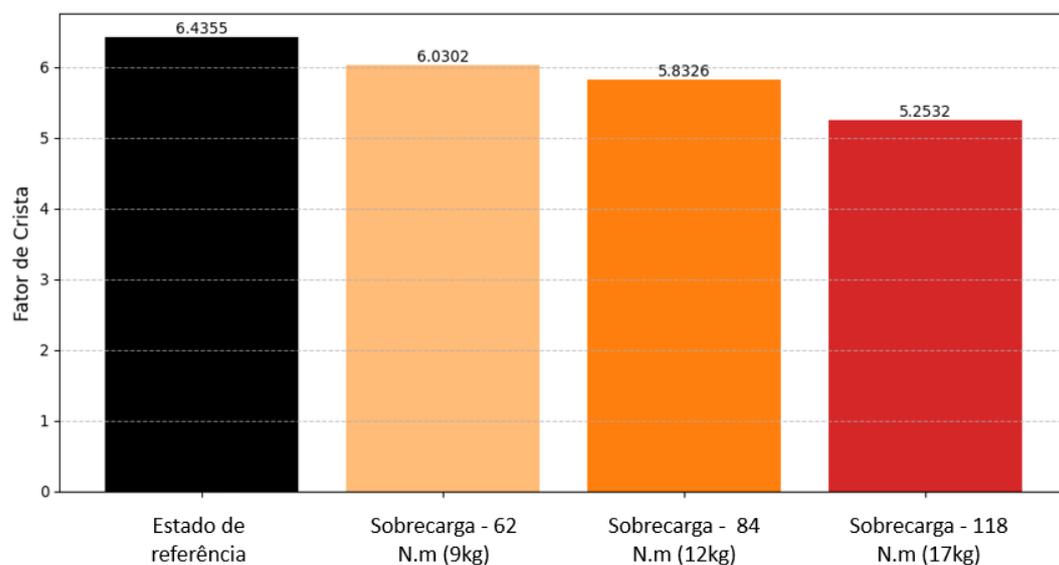
Figura 73: Valores de RMS para sobrecarga



Fonte: Autor

A partir da análise do fator de crista de acordo com as variações de sobrecarga, observa-se que há uma tendência de redução gradual com o aumento do torque aplicado. No estado de referência, o fator de crista é de 6,4355, reduzindo para 6,0302 com uma sobrecarga de 62 N.m, 5,8326 com 84 N.m e 5,2532 com 118 N.m, conforme apresentado na Figura 74. Essa redução indica que, à medida que a sobrecarga aumenta, as amplitudes dos picos tornam-se proporcionalmente menores em relação ao valor RMS.

Figura 74: Valores de Fator de Crista para sobrecarga



Fonte: Autor

5.4 Análise de vibração e som para condição de lubrificação ineficiente

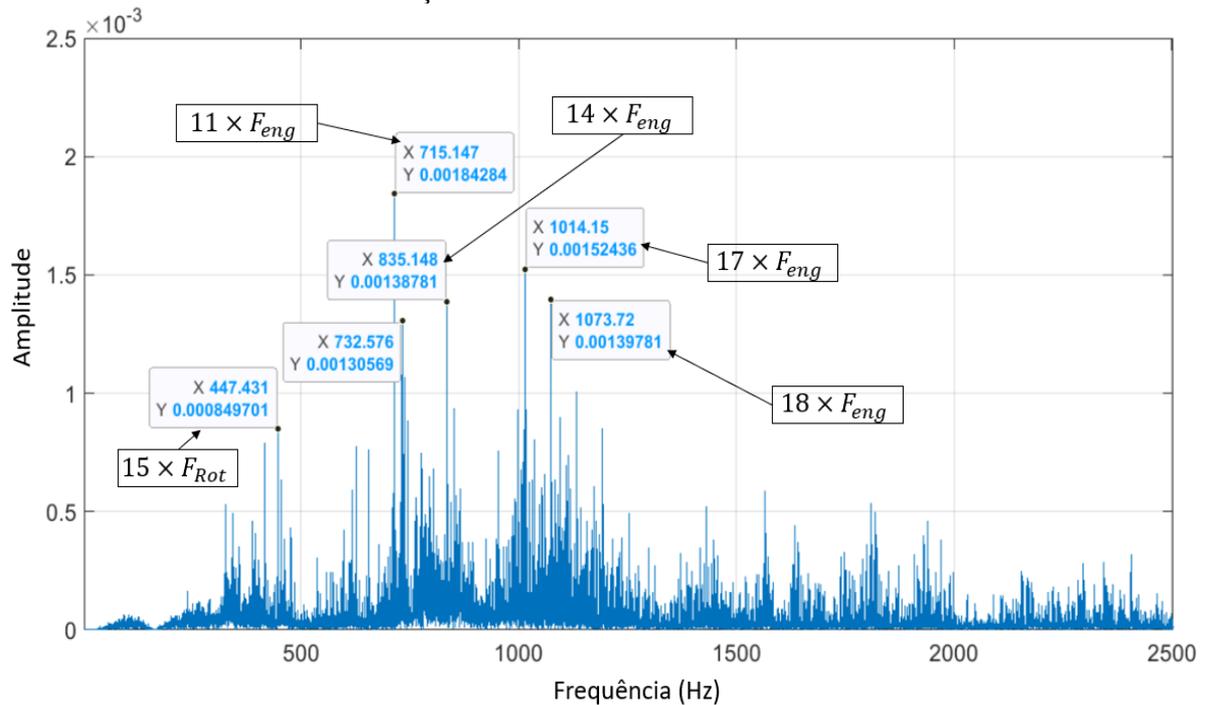
Para a condição de lubrificação ineficiente, não foi possível realizar a análise de vibração devido à limitação do sistema de medição a baixas frequências. Na literatura, no entanto, está exposto que uma característica típica de lubrificação ineficiente no espectro de frequência é o chamado “carpete”, ou seja, um ruído que se estende a uma região do espectro de vibração. Esse fenômeno reflete um aumento de picos pequenos e distribuídos ao longo do espectro (VEDAN, [s.d]). Gupta et al (2020), estudaram os comportamentos tribológicos e vibracionais de pares de engrenagens de dente retos convencionais e texturizados em condições de lubrificação completa e ineficiente. Para as condições de lubrificação ineficiente, identificou-se o fenômeno de “carpete” em faixas de alta frequência no espectro de vibração, corroborando para o fato de não ser possível a análise de vibração com o sistema utilizado, como já mencionado.

A partir da análise dos espectros de som, observa-se que a condição de lubrificação ineficiente, induzida através da redução do volume de óleo, introduzem alterações na resposta vibracional do sistema rotativo. Com a redução de 50% do nível do óleo, conforme observado na Figura 75, o espectro apresenta frequências dominantes em 715,147 Hz, 835,148 Hz, 1014,150 Hz e 1073,720 Hz. Os valores de amplitude nas frequências 715,147 Hz e 1014,150 Hz diminuem em comparação a condição de referência, enquanto novos picos aparecem, como em 447, 431 Hz e 1073,72 Hz. Essas novas frequências e a modulação da amplitude refletem modos de vibração que antes eram atenuados pela lubrificação adequada.

Na condição de redução de 75% do óleo do redutor, conforme observado na Figura 76, o espectro apresenta os seguintes picos: 656,004 Hz, 714,861 Hz, 775,29 Hz, 834,862 Hz, 1013,72 Hz e 1073,430 Hz, com amplitudes de até 0,0033 na frequência de 834,862 Hz. Esse aumento de amplitude, em especial na frequência de 834,862 Hz, indica um aumento de atrito. Além disso, a introdução de novas frequências como 556,575 Hz e 775,290 Hz, reflete o impacto da redução do óleo, provocando um contato mais direto entre as superfícies das engrenagens, amplificando modos de vibração que antes estariam amortecidos pelo correto filme de óleo. Os picos observados nas faixas de alta frequência e que se intensificaram com a redução do nível de óleo, são compatíveis com o comportamento presente em desgaste abrasivo, conforme descrito por Feng et al (2023). Logo, essas alterações, não só indicam uma lubrificação ineficiente, mas também

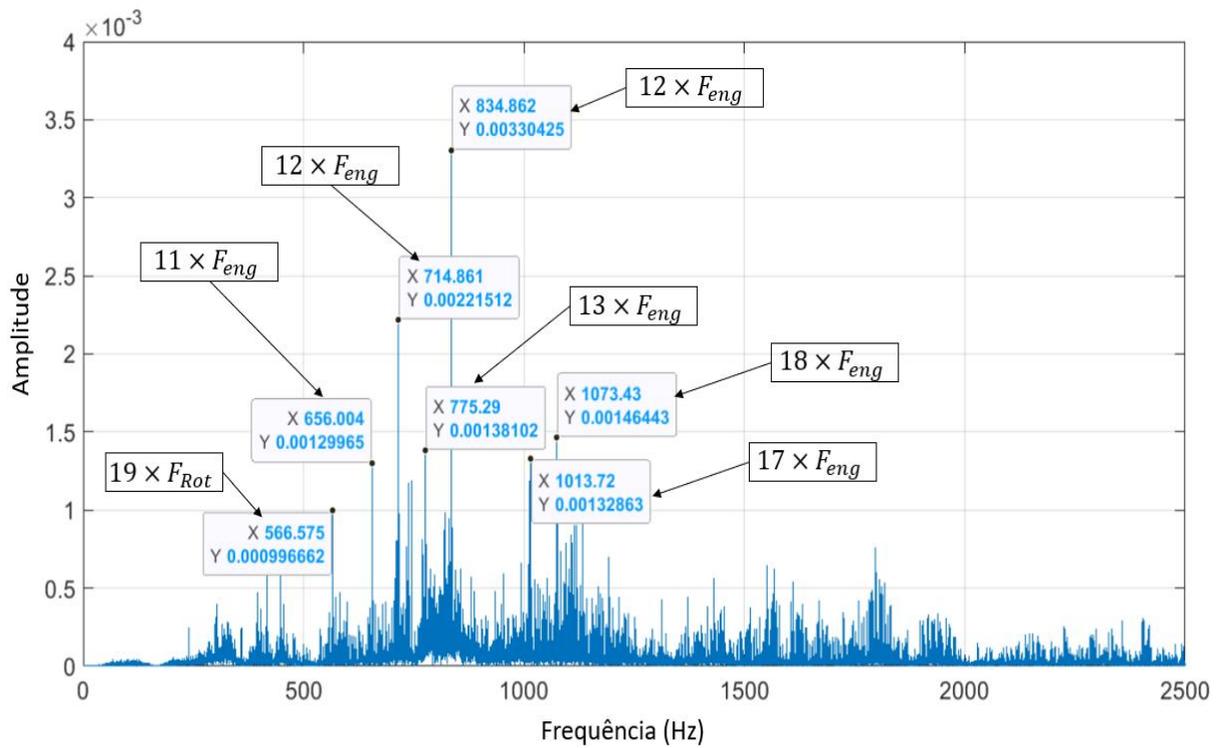
sugerem um desgaste abrasivo gradual. Em resumo, nota-se que à medida que a lubrificação se torna mais ineficiente, novos picos surgem no espectro e as amplitudes de algumas frequências aumentam, em especial para frequências mais altas. A condição de lubrificação ineficiente também ocasiona o surgimento de frequências adicionais.

Figura 75: Espectro de frequência da análise de som para lubrificação insuficiente com redução de 50% do nível de óleo.



Fonte: Autor

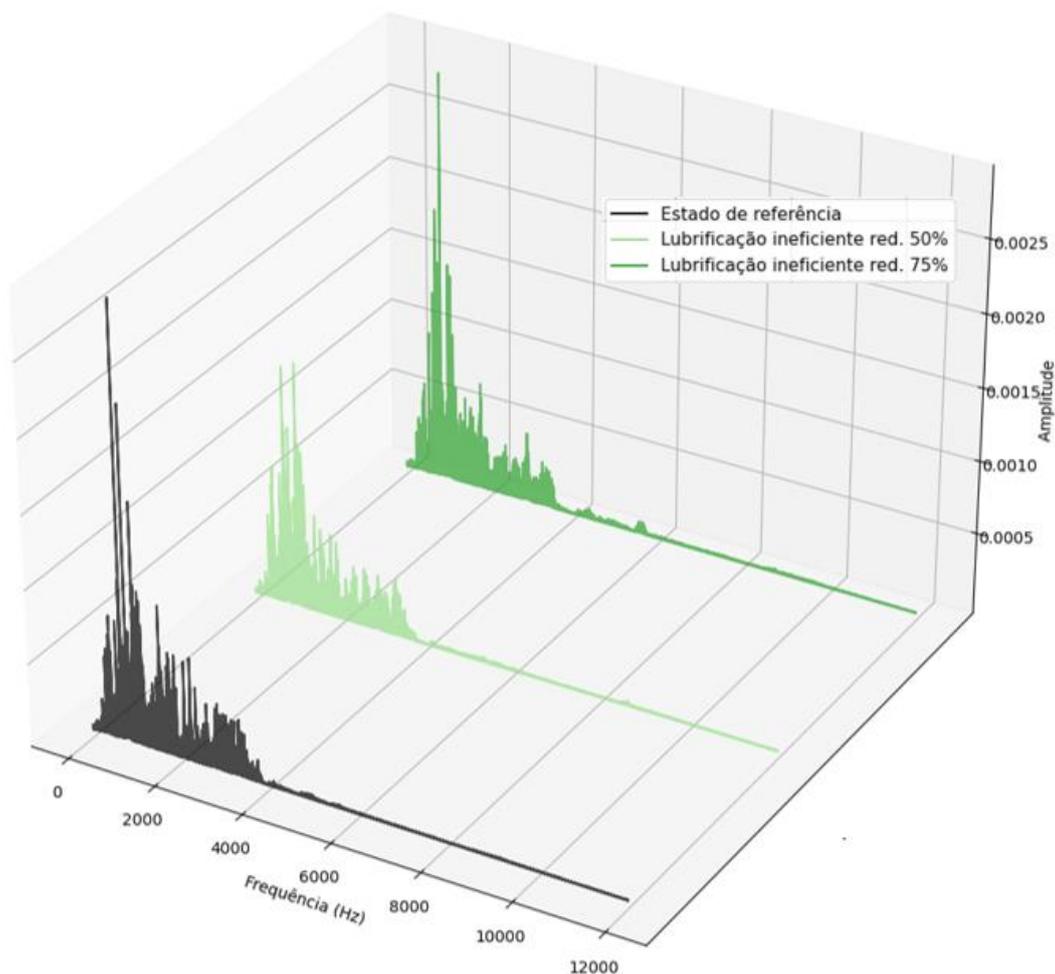
Figura 76: Espectro de frequência da análise de som para lubrificação insuficiente com redução de 75% do nível de óleo.



Fonte: Autor

Na Figura 77, são apresentados os espectros de frequência em 3D para os dois níveis de condição de lubrificação ineficiente, comparados à condição de referência. Essa visualização permite analisar as variações e evolução da energia vibracional à medida que a severidade da condição de lubrificação deficiente evolui com a redução do volume de óleo.

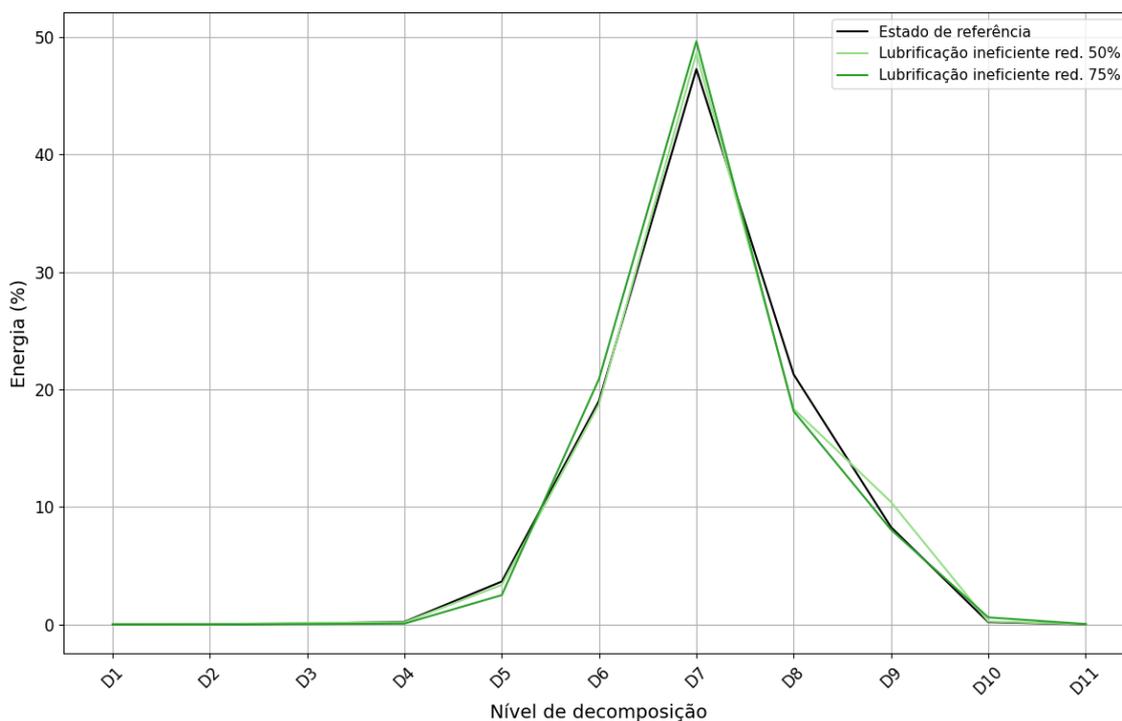
Figura 77: Espectro de frequência 3D para análise sonora da lubrificação ineficiente



Fonte: Autor

A análise dos coeficientes de energia obtidos pela Transformada de Wavelet para as diferentes condições de lubrificação ineficiente são apresentadas na Figura 78 e evidencia padrões de variação nas energias principalmente no detalhe 7 (187,5 – 375 Hz). Na condição de referência o valor de energia no detalhe 7 é de aproximadamente 47,26%. Com a redução de 50% do volume de óleo, a energia nesse detalhe aumenta para 48,62%. Quando a quantidade de óleo é reduzida em 75%, a energia no detalhe 7 chega a 49,63%. Logo, nota-se que o detalhe 7 é o mais sensível às mudanças de lubrificação, mostrando uma resposta vibracional crescente à medida que o volume de óleo é reduzido.

Figura 78: Espectrograma de energia da Wavelet para lubrificação ineficiente

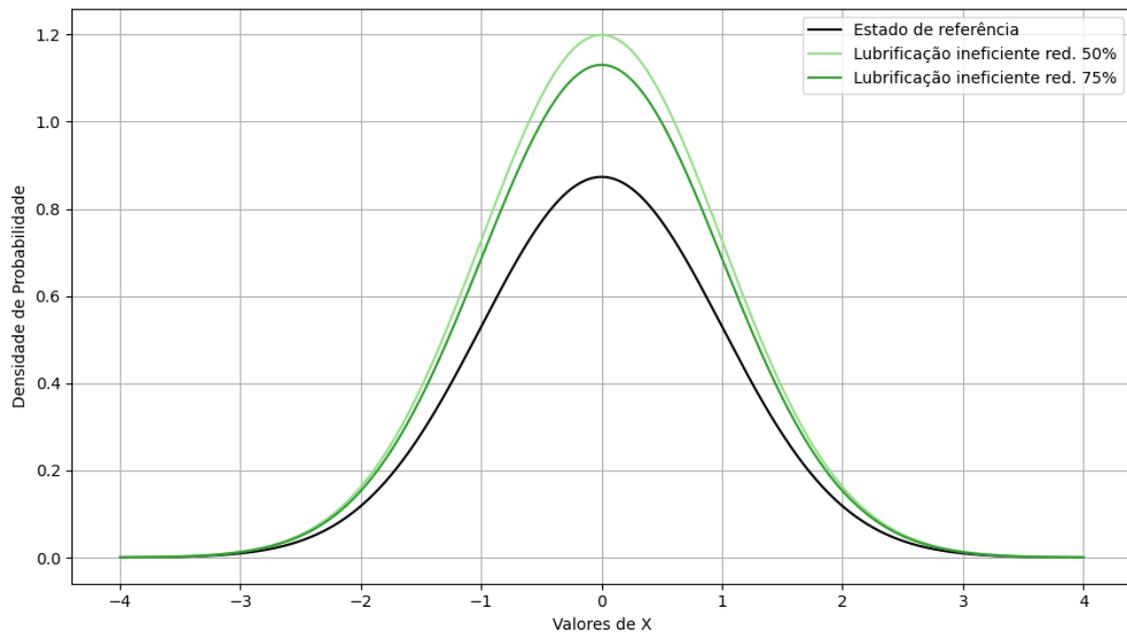


Fonte: Autor

O comportamento vibracional sob condição de lubrificação ineficiente também foi avaliado utilizando métricas estatísticas. Nas Figuras 79 e 80, observa-se os resultados para a curtose. A partir da Figura 80, nota-se que os valores de $K > 0$, indicando uma distribuição leptocúrtica para todas as condições de lubrificação.

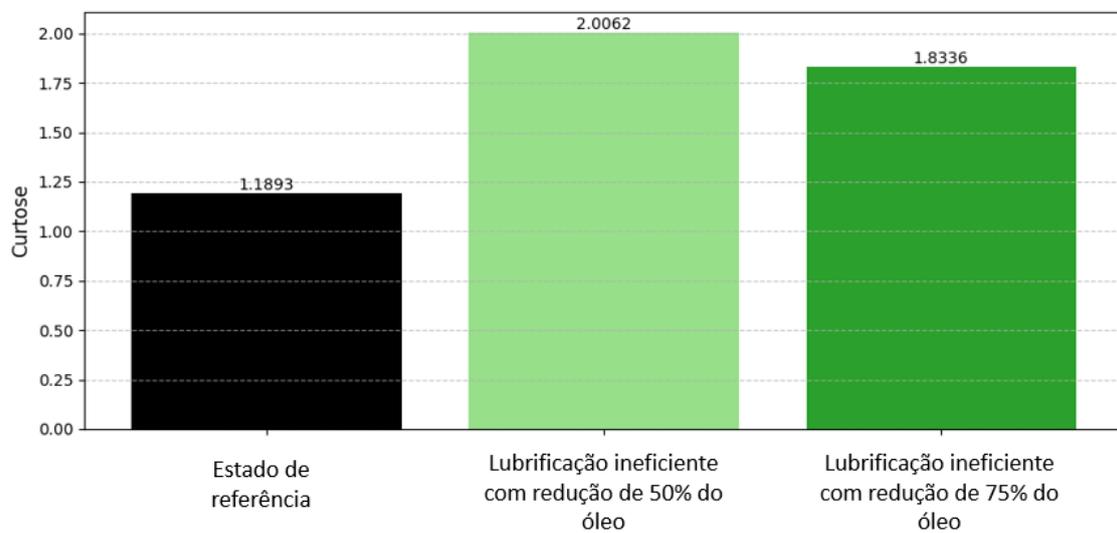
Com já mencionado anteriormente, a condição de referência apresenta um valor de curtose de 1,1893. Com a redução de 50% do volume de óleo, o valor de curtose aumenta para 2,0062, indicando a presença de picos de vibração mais intensos. Esse aumento pode estar associado ao atrito crescente e à formação de transientes, como pequenos choques entre as superfícies de contato das engrenagens. Esse elevado valor de curtose, também sugere que a redução de lubrificação está ocasionando irregularidades na distribuição de vibração. Na condição de redução do volume de óleo em 75%, a curtose apresenta valor igual a 1,8336, indicando uma pequena redução com relação a condição de lubrificação ineficiente anterior, mas ainda se mantém acima da condição de referência. Essa leve redução indica que as vibrações começam a se tornar mais uniformes, ou seja, há uma estabilização dos picos extremos.

Figura 79: Curvas de Curtose para lubrificação ineficiente



Fonte: Autor

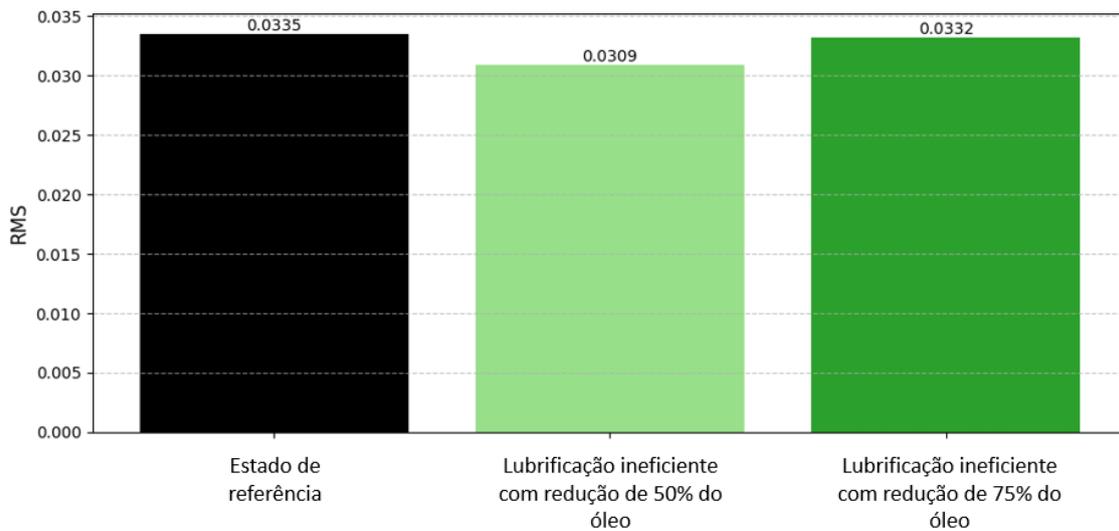
Figura 80: Valores de curtose para lubrificação ineficiente



Fonte: Autor

Na Figura 81, são apresentados os valores de RMS para as condições de lubrificação reproduzidas. Nota-se que não houve grandes flutuações nos seus valores.

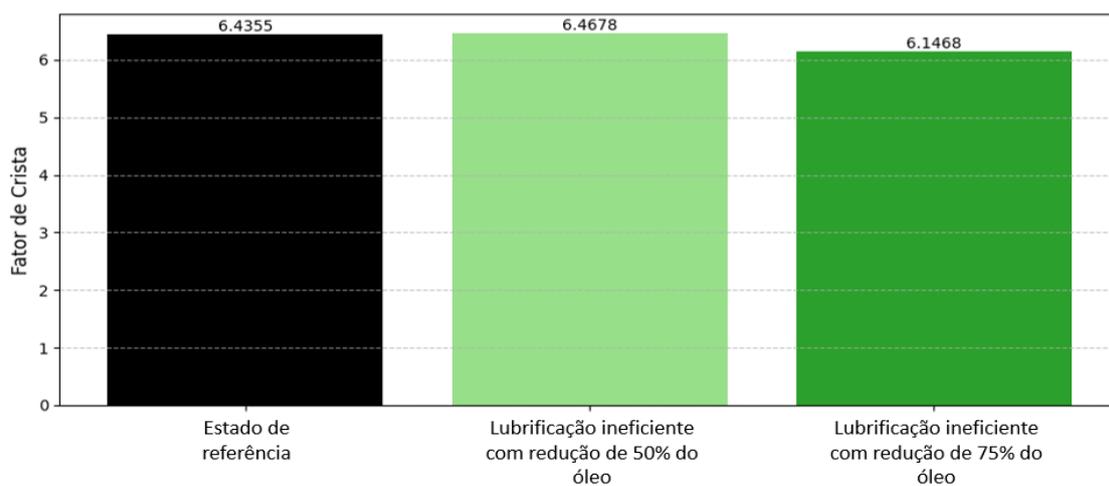
Figura 81: Valores de RMS para lubrificação ineficiente



Fonte: Autor

Na Figura 82, são apresentados os valores de Fator de crista para as condições de lubrificação avaliadas. Com a redução de 50% do volume de óleo, há um pequeno aumento no fator de crista, saindo de 6,4355 na condição de referência e chegando a 6,4678. Apesar de indicar que nessa condição o redutor esteja operando próximo da condição de referência, os picos de vibração começam a se tornar mais significativos. Com 75% da redução do volume de óleo, o fator de crista passa a ser 6,4168, essa diminuição sugere que os picos de vibração estão se tornando menos pronunciados com relação à média.

Figura 82: Valores de Fator de Crista para lubrificação ineficiente



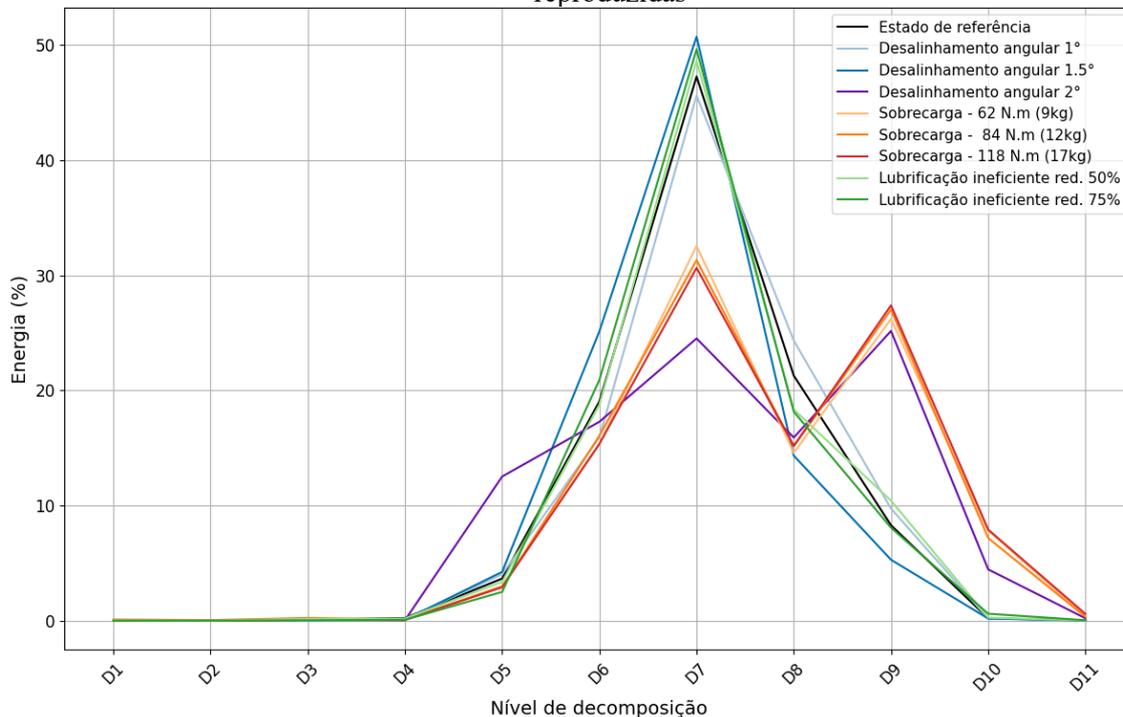
Fonte: Autor

5.5 Comparação global das condições de funcionamento reproduzidas

Após a análise detalhada de cada classe de condição de funcionamento, será apresentado nesta seção uma comparação abrangente dos resultados obtidos. Para isso serão utilizados gráficos separados para cada métrica de avaliação: espectrograma de energia da Wavelet, curtose, RMS e fator de crista. Compilando os dados de todas as condições de funcionamento em um único gráfico será possível identificar os padrões associados a cada condição de operação.

Na Figura 16, referente ao gráfico FUPAI para severidade de vibração nos redutores, percebe-se que há um aumento nas amplitudes de vibração entre 80 e 800 Hz. Esse padrão está presente no gráfico de energia dos detalhes Wavelet da Figura 83, que mostra que a indução de condições adversas a de referência e aumento da severidade de cada uma delas, induz alterações significativas, em sua maioria nos detalhes 6 (375 – 750 Hz), 7 (187,5 – 375 Hz), 8 (93,75 – 187,5 Hz) e 9 (46,88 – 93,75 Hz), onde existem maiores concentrações de energia. Isso mostra que o comportamento apresentado está em consonância com o exposto na norma FUPAI.

Figura 83: Energia nos diferentes níveis de decomposição para as condições de funcionamento reproduzidas

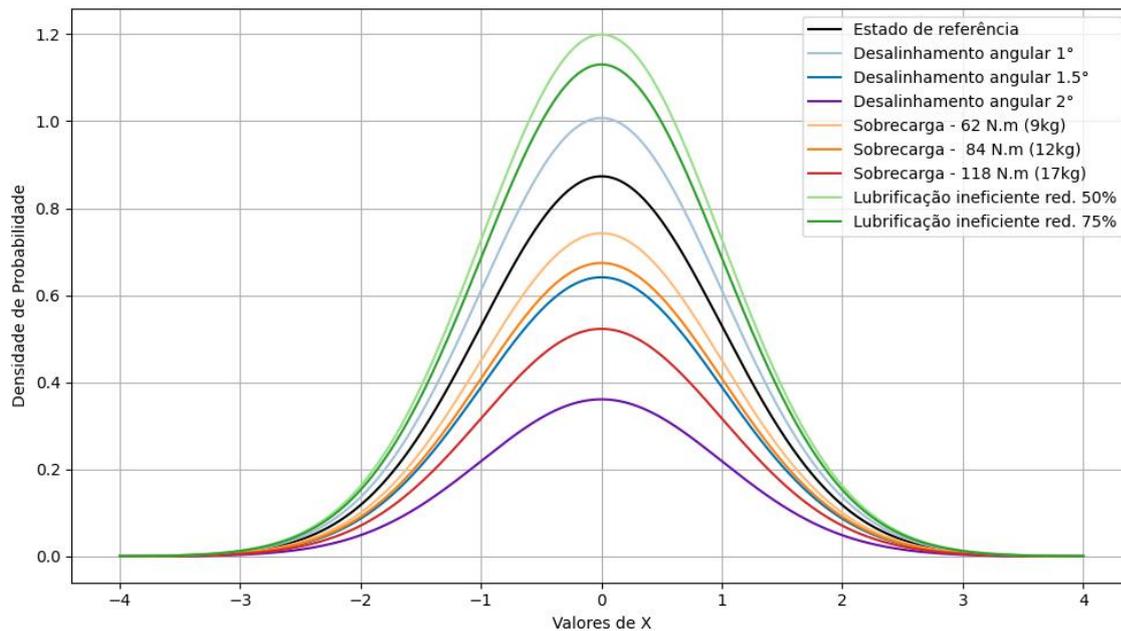


Fonte: Autor

A partir da análise comparativa da curtose em diferentes condições de funcionamento, nota-se que a condição de referência teve um valor de 1,1893, enquanto o desalinhamento angular de 1° aumentou a curtose para 1,5253, indicando maior concentração de vibração. Contudo, ao aumentar o desalinhamento para $1,5^\circ$ e 2° , a curtose caiu para 0,6079 e -0,1051, mostrando certa dispersão das amplitudes. Em relação a condição de sobrecarga, evidenciou-se que com o aumento do torque aplicado, houve uma tendência de dispersão crescente. Por outro lado, a lubrificação ineficiente, apresentou altos valores de curtose, demonstrando elevada concentração das vibrações.

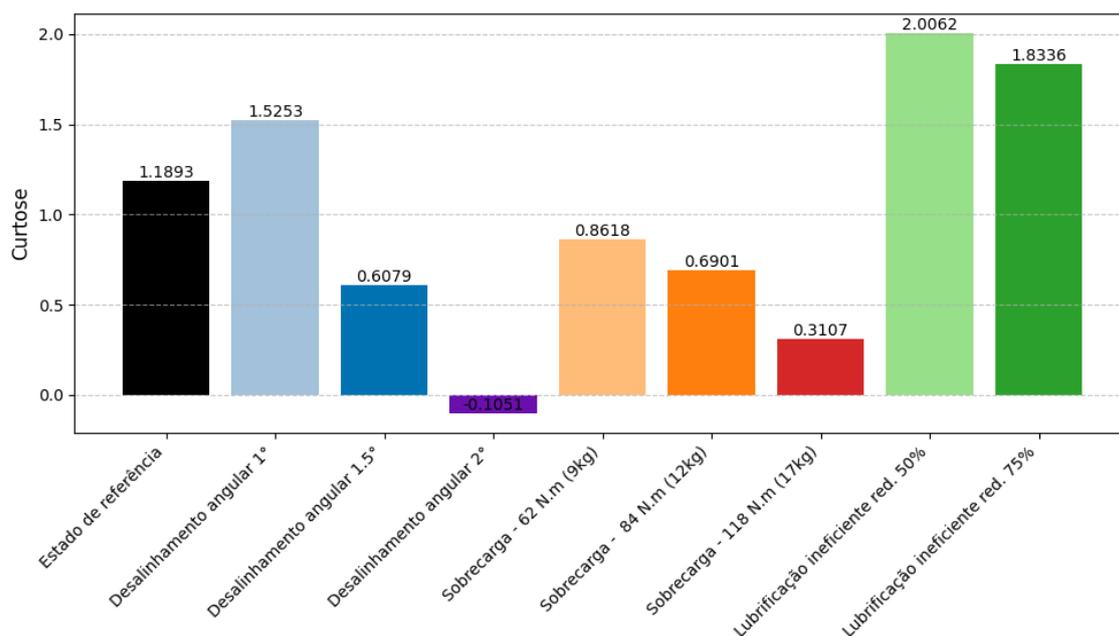
Em resumo, a comparação das curtoses, mostra que para desalinhamento angular a distribuição se torna mais dispersa com o aumento do ângulo, ou seja, a uma redução da concentração das vibrações. Na sobrecarga, com o aumento do torque aplicado há uma redução da concentração das vibrações. Já para o caso de lubrificação ineficiente, há um aumento da concentração das amplitudes.

Figura 84: Curvas de Curtose para as condições de funcionamento reproduzidas



Fonte: Autor

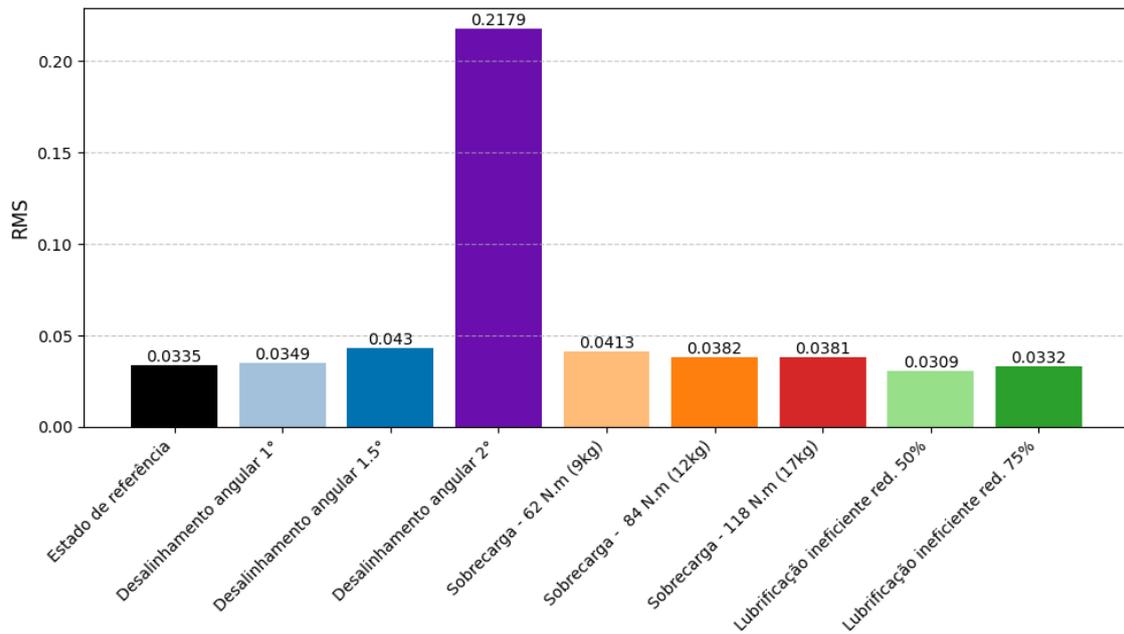
Figura 85: Valores de curtose para as condições de funcionamento reproduzidas



Fonte: Autor

A partir do gráfico 86, nota-se que o aumento dos valores RMS foi mais significativo com o aumento do desalinhamento angular. Para as condições de sobrecarga, os valores de RMS também foram maiores que os da condição de referência, mas com menor intensificação que para desalinhamento angular. Na condição de lubrificação ineficiente, não foram observadas grandes variações com relação a condição de referência.

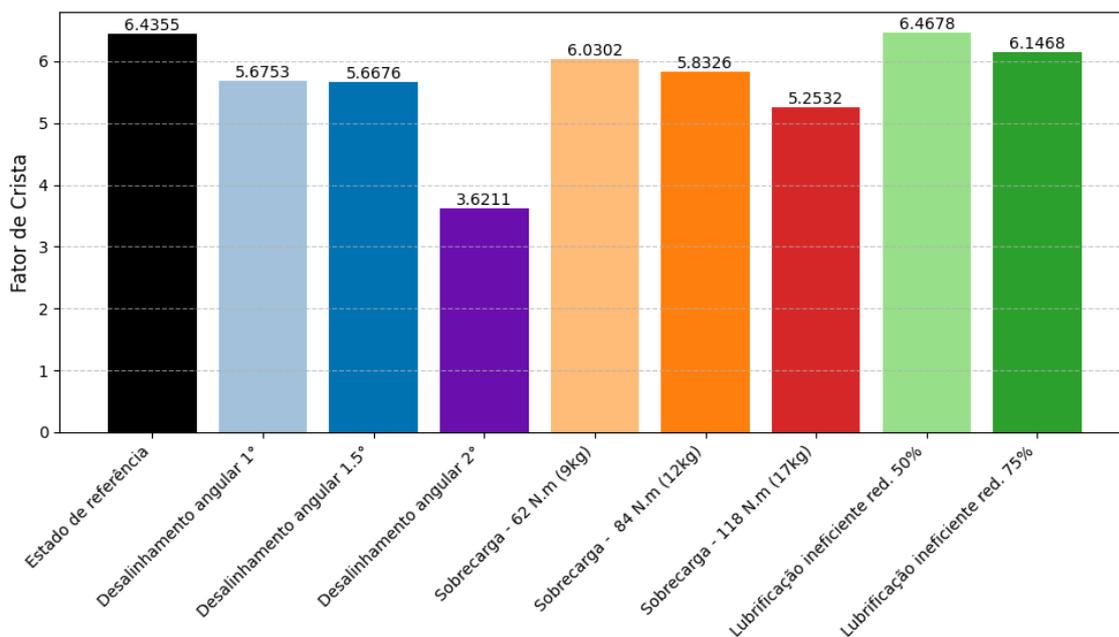
Figura 86: Valores de RMS para as condições de funcionamento reproduzidas.



Fonte: Autor

Ao analisar a Figura 87, observa-se que o aumento do desalinhamento angular levou a uma diminuição contínua do fator de crista, indicando uma redução nas irregularidades das vibrações. As condições de sobrecarga também apresentaram uma redução contínua do fator de crista. Na lubrificação ineficiente houve um pequeno aumento no fator de crista para a condição de redução do volume de óleo em 50% quando comparada com a condição de referência e para o caso referente a redução de 75% do volume de óleo, houve uma redução do fator de crista.

Figura 87: Valores de Fator de crista para as condições de funcionamento reproduzidas.



Fonte: Autor

5.6 Análise de desempenho das redes neurais do sistema de diagnóstico

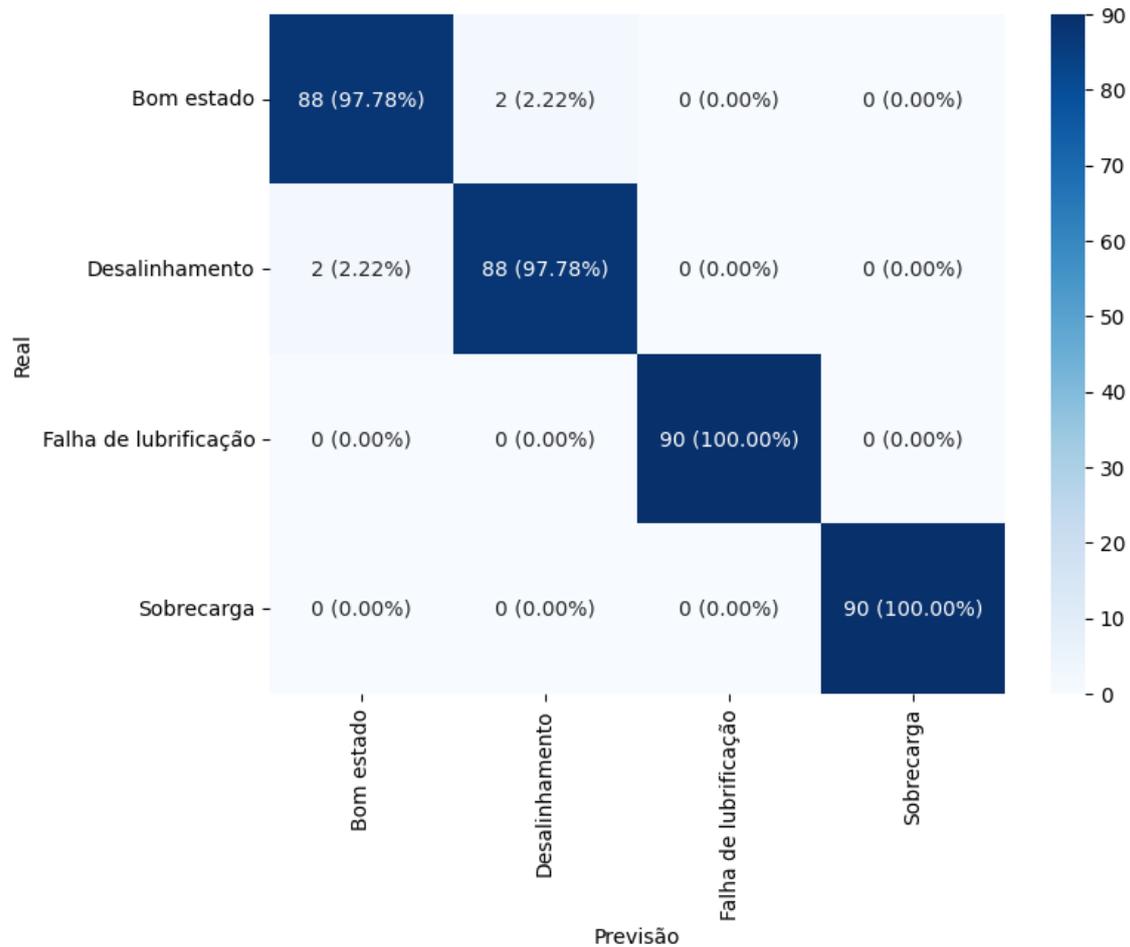
Para avaliar o desempenho das redes neurais artificiais que compõem o sistema de diagnóstico da condição de funcionamento e nível de severidade, foram aplicadas métricas quantitativas. Inicialmente, utilizou-se a matriz de confusão para visualizar as classificações corretas e incorretas realizadas pela rede em cada classe. Métricas como acurácia, precisão, *recall* e *f1-score*, também foram utilizadas. Para validar o modelo foi feito uso do método de validação cruzada. Além disso, para avaliar a convergência do modelo, foi utilizado o gráfico de perda de entropia cruzada ao longo das iterações.

5.6.1 Desempenho da rede neural artificial de classificação de condição de funcionamento

Analisando a matriz de confusão, presente na Figura 88, observa-se que o modelo classificador obteve índice satisfatório de acurácia para as 4 condições: Bom estado (Estado de referência), desalinhamento angular, sobrecarga e lubrificação ineficiente. A classe bom estado e desalinhamento angular, apresentaram uma pequena taxa de erro,

com duas amostras de cada uma sendo classificadas de maneira incorreta como pertencente à outra. Duas amostras da condição de bom estado, foram classificadas como desalinhamento angular e vice-versa. A presença dessa baixa taxa de erro na classificação dessas duas condições, bom estado e desalinhamento, indica que o modelo pode ter uma pequena dificuldade em distinguir essas classes quando comparadas com as demais.

Figura 88: Matriz de confusão para classificação da condição de funcionamento.



Fonte: Autor.

Na Tabela 9, são apresentados os indicadores de desempenho para a rede neural de classificação da condição de funcionamento. As métricas de acurácia, precisão, *recall* e *f1-score*, apresentaram valores acima de 98%, acima do proposto inicialmente no estudo.

Tabela 9: Indicadores de desempenho para a rede neural de classificação da condição de funcionamento.

Indicador de desempenho	Valor
Acurácia	98,889%
Precisão	98,889%
Recall	98,889%
F1-score	98,889%

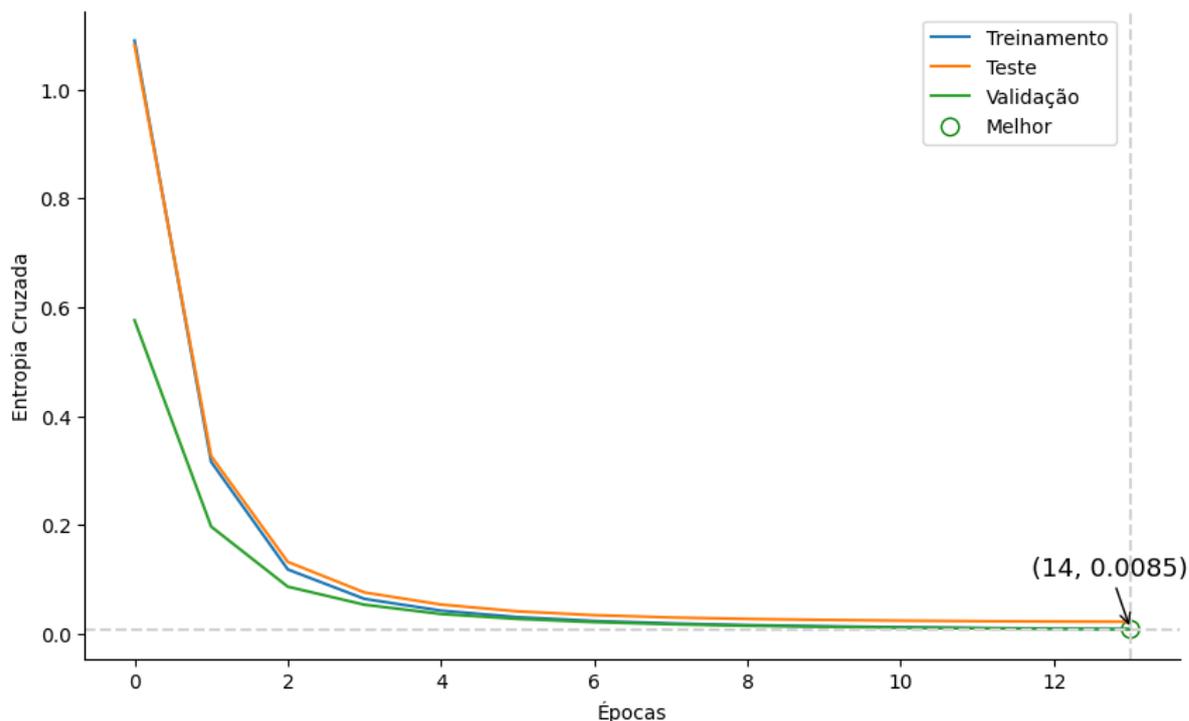
Fonte: Autor

A validação cruzada *k-fold* foi utilizada e obteve-se um valor de acurácia média de 97,738%. De acordo com Brownlee (2019), esse método de validação foi utilizado pois é menos tendencioso, já que cada exemplo do conjunto de dados é usado apenas uma vez no conjunto de teste para estimar o desempenho do modelo, diferentemente das divisões aleatórias de treinamento e teste, onde uma mesma amostra pode ser utilizada várias vezes para avaliar um modelo. O valor de 97,738% de acurácia média alcançado, indica que o modelo generaliza bem para novos dados.

O objetivo de um modelo de aprendizado é atingir um bom ajuste, que representa o equilíbrio entre o *overfitting* e *underfitting*. Esse bom ajuste ocorre quando as perdas nos conjuntos de treinamento e validação reduzem de maneira progressiva até atingirem um ponto de estabilidade, com uma pequena diferença entre os valores finais das perdas em ambos os conjuntos. Geralmente, a perda no conjunto de treinamento tende a ser ligeiramente menor que no conjunto de validação, ocasionando um pequeno desvio entre as curvas, conhecido como intervalo de generalização. Um modelo com bom ajuste é caracterizado por uma curva de perda de treinamento que estabiliza após uma fase decrescente, enquanto a curva de perda de validação também se estabiliza, apresentando apenas uma pequena diferença em relação à curva de treinamento (BROWNLEE, 2019).

Observa-se, na Figura 89, a perda de entropia cruzada ao longo das iterações para o modelo de classificação da condição de funcionamento, nela tanto a curva de perda de treinamento quanto de validação e teste apresentaram exatamente o mesmo comportamento descrito para um modelo com bom ajuste: a curva de treinamento se estabilizou após um período de redução, enquanto as curvas de teste e validação acompanharam essa tendência, mantendo uma pequena diferença em relação à de treinamento, caracterizando o intervalo de generalização e indicando bom ajuste. O melhor valor da entropia cruzada foi 0,0085 obtido na época 14.

Figura 89: Perda de Entropia cruzada ao longo das iterações para rede neural de classificação da condição de funcionamento.



Fonte: Autor

Na Tabela 10, são apresentadas outras configurações que foram avaliadas para definição do número de neurônios da camada oculta. Em verde está a configuração escolhida.

Tabela 10: Avaliação da quantidade de neurônios na camada oculta no desempenho da rede neural da condição de funcionamento

Número de neurônios na camada oculta	Acurácia	Validação cruzada
5	98,611%	74,643%
10	98,889%	95,000%
15	98,889%	97,738%
20	99,167%	94,286%

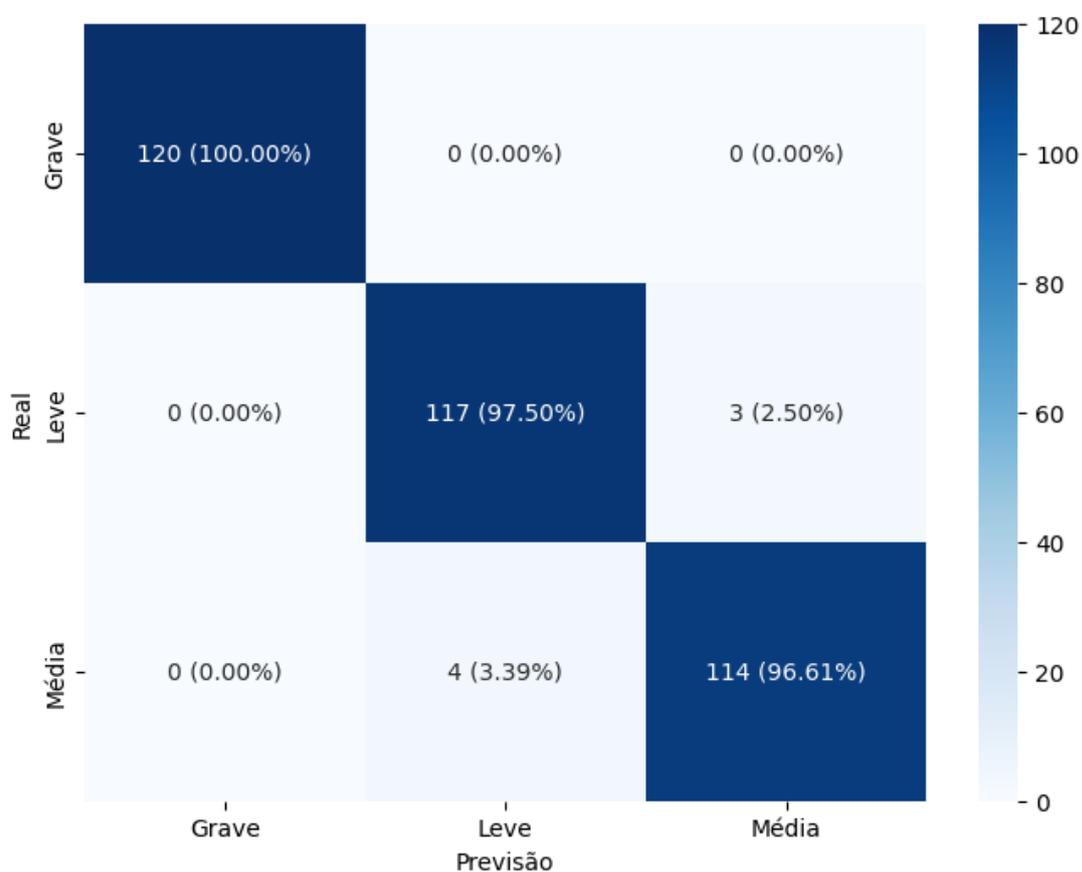
Fonte: Autor

5.6.2 Desempenho da rede neural artificial de classificação do nível de severidade

Avaliando o desempenho da rede neural para classificação dos níveis de severidade (leve, média ou grave), observa-se na Figura 90 a matriz de confusão, onde é possível

notar que para o nível de severidade Grave, o modelo acertou todas as 120 amostras, alcançando, portanto, 100% de acerto. Para o caso de severidade leve, 117 amostras foram classificadas corretamente, enquanto 3 foram incorretamente atribuídas à classe média, resultando em uma taxa de acerto de aproximadamente 97,5%. Avaliando o caso de severidade média, o modelo classificou corretamente 114 amostras, com 4 erros, onde essas amostras foram identificadas incorretamente como leve, levando a uma taxa de acerto de cerca de 96,61%. De forma geral, o modelo apresenta alta acurácia em todas as classes, com alta performance na classificação para os casos de severidade Grave e pequena taxa de erro na classificação para severidade leve e média.

Figura 90: Matriz de confusão para classificação do nível de severidade



Fonte: Autor

A Tabela 11 apresenta os indicadores de desempenho da rede neural para a classificação do nível de severidade. As métricas de acurácia, precisão, recall e *f1-score* alcançaram valores superiores a 98%, superando as metas estabelecidas inicialmente no estudo.

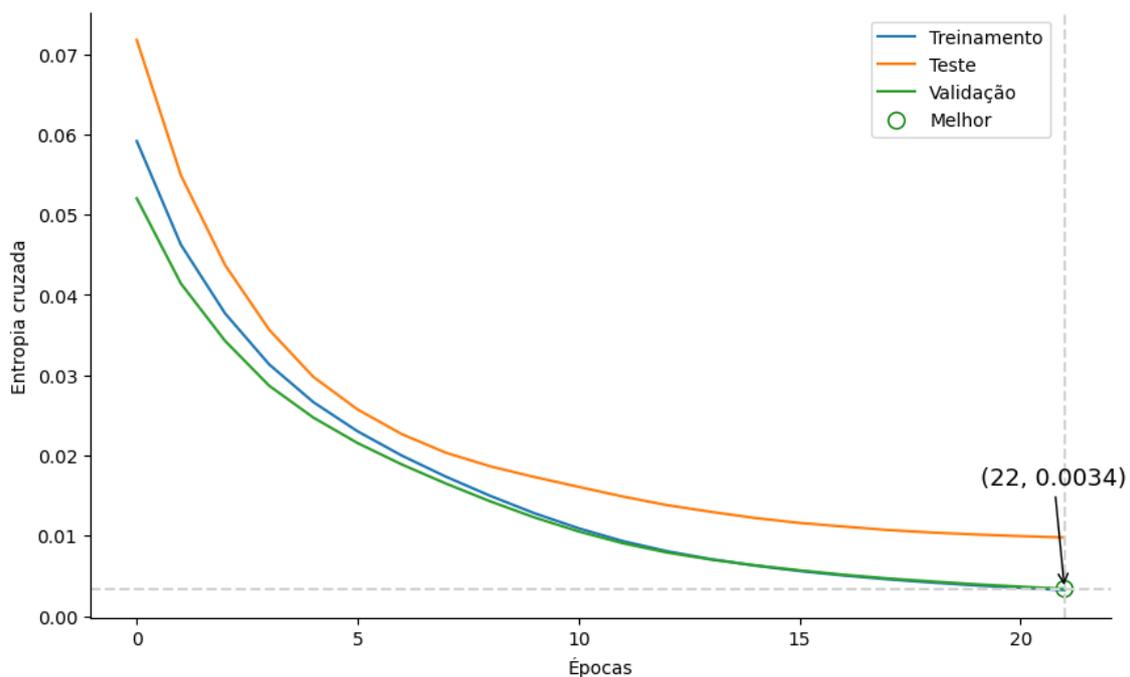
Tabela 11: Indicadores de desempenho para a rede neural de classificação de severidade

Indicador de desempenho	Valor
Acurácia	98,045%
Precisão	98,047%
Recall	98,045%
F1-score	98,044%

Fonte: Autor

A validação cruzada *k-fold* foi aplicada e obteve-se um valor de acurácia média de 97,403%. Esse resultado mostra que o modelo generaliza bem novos dados. Na Figura 91, é possível observar a evolução da perda de entropia cruzada ao longo das interações para a rede neural de classificação da severidade. Tanto as curvas de treinamento quanto de validação e teste, apresentaram um comportamento típico de um modelo bem ajustado, como já descrito nesta seção: a curva de treinamento se estabilizou após um período de redução, enquanto as de validação e teste seguiram a mesma tendência, mantendo uma pequena diferença em relação a curva de treinamento. O melhor valor de entropia cruzada, 0,0034, foi alcançado na época 22.

Figura 91: Perda de Entropia cruzada ao longo das iterações para rede neural de classificação da severidade



Fonte: Autor

Na Tabela 12, são apresentadas outras configurações que foram avaliadas para definição do número de neurônios da camada oculta. Em verde está a configuração escolhida.

Tabela 12: Avaliação da quantidade de neurônios na camada oculta no desempenho da rede neural de severidade

Número de neurônios na camada oculta	Acurácia	Validação cruzada
5	95,531%	70,833%
10	93,575%	91,870%
15	98,045%	97,403%
20	99,162%	97,232%

Fonte: Autor

6 CONCLUSÃO

Neste trabalho, foi desenvolvida uma bancada experimental para avaliar diferentes condições de funcionamento para o redutor coroa sem fim, incluindo o estado de referência, desalinhamento, sobrecarga e lubrificação ineficiente em vários níveis de severidade. Os sistemas de aquisição de dados, tanto para viração quanto para sinais sonoros, atenderam satisfatoriamente às expectativas, permitindo validar a construção da bancada e a análise comparativa entre as análises de vibração e sonora.

A análise dos dados de vibração foi realizada no domínio da frequência, enquanto os sinais sonoros foram avaliados por meio do domínio da frequência aplicando a transformada rápida de Fourier (FFT), domínio tempo – frequência através da transformada de Wavelet e no domínio do tempo através das seguintes técnicas estatísticas: curtose, RMS e fator de crista. Essas análises permitiram a definição de parâmetros característicos para cada condição de operação, sendo utilizadas posteriormente como entradas para o sistema de diagnóstico inteligente.

O sistema de diagnóstico foi composto por duas redes neurais artificiais: uma destinada para a classificação da condição de funcionamento e outra para classificação do nível de severidade (leve, média e grave). A saída dessas duas redes fornece um diagnóstico completo do estado de saúde da máquina. Os resultados acurácia acima do estipulado nos objetivos deste trabalho, onde a RNA para classificação da condição de funcionamento atingiu 98,889% e a de severidade 98,045%.

Para ambas as redes neurais foi aplicada a validação cruzada e construído os gráficos de perda de entropia cruzada ao longo das iterações. A partir dessa etapa de validação verificou-se a ausência de overfitting e underfitting do modelo, tornando-o, portanto, eficaz para diagnosticar as condições operacionais do redutor coroa sem fim. As respostas fornecidas pelo sistema de diagnóstico inteligente podem ser utilizadas para definir a melhor estratégia de manutenção de acordo o estado de equipamento e o melhor momento para intervenção.

6.1 Trabalhos futuros

Abaixo seguem algumas sugestões para trabalhos futuros.

- Integração com IOT para monitoramento em tempo real: Implementar sensores IOT para monitoramento em tempo real das condições de funcionamento;
- Análise das condições de funcionamento variando a velocidade do redutor;
- Uso de redes neurais convolucionais (CNNs) para analisar sinais de vibração e áudio;
- Análise do impacto de diferentes tipos de lubrificantes na resposta vibratória do sistema;
- Análise de falhas em componentes específicos como rolamentos e engrenagens através de RNAs;
- Previsão da vida útil do redutor com base nos sinais sonoros utilizando IA identificando o nível de desgaste;
- Desenvolver modelo que realize a otimização de parâmetros operacionais ideias, como carga e velocidade, para maximizar a vida útil do equipamento;
- Utilizar análise multivariada para detectar anomalias em redutores, combinando dados de vibração, áudio e temperatura com o objetivo de identificar falhas complexas que não são evidentes em análises individuais;
- Identificação de falhas em componentes de redutores com aprendizado não supervisionado;
- Criação de sistema de alerta para substituição de lubrificante com base nos dados de vibração ou sinais sonoros;
- Identificação de contaminação do óleo lubrificante nos redutores através da análise de vibração e som;
- Submeter o protótipo a análise em ambiente com poluição sonora;
- Avaliação de sistemas rotativos sob combinação de várias condições de funcionamento.

7 REFERÊNCIAS

ABIDI, M. H.; MOHAMMED, M. K.; ALKHALEFAH, H. Predictive Maintenance Planning for Industry 4.0 Using Machine Learning for Sustainable Manufacturing. *Sustainability (Switzerland)*, v. 14, n. 6, 1 mar. 2022. Disponível em: <<https://www.mdpi.com/2071-1050/14/6/3387>>. Acesso em: 12 ago. 2024

AGRAWAL, Pavan; JAYASWAL, Pratesh. Diagnosis and classifications of bearing faults using artificial neural network and support vector machine. *Journal of The Institution of Engineers (India): Series C*, v. 101, n. 1, p. 61-72, 2020. Disponível em: <https://link.springer.com/article/10.1007/s40032-019-00519-9#citeas>. Acesso em: 9 abr. 2024.

ALMEIDA, Fabrício César Lobato de. Diagnóstico Automático de Falhas em Grupos Geradores Hidroelétricos Utilizando Técnicas Preditivas de Manutenção e Redes Neurais Artificiais. 2008. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual Paulista, Ilha Solteira - SP, 2008. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/412d821a-45ca-45ce-b7fc-8afa84c23ebb/content>. Acesso em: 22 ago. 2024.

ALMEIDA, LUIS FERNANDO DE. “Redes Neurais Artificiais Aplicadas À Manutenção Baseada Na Condição”. 2011. Tese (Doutor em Engenharia Mecânica na área de Projetos e Materiais) - Universidade Estadual Paulista, Guaratinguetá - SP, 2011. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/25d0f775-d8f7-4ada-87e6-2cfa7d9b9a2c/content>. Acesso em: 3 set. 2024.

AQUINO, Marcelo Braz de. Detecção da Condição de Rubbing em Máquinas Rotativas Através da Transformada Wavelet. 2008. Tese (Doutor em Engenharia Mecânica.) - UNIVERSIDADE ESTADUAL DE CAMPINAS, Campinas - SP, 2008. Disponível em: <https://core.ac.uk/download/pdf/296895951.pdf>. Acesso em: 5 set. 2024.

ARATO, A. J. Manutenção preditiva usando análise de vibrações. Barueri: Manole, 2004.

ARAÚJO, Rodrigo. Análise de falha aplicada a redutores de velocidade com perda de lubrificante por vazamento. 2011. Monografia (MBA Gestão Estratégica em Manutenção, Produção e Negócios) - Rede Pitágoras de Ensino / ICAP, São João Del Rei, 2011. Disponível em: http://www.icap.com.br/biblioteca/165350010212_Monografia_Rodrigo_Araujo.pdf. Acesso em: 26 fev. 2024.

AMARNATH, M.; SUGUMARAN, V.; KUMAR, Hemantha. Exploiting sound signals for fault diagnosis of bearings using decision tree. *Measurement*, v. 46, n. 3, p. 1250-1256, 2013. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0263224112004320?via%3Dihub>. Acesso em: 20 fev. 2024.

Associação brasileira de normas técnicas. NBR 5462: Confiabilidade e Manutenibilidade. Rio de Janeiro, 1994.

AZEVEDO, Robson da Silva. “Desenvolvimento de uma ferramenta virtual para detecção e análise de desbalanceamento em simulador de máquina rotativa”. 2017. Monografia (Graduação em Engenharia Automotiva) - Universidade de Brasília, Brasília, 2017. Disponível em: https://bdm.unb.br/bitstream/10483/19747/1/2017_RobsonDaSilvaAzevedo_tcc.pdf. Acesso em: 2 set. 2024.

BANKS, Jeffrey C.; REICHARD, Karl M.; BROUGHT, Mark S. Lubrication level diagnostics using vibration analysis. In: 2004 IEEE Aerospace Conference Proceedings (IEEE Cat. No. 04TH8720). IEEE, 2004. p. 3528-3534.

BARBOSA, Jorge Diamantino Moreira. Manutenção preditiva com recurso a Inteligência Artificial. 2023. Dissertação (Mestrado Integrado em Engenharia Eletrotécnica e de Computadores) - Faculdade de Ciências e Tecnologias da Universidade de Coimbra, Coimbra, 2023. Disponível em: https://estudogeral.uc.pt/retrieve/269443/Dissertac%CC%A7a%CC%83o_JB.pdf. Acesso em: 31 jul. 2024.

BARSHIKAR, Raghavendra R.; BAVISKAR, Prasad R. Evaluation of performance of vibration signatures for condition monitoring of worm gearbox by using ANN. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, p. 1-14, 2023. Disponível em: <https://link.springer.com/article/10.1007/s12008-023-01268-x>. Acesso em: 12 abr. 2024.

BAYDAR, N.; BALL, Andrew. Detection of gear failures via vibration and acoustic signals using wavelet transform. *Mechanical Systems and Signal Processing*, v. 17, n. 4, p. 787-804, 2003. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0888327001914359>. Acesso em: 25 ago. 2024.

BELLI NETO, Olympio. Desenvolvimento de um Pacote para a Diagnose de Máquinas Rotativas a partir de Vibrações Mecânicas e Análise Bayesiana. 2023. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual de Campinas, Campinas - SP, 2023. Disponível em: <https://unicamp.br/unicamp/teses/2023/02/27/desenvolvimento-de-um-pacote-para-diagnose-de-maquinas-rotativas-partir-de/>. Acesso em: 9 set. 2024.

BEZERRA, Roberto de Araujo. Detecção de falhas em rolamentos por análise de vibração. 2004. 150p. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP. Disponível em: <https://hdl.handle.net/20.500.12733/1599538>. Acesso em: 20 out. 2024.

BROWNLEE, J. Better deep learning: Train faster, reduce overfitting and make better predictions. 2019.

BUDYNAS, Richard; NISBETT, J K. Elementos de máquinas de Shigley. Porto Alegre: Grupo A, 2016. E-book. ISBN 9788580555554. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788580555554/>. Acesso em: 12 ago. 2024.

CARRETEIRO, R; BELMIRO, P. Lubrificantes & Lubrificação Industrial. Ed. Rio de Janeiro: Interciência Ltda, 2006.

CARVAJAL, Ricardo Enrique Gutiérrez. Sobre Técnicas para Manutenção e Diagnóstico Inteligente de Sistemas Mecatrônicos. Estudo de Caso utilizando Cálculo de Ordem Fracionária. 2011. Tese (Doutor em Engenharia Mecânica) - Universidade Estadual de Campinas, Campinas - SP, 2011. Disponível em: <https://repositorio.unicamp.br/acervo/detalhe/837130>. Acesso em: 5 set. 2024.

CHEN, Renxiang et al. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform. *Computers in industry*, v. 106, p. 48-59, 2019. Disponível em: https://www.sciencedirect.com/science/article/pii/S0166361518305244?casa_token=mVbTYXBx-NsAAAAA:tDZ3o9MIh19gqrxV_eEguE21ZTaJrECzj7AOl-2Q3FS2t-HGDU6MM5cKp6y-u8As0ESqaDKIu2wE. Acesso em: 10 maio 2024.

CHUI, C. K. *Wavelet Analysis and Its Applications*, Vol. 1: An Introduction to Wavelets. Boston, Academic Press, 1992.

CUNHA, Rodrigo Carvalho. Análise do estado de conservação de um redutor de velocidade através da técnica de partículas de desgaste no óleo lubrificante auxiliada pela análise de vibrações. 2005. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual Paulista, Ilha Solteira - SP, 2005. Disponível em: https://www.feis.unesp.br/Home/departamentos/engenhariamecanica/pos-graduacao/dissertacao_rccunha.pdf. Acesso em: 28 jul. 2024.

CURY, Hachid Habib. “Implementação de uma FFT em FPGA para processamento de sinais phase-OTDR aplicado em sensores de aceleração distribuídos”. 2021. Monografia (Graduação em Engenharia Eletrônica) - Universidade de Brasília, Brasília, 2021. Disponível em: https://bdm.unb.br/bitstream/10483/32224/1/2021_HachidHabidCury_tcc.pdf. Acesso em: 1 set. 2024

DAUBECHIES, I. “Ten Lectures on Wavelets”. Philadelphia: SIAM Books, 1992, page 357.

DAUBECHIES, I. Orthonormal Bases of Compactly Supported Wavelets. *Comm. Pure Appl. Math.* v.41, pp. 909-996, 1988.

DIAS, A. L. Diagnóstico de anomalias em aplicações de acionamento de motores elétricos a partir de dados de processo de redes PROFINET e aprendizagem de máquinas. 2019. Tese (Doutor em Ciências - Programa de Pós-Graduação em Engenharia Elétrica) - Universidade de São Paulo, 2019. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18153/tde-10092019-104345/publico/Andre.pdf>. Acesso em: 5 set. 2024.

DIAS, Ariangelo Hauer; MATHIAS, Ivo Mário; VIRGENS FILHO, Jorim Sousa das; RICKLI, Leila Issa. Aplicação de redes neurais artificiais de topologia mlp em simulação de dados radiométricos. *Revista Brasileira de Agrocomputação: p.*, Dec.2007, Ponta Grossa-PR, v. v.2, ed. n.2, p. 5-11, 11 out. 2007. Disponível em: https://www.researchgate.net/profile/Jorim-Virgens-Filho/publication/259763406_APPLICATION_OF_ARTIFICIAL_NEURALS_NETWORKS_OF_MLP_TOPOLOGY_IN_SIMULATION_OF_RADIOMETRICS_DATA/links/0deec52dc41454deb2000000/APPLICATION-OF-ARTIFICIAL-NEURALS-NETWORKS-OF-MLP-TOPOLOGY-IN-SIMULATION-OF-RADIOMETRICS-DATA.pdf. Acesso em: 10 set. 2024

DINIZ, Paulo S R.; SILVA, Eduardo A B.; NETTO, Sergio L. Processamento digital de sinais. Porto Alegre: Grupo A, 2014. E-book. ISBN 9788582601242. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788582601242/>. Acesso em: 19 set. 2024.

DUBE, Anupkumar; JAYBHAYE, M. D. Condition Monitoring of a Worm Gearbox Under Dynamic Loading Condition. *Advances in Lightweight Materials and Structures*, [S. l.], v. 8, p. 505–512, 15 out. 2020. DOI 10.1007/978-981-15-7827-4_51. Disponível em: https://link.springer.com/chapter/10.1007/978-981-15-7827-4_51#citeas. Acesso em: 9 abr. 2024.

DynaLogger HF+s PO (DynaPortable). Dynamox, 2023. Disponível em: <https://content.support.dynamox.net/wp-content/uploads/2023/07/HFSpo-PT.pdf>.

Acesso em: Acesso em: 1 mar. 2024

FAGUNDES DA SILVA, Ademar. Redutor de velocidades com solução anti-backlash. 2019. Dissertação (Mestre em Mecatrônica) - Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina, Florianópolis, 2019. Disponível em: <https://repositorio.ifsc.edu.br/bitstream/handle/123456789/1073/Disserta%C3%A7%C3%A3o%20Ademar.pdf?sequence=1>. Acesso em: 1 ago. 2024.

FELIX, Leonardo Oldani. Detecção de falhas em caixas de engrenagens utilizando machine learning. 2023. Dissertação (Mestre em Engenharia Oceânica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2023. Disponível em: https://w1files.solucaoatrio.net.br/atrio/ufrj-peno_upl/THESIS/10004108/leonardo_oldani_felix_dissertao_20240322224629877.pdf. Acesso em: 26 ago. 2024.

FENG, Ke et al. A review of vibration-based gear wear monitoring and prediction techniques. *Mechanical Systems and Signal Processing*, v. 182, p. 109605, 2023. Disponível em: https://www.sciencedirect.com/science/article/pii/S0888327022006951?casa_token=piN0sqK0Qe4AAAAA:76noKrjrED2D9GE_6TxIM43_QcS0UiMttvIH6Lqs5IHnwL4tnd8EK2JTSajZtH_xE63TOEaEQs. Acesso em: 29 ago. 2024.

Figueirêdo, Ilan sousa. Uma nova abordagem de inteligência artificial baseada em autoaprendizagem profunda para manutenção preditiva em um ambiente de produção de petróleo e gás offshore. 2023. Tese (Doutorado em Modelagem Computacional e Tecnologia Industrial) - Centro Universitário SENAI CIMATEC, [S. l.], 2023. Disponível em: <http://repositoriosenaiba.fieb.org.br/handle/fieb/1730>. Acesso em: 28 fev. 2024.

GARDNER M.W. GARDNER, DORLING S.R.,1998. “Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences”. *Science Direct*.

O que é um redutor de velocidade? [S. l.], 11 ago. 2017. Disponível em: <https://www.globalreduutores.com.br/13-o-que-e-um-redutor-de-velocidade>. Acesso em: 15 maio 2024.

GLOWACZ, A. Acoustic-based fault diagnosis of commutator motor. *Electronics (Switzerland)*, v. 7, n. 11, 2018. Disponível em: <https://www.mdpi.com/2079-9292/7/11/299>. Acesso em: 9 jul. 2024.

GOSWAMI, Priyom; RAI, Rajiv Nandan. A systematic review on failure modes and proposed methodology to artificially seed faults for promoting PHM studies in laboratory environment for an industrial gearbox. *Engineering Failure Analysis*, v. 146, p. 107076, 2023. Disponível em: https://www.sciencedirect.com/science/article/pii/S1350630723000304?casa_token=prghENmKHssAAAAA:WZcqcznifSQzuSheif5AleV7eqHrSSgBrO_OVpCYZyEl1ni91xGjVkJVkoUgoK_QapOI2arzJfiXVX-. Acesso em: 9 abr. 2024.

GUPTA, Niharika et al. Tribological and vibration studies of textured spur gear pairs under fully flooded and starved lubrication conditions. *Tribology Transactions*, v. 63, n. 6, p. 1103-1120, 2020. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10402004.2020.1794093>. Acesso em: 9 ago. 2024.

HAYKIN, S. *Redes Neurais: Princípios e Prática*. Disponível em: Minha Biblioteca, (2nd edição). Grupo A, 2007.

HAYKIN, S. *Neural Networks and Learning Machines*, 3 ed., Pearson, Hamilton, Canadá, 2009

HAYKIN, S. S.; VEEN, B. V. *Sinais e sistemas*. [S.l.]: Bookman, 2001.

HAYT, W.; KERMMERLY, J.; DURBIN, S. *Análise de Circuitos em Engenharia*; Mc Graw Hill: New York, NY, USA, 2014.

HEYDARZADEH, M. et al. Gear fault diagnosis using discrete wavelet transform and deep neural networks. IECON Proceedings (Industrial Electronics Conference), p. 1494–1500, 2016. Disponível em: <https://ieeexplore.ieee.org/document/7793549>. Acesso em: 9 jul. 2024.

HOLANDA, Sandra Maria Santos. Aplicação da manutenção preditiva por análise de vibrações em equipamentos de trens urbanos com plano de manutenção proposto. 2016. Dissertação (Mestre em Engenharia Mecânica) - Universidade Federal de Pernambuco, Recife - PE, 2016. Disponível em: <https://repositorio.ufpe.br/bitstream/123456789/17606/1/Disserta%0c3%a7%0c3%a3o%20Sandra%20Holanda%20IMPRESS%0c3%83O%20FINAL%2029ABR3.pdf>. Acesso em: 6 ago. 2024.

InvenSense. MPU-6000 and MPU-6050 Product Specification Revision 3.4, 2013. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2015/02/MPU-6000-Datasheet1.pdf>. Acesso em: 30 maio 2024.

IRMÃO, Marcos Antonio Da Silva. Comparação de representações conjuntas tempo-frequência aplicadas na análise de falhas em sistemas engrenados. 2002. Dissertação (Mestre em Engenharia Mecânica) - Universidade Federal da Paraíba, Campina Grande - PB, 2002. Disponível em: https://bdtd.ibict.br/vufind/Record/UFCG_8c031dba5f956cbf1305a643f96e5be0. Acesso em: 3 set. 2024.

ISMON, Maznan Bin; ZAMAN, Izzuddin Bin; GHAZALI, Mohd Imran. Condition Monitoring of Variable Speed Worm Gearbox Lubricated with Different Viscosity Oils. Applied Mechanics and Materials, [S. l.], v. 773-774, p. 178-182, 31 jul. 2015. DOI 10.4028/www.scientific.net/amm.773-774.178. Disponível em: <https://www.scientific.net/AMM.773-774.178>. Acesso em: 7 maio 2024.

JING, Luyang et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. Measurement, v. 111, p. 1-10, 2017. Disponível em: https://www.sciencedirect.com/science/article/pii/S0263224117304517?casa_token=YIM3PCu

TN9sAAAAA:U0R68JLGj-

zim_nzM112NUFDQFR7mIUyuzZk3e4nPNXitKx2Va5kuuEpu5RWTqLX9dcnJmHvTE. Acesso em: 3 agosto de 2024.

KARABACAK, Y. E.; GÜRSEL ÖZMEN, N.; GÜMÜŞEL, L. Intelligent worm gearbox fault diagnosis under various working conditions using vibration. Sound and Thermal featuresApplied Acoustics, 2022. Disponível em: https://www.sciencedirect.com/science/article/pii/S0003682X21005570?casa_token=m3NuoJbb4IwAAAAA:1-sSf8e2K-Cf7etBwex7cJVygmtAZ79LR0BHyO-SD0fbA7U9v6Si1oUmCjHg0CzYjX9nPWXzbhUX. Acesso em: 9 abr. 2024.

KARDEC, A.; NASCIF, J. Manutenção: Função estratégica. 3ª edição, Editora Qualitymark, Rio de Janeiro, 2010.

KHAN, Muhammad Ali et al. Gear misalignment diagnosis using statistical features of vibration and airborne sound spectrums. Measurement, v. 145, p. 419-435, 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263224119305329>. Acesso em: 29 jul. 2024.

KHAZAEI, M. et al. Feature-level fusion based on wavelet transform and artificial neural network for fault diagnosis of planetary gearbox using acoustic and vibration signals. Insight: Non-Destructive Testing and Condition Monitoring, v. 55, n. 6, p. 323–330, 2013.

KIRANYAZ, Serkan et al. Exploring Sound vs Vibration for Robust Fault Detection on Rotating Machinery. IEEE Sensors Journal, 2024. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10546956>. Acesso em: 10 nov. 2024.

LAGO, Daniel Fabiano. Manutenção de redutores de velocidade pela integração das técnicas preditivas de análise de vibrações e análise de óleo lubrificante. 2007. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual Paulista, Ilha Solteira - SP, 2007. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/4fb7e142-5da7-46cb-9510-9305863c493c/content>. Acesso em: 29 jul. 2024.

LEE, J.; LAPIRA, E.; YANG, S.; KAO, A. Predictive Manufacturing System - Trends of Next-Generation Production Systems. IFAC Proceedings Volumes, v. 46, n. 7, p. 150–156, 1 maio 2013. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1474667015356664>>. Acesso em: 12 ago. 2024

LEITE, Juarez Antonio. Bancada multifuncional para simulação de mecanismos de falhas em máquinas. 2012. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual Paulista, Guaratinguetá - SP, 2012. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/c4533af6-006d-4305-8aca-5e0038fc4aeb/content>. Acesso em: 3 set. 2024.

LIMA, Isaías. Inteligência Artificial. Rio de Janeiro: Grupo GEN, 2014. E-book. ISBN 9788595152724. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595152724/>. Acesso em: 10 set. 2024.

LIU, Chenyu et al. Vibration-based gear continuous generating grinding fault classification and interpretation with deep convolutional neural network. Journal of Manufacturing Processes, v. 79, p. 688-704, 2022. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1526612522003000>. Acesso em: 10 maio 2024.

LIU, Ruonan et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. Mechanical Systems and Signal Processing, v. 108, p. 33-47, 2018. Disponível em: https://www.sciencedirect.com/science/article/pii/S0888327018300748?casa_token=nFCLlgMhqKQAAAAA:RtJG-dH5_N4wdrbQppqTNQ4jwE2aNysyqDUTV9bE7bFwkLN16fJuemBwzCIfquEW7R3OzS_6qRQ. Acesso em: 10 maio 2024.

LOPO DE CARVALHO, Duarte Maria d'Orey Manoel. Diagnóstico de falhas, utilizando a análise de vibração e a termografia. 2023. Dissertação (Mestrado em Engenharia de Máquinas Marítimas) - ESCOLA SUPERIOR NÁUTICA INFANTE D. HENRIQUE DEPARTAMENTO DE ENGENHARIA MARÍTIMA, [S. l.], 2023. Disponível em: <https://comum.rcaap.pt/bitstream/10400.26/48885/1/Duarte%20Maria%20d%27Orey%20Lopo%20Carvalho.pdf>. Acesso em: 6 ago. 2024.

MARÇAL, Rui Francisco Martins. Um método para detectar falhas incipientes em máquinas rotativas baseado em análise de vibrações e lógica fuzzy. 2000. Tese (Doutor em Engenharia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/1969/000362586.pdf?sequence=1>. Acesso em: 27 ago. 2024.

MARQUES, Luís Filipe Santos. Desenvolvimento de algoritmos para monitorização da condição de operação de máquinas: aplicação à previsão de falha de rolamentos de aeronaves. 2019. Dissertação (Mestre em Engenharia Física) - Universidade de Coimbra, Coimbra, 2019. Disponível em: https://estudogeral.uc.pt/bitstream/10316/88091/1/Disserta%c3%a7%c3%a3oMestrado_LuisMarques.pdf. Acesso em: 6 set. 2024.

MAURO SÁ. (2000). Curso de Vibrações. Apostila.

MECHEFSKE, Chris K.; JIN, Chenyi. Experimental study of worm gearbox faults using acoustic emission signals. In: International Symposium on Space Flight Dynamics (27th: 2019: Melbourne, Vic.). Melbourne: Engineers Australia, Royal Aeronautical Society., 2019. p. 867-875. Disponível em: https://www.humsconference.com.au/Papers2019/Peer_Reviewed/HUMS2019_Mechefske-2.pdf. Acesso em: 10 maio 2024.

MELCONIAN, Sarkis. Elementos de máquinas. Rio de Janeiro: Grupo GEN, 2019. E-book. ISBN 9788536530420. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788536530420/>. Acesso em: 12 ago. 2024.

MELO, Jônata Ferreira de. Desenvolvimento de técnica de predição de defeitos em máquinas rotativas por meio de redes neurais artificiais. 2018. Tese (Doutor em Engenharia Mecânica) - Universidade Federal de Pernambuco, Recife - PE, 2018. Disponível em:

<https://repositorio.ufpe.br/bitstream/123456789/32494/1/TESE%20J%c3%b4nata%20Ferreira%20de%20Melo.pdf>. Acesso em: 15 ago. 2024.

MISITI, M., MISITI, Y., OPPENHEIN, G., POGGI, J.-M. Wavelet Toolbox – User’s Guide. The MathWorks, Inc. 2004.

MOUBRAY, J. Reliability-centered maintenance: second edition. 2^a. ed. New York: Industrial Press Inc., 1997.

NAKAMURA, Hisahide et al. A diagnosis method of bearing and stator fault in motor using rotating sound based on deep learning. *Energies*, v. 14, n. 5, p. 1319, 2021. Disponível em: <https://www.mdpi.com/1996-1073/14/5/1319>. Acesso em: 10 nov. 2024.

NASCIMENTO, Erick Giovani Sperandio. Um Algoritmo Baseado em Técnicas de Agrupamento para Detecção de Anomalias em Séries Temporais Utilizando a Distância de Mahalanobis. 2012. Dissertação (Mestre) - Universidade Federal do Espírito Santo, Vitória - ES, 2012. Disponível em: https://sappg.ufes.br/tese_drupal//tese_5950_.pdf. Acesso em: 25 set. 2024.

NATH, Aneesh G.; UDMALE, Sandeep S.; SINGH, Sanjay Kumar. Role of artificial intelligence in rotor fault diagnosis: A comprehensive review. *Artificial Intelligence Review*, v. 54, p. 2609-2668, 2021. Disponível em: <https://link.springer.com/article/10.1007/s10462-020-09910-w>. Acesso em: 28 maio. 2024.

NEPOMUCENO, Lauro X. Técnicas de manutenção preditiva, vol. 1. São Paulo: Editora Blucher, 1989. E-book. ISBN 9788521217466. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788521217466/>. Acesso em: 04 out. 2024.

NGUYEN, Trong-Du; NGUYEN, Phong-Dien. Improvements in the Wavelet Transform and Its Variations: Concepts and Applications in Diagnosing Gearbox in Non-Stationary Conditions. *Applied Sciences*, v. 14, n. 11, p. 4642, 2024. Disponível em: <https://www.mdpi.com/2076-3417/14/11/4642>. Acesso em: 12 ago. 2024.

NIEMANN, Gustav. Elementos de máquinas Vol. 3. São Paulo: Editora Blucher, 1971. E-book. ISBN 9788521214274. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788521214274/>. Acesso em: 12 ago. 2024.

NÓBREGA SOBRINHO, Carlos Alberto. Estudo comparativo de técnicas para Diagnóstico de falhas em motores de Indução trifásicos. 2015. Tese (Doutor em Engenharia Mecânica) - Universidade Federal da Paraíba, João Pessoa - PB, 2015. Disponível em: https://repositorio.ufpb.br/jspui/handle/tede/8958?locale=pt_BR. Acesso em: 30 ago. 2024.

NORTON, Robert L. Projeto de máquinas. Porto Alegre: Grupo A, 2013. E-book. ISBN 9788582600238. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788582600238/>. Acesso em: 12 ago. 2024.

NUNES, P.; SANTOS, J.; ROCHA, E. Challenges in predictive maintenance – A review. CIRP Journal of Manufacturing Science and Technology Elsevier Ltd, 1 fev. 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1755581722001742#bbib6>.

OLIVEIRA, H. M. DE. Análise de Fourier e Análise Wavelet: Sinais estacionários e não Estacionários. Recife: Editora Universitária, UFPE 2007.

OLIVEIRA NETO, J. M. DE et al. Viabilidade da aplicação da transformada de Wavelet (DWT) com vistas a detectar condições de desalinhamento angular em um par engrenado através da análise sonora. Capítulo 9. 1. ed. Belo Horizonte: Poisson, 2019.

OLIVEIRA NETO, J. M. D. Desenvolvimento de um sistema inteligente de monitoramento prescritivo para severidade das condições de funcionamento de um redutor do tipo coroa sem-fim. Orientador: Dr. Marcelo Cavalcanti Rodrigues. 2023. Tese (Doutor em Engenharia Mecânica) - Universidade Federal da Paraíba, João Pessoa, 2023.

Disponível em: <https://repositorio.ufpb.br/jspui/handle/123456789/30202>. Acesso em: 13 ago. 2024.

OPPENHEIM, A.; SCHAFER, R. Processamento Em Tempo Discreto De Sinais. PEARSON BRASIL, 2013.

OPPENHEIM, A.; WILLSKY, A.; NAWAB, S. Sinais e sistemas. Prentice-Hall, 2010.

OLSON, David L.; DELEN, Dursun. Advanced Data Mining Techniques. [S. l.]: Springer, 2008. ISBN 978-3-540-76916-3.

OSHA. Manual Técnico da OSHA Section III : Chapter 5, 2013.

PADOVANI NETO, Fábio Casale. Aplicação de redes neurais na proteção de sistemas de distribuição ativos. 2019. Dissertação (Mestre em Engenharia Elétrica) - Instituto Alberto Luiz Coimbra De Pós-Graduação e Pesquisa De Engenharia (Coppe) Da Universidade Federal Do Rio De Janeiro, [S. l.], 2019. Disponível em: http://www.coep.ufrj.br/~tarang/Simulight/Dissertacao_Padovani.pdf. Acesso em: 11 set. 2024.

PAREY, A.; SINGH, A. Gearbox fault diagnosis using acoustic signals, continuous wavelet transform and adaptive neuro-fuzzy inference system. Applied Acoustics, v. 147, p. 133–140, 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0003682X18302147>. Acesso em: 2 jul. 2024.

PEREIRA, André Luis Vinagre. Manutenção preditiva de um par engrenado através da análise de lubrificantes e da análise de vibrações utilizando a transformada de wavelet. 2018. Dissertação (Mestre em Engenharia Mecânica) - Universidade Estadual Paulista, [S. l.], 2018. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/73c211df-f885-46ab-b76d-fb94cc44414f/content>. Acesso em: 29 fev. 2024

PEREZ, Arturo Garcia; TRONCOSO, Rene J Romero; YEPEZ, Eduardo Cabal; RIOS, Roque A Osornio; MARTINEZ, Jose A Lucio. Application of high-resolution spectral

analysis for identifying faults in induction motors by means of sound. *Journal of Vibration and Control*, [S. l.], ano 2011, v. 18, n. 11, p. 1585-1594, 18 out. 2011. DOI 10.1177/1077546311422925. Disponível em: https://journals.sagepub.com/doi/full/10.1177/1077546311422925?casa_token=LsfkPTUuzRMAAAA%3AInsN1SFSLAa83uULQUhW3-7vStSE4weyMrcPJih2wq3S-qf-ffzWkKRiCnwYiXioxjbJncJVCN003uU. Acesso em: 4 jun. 2024.

PORTO, Ana Carolina. *Processamento digital e análise estatística de sinais de áudio medidos através de dispositivos móveis para a aplicação no monitoramento do torneamento de ligas de titânio*. 2023. Monografia (Bacharelado em Engenharia Mecânica) - Universidade Federal de São Carlos, São Carlos - SP, 2023. Disponível em: https://repositorio.ufscar.br/bitstream/handle/ufscar/20081/TCC_2023-06_AC_Porto.pdf?sequence=1&isAllowed=y. Acesso em: 4 set. 2024.

POZZEBON, Giovani Guarienti. *Transformada Wavelet e Redes Neurais Artificiais na análise de sinais relacionados à qualidade da energia elétrica*. 2009. Dissertação (Mestre em Engenharia Elétrica) - Universidade Federal de Santa Maria, Santa Maria - RS, 2009. Disponível em: <https://repositorio.ufsm.br/bitstream/handle/1/8463/POZZEBON%2c%20GIOVANI%20GUARIENTE.pdf?sequence=1&isAllowed=y>. Acesso em: 26 ago. 2024.

P.V. SRIHARI; K. GOVINDARAJULU; K. RAMACHANDRA. A Method to Improve Reliability of Gearbox Fault Detection with Artificial Neural Networks. *International Journal of Automotive and Mechanical Engineering*, [S. l.], v. 2, p. 221–230, 2022. DOI: 10.15282/ijame.2.2010.10.0018. Disponível em: <https://journal.ump.edu.my/ijame/article/view/8172>. Acesso em: 13 abr. 2024.

RAFIEE, J. et al. Intelligent condition monitoring of a gearbox using artificial neural network. *Mechanical Systems and Signal Processing*, v. 21, n. 4, p. 1746–1754, 2007. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0888327006001750>. Acesso em: 2 jul. 2024.

REIS, Luana Gantert. *Detecção de defeitos em plantas industriais através de características espectrais do som*. 2021. Dissertação (Mestre em Engenharia Elétrica) -

Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2021. Disponível em: <https://www.gta.ufrj.br/ftp/gta/TechReports/Luana21/Luana21.pdf>. Acesso em: 18 set. 2024.

ROBERTS, Michael J. Fundamentos de sinais e sistemas. Porto Alegre: Grupo A, 2009. E-book. ISBN 9788563308573. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788563308573/>. Acesso em: 16 set. 2024.

SAIMURUGAN, M.; RAMPRASAD, R. A dual sensor signal fusion approach for detection of faults in rotating machines. *Journal of Vibration and Control*, v. 24, n. 12, p. 2621-2630, 2018. Disponível em: https://journals.sagepub.com/doi/full/10.1177/1077546316689644?casa_token=1Aby49Kzv8MAAAAA%3ALjjYDYyWI6LUsjLP9IT5RIcSmBfZEQ8975DJ0BfJ2i2LrFhP5JmJSojA9m4pAFymIwhv9qutU1dA9w. Acesso em: 10 nov. 2024.

SANTOS, Rodolfo De Sousa. Detecção de falhas em rolamentos de máquinas rotativas utilizando técnicas de processamentos de sinais. 2017. Tese (Doutor em Engenharia Mecânica) - Universidade Estadual Paulista, Guaratinguetá-SP, 2017. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/3aa704e3-740e-4b68-81ce-55e162d3ca3d/content>. Acesso em: 2 set. 2024.

SANTIAGO, Darley Fiácrio de Arruda. Diagnóstico de Falhas em Máquinas Rotativas Utilizando Transformada de Wavelet e Redes Neurais Artificiais. 2004. Tese (Doutor em Engenharia Mecânica) - UNIVERSIDADE ESTADUAL DE CAMPINAS, Campinas - SP, 2004. Disponível em: <https://repositorio.unicamp.br/Acervo/Detalhe/300659>. Acesso em: 10 set. 2024.

SARAVANAN, N.; RAMACHANDRAN, K. I. Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN). *Expert Systems with Applications*, v. 37, n. 6, p. 4168–4181, 2010. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0957417409009488>. Acesso em: 2 ago. 2024.

SEQUEIRA, Cláudia Dias. A análise de vibrações como ferramenta para a melhoria da manutenção em aerogeradores. Lisboa: Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2012. Disponível em: <https://run.unl.pt/handle/10362/9961>. Acesso em: 15 mar. 2024.

SICSÚ, Abraham L.; SAMARTINI, André; BARTH, Nelson L. Técnicas de machine learning. São Paulo: Editora Blucher, 2023. E-book. ISBN 9786555063974. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786555063974/>. Acesso em: 13 ago. 2024.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. São Paulo: Artliber, 2010.

SHIRDEL, Shahryar et al. A hybrid method based on deep learning and ensemble learning for induction motor fault detection using sound signals. *Multimedia Tools and Applications*, v. 83, n. 18, p. 54311-54329, 2024. Disponível em: <https://link.springer.com/article/10.1007/s11042-023-15996-5>. Acesso em: 9 set. 2024.

SHUBITA, Rashad R.; ALSADEH, Ahmad S.; KHATER, Ismail M. Fault detection in rotating machinery based on sound signal using edge machine learning. *IEEE Access*, v. 11, p. 6665-6672, 2023. Disponível em: <https://ieeexplore.ieee.org/document/10017251?denied=>. Acesso em: 10 set. 2024.

SINGH, Vikas et al. Artificial intelligence application in fault diagnostics of rotating industrial machines: A state-of-the-art review. *Journal of Intelligent Manufacturing*, v. 34, n. 3, p. 931-960, 2023. Disponível em: <https://link.springer.com/article/10.1007/s10845-021-01861-5>. Acesso em: 13 ago. 2024.

SINGLA, Virender; RC, Sharma; SINGH, Jagmail. Fault diagnosis of bearing for wear at inner race using acoustic signal. *International Journal of Mechanical Engineering*

Research and Development (IJMERD), v. 1, n. 1, 2011. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3498923. Acesso em: 13 ago. 2024.

SÓRIA, Bruno Santana. Estudo do comportamento das vibrações em fresamento frontal do aço inoxidável aisi 316 utilizando transformada de wavelet. 2016. Dissertação (Mestre em Engenharia) - UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL, Porto Alegre, 2016. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/152768/001012040.pdf?sequence=1&isAll> owed=y. Acesso em: 9 set. 2024.

SOUZA, Wallace Gabriel De. Identificação de Falhas em Rolamentos Aplicados em Motores de Indução por meio de Sensores de Corrente de Efeito Hall, Técnicas de Processamento de Sinais e Sistemas Inteligentes. 2022. Tese (Doutor em Engenharia Elétrica) - UNIVERSIDADE ESTADUAL PAULISTA, Bauru - SP, 2022. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/7744ed6a-4041-460f-8138-e6d80d26f065/content>. Acesso em: 7 set. 2024.

TANG, Lili et al. A survey of mechanical fault diagnosis based on audio signal analysis. Measurement, p. 113294, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0263224123008588?via%3Dihub>. Acesso em: 21 fev. 2024.

TENG, Wei et al. Vibration analysis for fault detection of wind turbine drivetrains—a comprehensive investigation. Sensors, v. 21, n. 5, p. 1686, 2021. Disponível em: <https://www.mdpi.com/1424-8220/21/5/1686>. Acesso em: 7 set. 2024.

T.P. Carvalho, F.A. Soares, R. Vita, R. da P. Francisco, J.P. Basto, S.G. Alcalá. A systematic literature review of machine learning methods applied to predictive maintenance, Comput. Ind. Eng. 137 (2019) <http://dx.doi.org/10.1016/j.cie.2019.106024>.

VEDAN, A. Lubrificação industrial: tipos de lubrificantes e métodos. Tractian. Disponível em: <https://tractian.com/blog/lubrificacao-industrial-entenda-os-tipos-e-sua-importancia?ref=tractian-1.ghost.io>

VIANA, Carlos Alberto Alves. Método para detecção e monitoramento de falhas em máquinas rotativas utilizando aprendizado profundo e imagens de vibração. 2023. Tese (Doutor em Engenharia Mecânica) - UNIVERSIDADE ESTADUAL DE CAMPINAS, Campinas - SP, 2023. Disponível em: <https://www.repositorio.unicamp.br/acervo/detalhe/1373453>. Acesso em: 3 set. 2024.

VIRGILLITO, Salvatore B. Estatística Aplicada. Rio de Janeiro: Saraiva Uni, 2017. E-book. p.II. ISBN 9788547214753. Disponível em: <https://integrada.minhabiblioteca.com.br/reader/books/9788547214753/>. Acesso em: 29 dez. 2024.

VRBA, Jan et al. A machine learning approach for gearbox system fault diagnosis. *Entropy*, v. 23, n. 9, p. 1130, 2021. Disponível: <https://www.mdpi.com/1099-4300/23/9/1130#B24-entropy-23-01130>. Acesso em: 9 abr. 2024.

WAN, J., Tang, S., LI, D., WANG, S., LIU, C., ABBAS, H., & VASILAKOS, A. V. (2017). A manufacturing big data solution for active preventive maintenance. *IEEE Transactions on Industrial Informatics*, 13, 2039–2047

WANG, W. J.; MCFADDEN, P. D. Application of wavelets to gearbox vibration signals for fault detection. *Journal of sound and vibration*, v. 192, n. 5, p. 927-939, 1996. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0022460X96902266>. Acesso em: 29 dez. 2024.

WAQAR, T.; DEMETGUL, M. Thermal analysis MLP neural network based fault diagnosis on worm gears. *Measurement: Journal of the International Measurement Confederation*, v. 86, p. 56–66, 2016. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0263224116001019>. Acesso em: 10 maio 2024.

WU, J. DA; CHAN, J. J. Faulted gear identification of a rotating machinery based on wavelet transform and artificial neural network. *Expert Systems with Applications*, v. 36, n. 5, p. 8862–8875, 2009. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0957417408008506>. Acesso em: 9 jul. 2024.

YAO, Y.; WANG, H.; LI, S.; LIU, Z.; GUI, G.; DAN, Y.; HU, J. End-To-End Convolutional Neural Network Model for Gear Fault Diagnosis Based on Sound Signals. *Appl. Sci.* 2018, 8, 1584. <https://doi.org/10.3390/app8091584>.