



*Universidade Federal da Paraíba - UFPB*

*Centro de Tecnologia*

*Programa de Pós-Graduação em Engenharia Mecânica*

*Mestrado - Doutorado*

# **METODOLOGIA DE AQUISIÇÃO DE DADOS PARA CAPTURA DE SINAIS DE VIBRAÇÃO MECÂNICA DE MÁQUINAS**

por

Ana Karine Gomes Duarte

*Dissertação de Mestrado apresentada à Universidade Federal  
da Paraíba para obtenção do grau de Mestre.*

**João Pessoa - Paraíba**

**julho, 2025**

**ANA KARINE GOMES DUARTE**

**METODOLOGIA DE AQUISIÇÃO DE DADOS  
PARA CAPTURA DE SINAIS DE VIBRAÇÃO  
MECÂNICA DE MÁQUINAS**

Dissertação apresentada ao curso de  
Pós-Graduação em Engenharia  
Mecânica da Universidade Federal  
da Paraíba, em cumprimento às  
exigências para obtenção do Grau de  
Mestre.

**Orientador: Prof. Dr. Cícero da Rocha Souto**

**Coorientador: Prof. Dr. Rodolfo de Sousa Santos**

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

D812m Duarte, Ana Karine Gomes.

Metodologia de aquisição de dados para captura de  
sinais de vibração mecânica de máquinas / Ana Karine  
Gomes Duarte. - João Pessoa, 2025.

117 f. : il.

Orientação: Cícero da Rocha Souto.

Coorientação: Rodolfo de Sousa Santos.

Dissertação (Mestrado) - UFPB/CT.

1. Vibrações mecânicas - detecção. 2. Manutenção  
preditiva. 3. Defeitos em Máquinas. 4. Processamento de  
sinais. 5. Frequências. I. Souto, Cícero da Rocha. II.  
Santos, Rodolfo de Sousa. III. Título.

UFPB/BC

CDU 681.892(043)

# METODOLOGIA DE AQUISIÇÃO DE DADOS PARA CAPTURA DE SINAIS DE VIBRAÇÃO MECÂNICA DE MÁQUINAS

por

**ANA KARINE GOMES DUARTE**

*Dissertação aprovada em 28 de julho de 2025*



Documento assinado digitalmente

**Cícero da Rocha Souto**

Data: 05/08/2025 18:22:58-0300

Verifique em <https://validar.iti.gov.br>

**Prof. Dr. CÍCERO DA ROCHA SOUTO**

*Orientador – UFPB*



Documento assinado digitalmente

**RODOLFO DE SOUSA SANTOS**

Data: 07/08/2025 13:13:34-0300

Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Rodolfo de Sousa Santos**

*Coorientador – URCA*



Documento assinado digitalmente

**MARCELO CAVALCANTI RODRIGUES**

Data: 07/08/2025 09:04:17-0300

Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Marcelo Cavalcanti Rodrigues**

*Examinador Interno – UFPB*



Documento assinado digitalmente

**KOJE DANIEL VASCONCELOS MISHINA**

Data: 06/08/2025 15:55:24-0300

Verifique em <https://validar.iti.gov.br>

**Prof. Dr. Kojé Daniel Vasconcelos Mishina**

*Examinador Externo – UFPB*

## **DEDICATÓRIA**

Este trabalho é dedicado para todas as mulheres que estão nas STEM e lutam uma batalha por dia para a realização de um sonho. Nós somos grandiosas.

## **AGRADECIMENTOS**

Primeiramente, agradeço imensamente a Deus e a Nossa Senhora do Carmo pelas bênçãos e pela oportunidade de poder contribuir para a comunidade científica e acadêmica.

Agradeço a Daniele, minha parceira de vida, por ter segurado minha mão, por ter me apoiado durante toda essa trajetória e por nunca ter me permitido desistir. Obrigada pela companhia diária e irretocável. Você é sempre com quem (e para quem) eu conto primeiro.

Agradeço a minha família por todo o apoio incondicional, por não duvidarem de mim e por sempre me apoiarem em todos os momentos. Meus pais, Odicildo e Karmen, meu maior alicerce. Meus irmãos e melhores amigos, Odilon e Eliza. Meus avós, Odilon e Jocilda. Meu tio, Antônio Gomes, pelo apoio e influência. E minha avó Maria, maior influenciadora do estudo nessa família.

Aos meus orientadores, Prof. Cícero e Prof. Rodolfo, pelo apoio e confiança que depositaram em mim. Sou muito grata pela oportunidade de trabalhar com vocês e os admiro fortemente.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro prestado através da bolsa de Demanda Social (DS).

Por fim, agradeço a todas as mulheres na STEM que vieram antes de mim, as que estão comigo e as que ainda virão. Nossos sonhos são possíveis pela dedicação e perseverança de cada uma de nós.

Sou um conjunto das marcas das pessoas que passaram pela minha vida. Direta ou indiretamente, obrigada por tornarem isso possível!

# **METODOLOGIA DE AQUISIÇÃO DE DADOS PARA CAPTURA DE SINAIS DE VIBRAÇÃO MECÂNICA DE MÁQUINAS**

## **RESUMO**

O crescente interesse na aplicação de manutenção preditiva em máquinas mecânicas tem incentivado a comunidade acadêmica a explorar técnicas de aquisição e processamento de sinais provenientes de sensores instalados nesses equipamentos. Os sinais capturados pelos sensores são fundamentais para avaliar a condição de operação da máquina e determinar o momento ideal para uma parada planejada, permitindo intervenções de manutenção menos invasivas. Contudo, para que essa avaliação seja confiável, é essencial que a aquisição dos sinais represente fielmente os fenômenos físicos que se deseja monitorar. Entre os diversos indicadores de falhas potenciais, destacam-se os sinais de vibração mecânica, que carregam assinaturas em frequência características de defeitos que podem estar se desenvolvendo nos componentes da máquina. Diante da importância da correta captação desses sinais, este trabalho propõe o desenvolvimento de uma metodologia interativa de aquisição de dados, capaz de se ajustar dinamicamente para garantir a máxima fidelidade na coleta dos sinais provenientes de transdutores de vibração. A metodologia baseia-se no teorema da amostragem, realizando ajustes automáticos na taxa de amostragem e/ou no número de pontos adquiridos, conforme a situação de medição. A estratégia é buscar a maior amplitude de possíveis frequências associadas a falhas, mesmo em estágios iniciais de severidade, permitindo um acompanhamento mais exato da evolução do defeito ao longo de múltiplas medições. Para validar a proposta, este trabalho apresenta resultados experimentais obtidos por meio da captura de sinais gerados por um simulador de falhas elétricas, que emula condições reais de falha em máquinas.

Palavras chaves – Vibrações Mecânicas. Processamento de Sinais. Frequências. Defeitos em Máquinas. Manutenção Preditiva.

# **DATA ACQUISITION METHODOLOGY FOR CAPTURING MECHANICAL VIBRATION SIGNALS FROM MACHINES**

## **ABSTRACT**

The growing interest in the application of predictive maintenance to mechanical machines has encouraged the academic community to explore techniques for acquiring and processing signals from sensors installed in this equipment. The signals captured by the sensors are essential for assessing the operating condition of the machine and determining the ideal time for a planned shutdown, allowing less invasive maintenance interventions. However, for this assessment to be reliable, it is essential that the signal acquisition accurately represents the physical phenomena to be monitored. Among the various indicators of potential failures, mechanical vibration signals stand out, as they carry frequency signatures characteristic of defects that may be developing in the machine components. Given the importance of correctly capturing these signals, this work proposes the development of an interactive data acquisition methodology, capable of dynamically adjusting itself to ensure maximum fidelity in the collection of vibration transducer signals. The methodology is based on the sampling theorem, making automatic adjustments to the sampling rate and/or the number of points acquired, according to the measurement situation. The strategy is to seek the greatest possible range of frequencies associated with failures, even in the early stages of severity, allowing more accurate monitoring of the evolution of the defect over multiple measurements. To validate the proposal, this work presents experimental results obtained by capturing signals from an electrical signal generator, simulating real machine failures.

Keywords - Mechanical Vibrations. Signal Processing. Frequencies. Machine Defects. Predictive Maintenance.



## SUMÁRIO

1. INTRODUÇÃO.....	15
<b>1.1 INTRODUÇÃO .....</b>	<b>15</b>
<b>1.2 OBJETIVOS.....</b>	<b>17</b>
1.2.1 Objetivo Geral .....	17
1.2.2 Objetivos Específicos.....	18
<b>1.3 JUSTIFICATIVA .....</b>	<b>18</b>
<b>1.4 ORGANIZAÇÃO DO TRABALHO .....</b>	<b>19</b>
2. REVISÃO BIBLIOGRÁFICA .....	20
<b>2.1 DEFEITOS EM ELEMENTOS MECÂNICOS.....</b>	<b>20</b>
<b>2.2 MANUTENÇÃO MECÂNICA.....</b>	<b>21</b>
<b>2.3 ANÁLISE DE VIBRAÇÕES E PROCESSAMENTO DE SINAIS .....</b>	<b>26</b>
<b>2.4 TÉCNICAS DE ANÁLISE DE SINAIS TRADICIONAIS.....</b>	<b>31</b>
2.4.1 Domínios do Tempo e da Frequência .....	32
2.4.2 Técnica do Envelope .....	37
2.4.3 Técnica de Wavelet .....	39
<b>2.5 TÉCNICAS DE ANÁLISE DE SINAIS EM DESENVOLVIMENTO.....</b>	<b>40</b>
2.5.1 Machine Learning .....	40
2.5.2 Redes Neurais.....	41
3. MATERIAIS E MÉTODOS.....	43
<b>3.1 INTRODUÇÃO .....</b>	<b>43</b>
<b>3.2 BANCADA EXPERIMENTAL .....</b>	<b>43</b>
<b>3.3 PARÂMETROS DE AQUISIÇÃO .....</b>	<b>45</b>
3.3.1 Frequência de Amostragem ( $F_a$ ).....	45
3.3.2 Número de Pontos (N).....	46
<b>3.4 EXPLICAÇÃO DO MÉTODO .....</b>	<b>47</b>
<b>3.5 SOFTWARES .....</b>	<b>52</b>
3.5.1 LabVIEW .....	52
3.5.2 MATLAB .....	53
4. RESULTADOS E DISCUSSÕES.....	55
<b>4.1 INTRODUÇÃO .....</b>	<b>55</b>
<b>4.2 APRESENTAÇÃO DOS RESULTADOS .....</b>	<b>55</b>
4.2.1 Teste 01 .....	55

4.2.2 Teste 02 .....	61
4.2.3 Teste 03 .....	65
4.3.2 Teste 04 .....	69
4.3.3 Teste 05 .....	73
4.3.4 Teste 06 .....	78
4.3.3 Teste 07 .....	83
4.3.6 Teste 08 .....	86
4.3.7 Teste 09 .....	91
4.3.8 Teste 10 .....	95
4.3.9 Teste 11 .....	99
4.3.10 Teste 12 .....	103
<b>4.3 DISCUSSÕES GERAIS .....</b>	<b>108</b>
<b>5. CONCLUSÕES .....</b>	<b>110</b>
<b>REFERÊNCIAS .....</b>	<b>112</b>
APÊNDICE I – Programa MATLAB para Frequência de Amostragem.....	117
APÊNDICE II – Programa MATLAB para Maior Amplitude.....	119

## LISTA DE FIGURAS

Figura 1 - Exemplo de Domínio do Tempo.....	32
Figura 2 - Exemplo Domínio da Frequência .....	36
Figura 3 – Diagrama de Blocos .....	43
Figura 4 - Bancada Experimental .....	45
Figura 5 - Exemplo de Leakage.....	47
Figura 6 - Etapas do Método .....	49
Figura 7 - Tela LabView .....	53
Figura 8 - Forma de Onda do Teste 01 .....	56
Figura 9 - Domínio do Tempo do Teste 01 .....	56
Figura 10 - Espectro para $F_a = 100$ e $N = 1000$ .....	57
Figura 11 - Espectro para $F_a = 500$ e $N = 5000$ .....	58
Figura 12 - Pico para 33,33 Hz, com $F_a = 505$ e $N = 5000$ .....	60
Figura 13 - Pico para 66,64 Hz, com $F_a = 595$ e $N = 5000$ .....	60
Figura 14 - Pico para 166,675 Hz, com $F_a = 625$ e $N = 5000$ .....	60
Figura 15 - Forma de Onda do Teste 02.....	61
Figura 16 - Domínio do Tempo do Teste 02 .....	62
Figura 17 - Espectro para $F_a = 500$ e $N = 5000$ .....	62
Figura 18 - Espectro para $F_a = 1000$ e $N = 5000$ .....	63
Figura 19 - Pico para 81,21 Hz, com $F_a = 2707$ e $N = 5000$ .....	64
Figura 20 - Pico para 162,34 Hz, com $F_a = 8117$ e $N = 5000$ .....	65
Figura 21 - Pico para 406,15 Hz, com $F_a = 8123$ e $N = 5000$ .....	65
Figura 22 - Forma de Onda do Teste 03.....	66
Figura 23 - Domínio do Tempo do Teste 03 .....	66
Figura 24 - Espectro da Frequência para $F_a = 1000$ e $N = 5000$ .....	67
Figura 25 - Pico para 66,21 Hz, com $F_a = 2207$ e $N = 5000$ .....	68
Figura 26 - Pico para 132,4 Hz, com $F_a = 1000$ e $N = 5000$ .....	69
Figura 27 - Pico para 264,805 Hz, com $F_a = 1055$ e $N = 5000$ .....	69
Figura 28 - Forma de Onda do Teste 04.....	70
Figura 29 - Domínio do Tempo Teste 04 .....	70

Figura 30 - Espectro da Frequência para $F_a = 1000$ e $N = 5000$ .....	71
Figura 31 - Pico para 155,19 Hz, com $F_a = 1050$ e $N = 5000$ .....	72
Figura 32 - Pico para 310,36 Hz, com $F_a = 7759$ e $N = 5000$ .....	73
Figura 33 - Pico para 465,64 Hz, com $F_a = 7759$ e $N = 5000$ .....	73
Figura 34 - Forma de Onda do Teste 05 .....	74
Figura 35 - Domínio do Tempo do Teste 05 .....	74
Figura 36 - Espectro da Frequência para $F_a = 500$ e $N = 5000$ .....	75
Figura 37 - Pico para 13,47 Hz, com $F_a = 898$ e $N = 5000$ .....	76
Figura 38 - Pico para 40,44 Hz, com $F_a = 674$ e $N = 5000$ .....	77
Figura 39 - Pico para 94,36 Hz, com $F_a = 674$ e $N = 5000$ .....	77
Figura 40 - Pico para 107,815 Hz, com $F_a = 673$ e $N = 5000$ .....	77
Figura 41 - Forma de Onda do Teste 06 .....	78
Figura 42 - Domínio do Tempo do Teste 06 .....	79
Figura 43 - Espectro da Frequência para $F_a = 500$ e $N = 5000$ .....	79
Figura 44 – Leakage apresentado no Espectro .....	80
Figura 45 - Pico para 10,55 Hz, com $F_a = 1055$ e $N = 5000$ .....	81
Figura 46 - Pico para 63,27 Hz, com $F_a = 1051$ e $N = 5000$ .....	82
Figura 47 - Pico para 73,848, com $F_a = 529$ e $N = 5000$ .....	82
Figura 48 - Pico para 94,934 Hz, com $F_a = 528$ e $N = 5000$ .....	82
Figura 49 - Forma de Onda do Teste 07 .....	83
Figura 50 - Domínio do Tempo do Teste 07 .....	84
Figura 51 - Espectro de Frequência para $F_a = 500$ e $N = 5000$ .....	84
Figura 52 - Pico para 24,57 Hz, com $F_a = 525$ e $N = 5000$ .....	86
Figura 53 - Pico para 49,113 Hz, com $F_a = 535$ e $N = 5000$ .....	86
Figura 54 - Forma de Onda do Teste 08 .....	87
Figura 55 - Domínio do Tempo do Teste 08 .....	87
Figura 56 - Espectro de Frequência para $F_a = 1000$ e $N = 5000$ .....	88
Figura 57 - Pico para 63,13 Hz, com $F_a = 1070$ e $N = 5000$ .....	90
Figura 58 - Pico para 189,39 Hz, com $F_a = 1070$ e $N = 5000$ .....	90
Figura 59 - Pico para 252,44 Hz, com $F_a = 6311$ e $N = 5000$ .....	91
Figura 60 - Forma de Onda do Teste 09 .....	92
Figura 61 - Domínio do Tempo do Teste 09 .....	92
Figura 62 – Espectro de Frequência para $F_a = 500$ e $N = 5000$ .....	93
Figura 63 - Pico para 36,59 Hz, com $F_a = 3659$ e $N = 5000$ .....	94

Figura 64 - Pico para 73,18 Hz, com $F_a = 3659$ e $N = 5000$ .....	95
Figura 65 - Forma de Onda do Teste 10.....	96
Figura 66 - Domínio do Tempo do Teste 10 .....	96
Figura 67 - Espectro de Frequência para $F_a = 500$ e $N = 5000$ .....	97
Figura 68 - Pico para 27,84 Hz, com $F_a = 580$ e $N = 5000$ .....	98
Figura 69 - Pico para 83,5 Hz, com $F_a = 500$ e $N = 5000$ .....	99
Figura 70 - Pico para 194,847 Hz, com $F_a = 535$ e $N = 5000$ .....	99
Figura 71 - Forma de Onda do Teste 11 .....	100
Figura 72 - Domínio do Tempo do Teste 11 .....	100
Figura 73 – Espectro de Frequência para $F_a = 100$ e $N = 1000$ .....	101
Figura 74 - Pico para 7,89 Hz, com $F_a = 263$ e $N = 1000$ .....	103
Figura 75 - Pico para 23,64 Hz, com $F_a = 197$ e $N = 1000$ .....	103
Figura 76 - Forma de Onda do Teste 12.....	104
Figura 77 - Domínio do Tempo do Teste 12 .....	104
Figura 78 - Espectro de Frequência para $F_a = 500$ e $N = 5000$ .....	105
Figura 79 – Leakage .....	106
Figura 80 - Pico para 10,25 Hz, com $F_a = 625$ e $N = 5000$ .....	107
Figura 81 - Pico para 30,75 Hz, com $F_a = 625$ e $N = 5000$ .....	107
Figura 82 - Pico para 41 Hz, com $F_a = 625$ e $N = 5000$ .....	108
Figura 83 - Percentagem de Erros .....	109

## LISTA DE TABELAS

Tabela 1 - Atributos do Domínio do Tempo .....	34
Tabela 2 - Frequências dos Sinais .....	48
Tabela 3 - Frequências e Amplitudes do Teste 01.....	59
Tabela 4 - Comparação de Frequências.....	59
Tabela 5 - Frequências e Amplitudes para Teste 02.....	63
Tabela 6 - Comparação de Frequências.....	64
Tabela 7 - Frequências e Amplitudes do Teste 03.....	67
Tabela 8 - Comparação de Frequências.....	68
Tabela 9 - Frequências e Amplitudes para Teste 04.....	71
Tabela 10 - Comparação de Frequências.....	72
Tabela 11 - Frequências e Amplitudes do Teste 05.....	75
Tabela 12 - Comparação de Frequências.....	76
Tabela 13 - Frequências e Amplitudes do Teste 06.....	80
Tabela 14 - Comparação de Frequências.....	81
Tabela 15 - Frequências e Amplitudes para Teste 07.....	85
Tabela 16 - Comparação de Frequências.....	85
Tabela 17 - Frequências e Amplitudes para Teste 08.....	89
Tabela 18 - Comparação de Frequências.....	89
Tabela 19 – Frequências e Amplitudes para Teste 09 .....	93
Tabela 20 – Comparação de Frequências .....	94
Tabela 21 - Frequências e Amplitudes para Teste 10.....	97
Tabela 22 - Comparação de Frequências.....	98
Tabela 23 – Frequências e Amplitudes para Teste 11 .....	102
Tabela 24 – Comparação de Frequências .....	102
Tabela 25 - Frequências e Amplitudes do Teste 12.....	106
Tabela 26 - Comparação de Amplitudes .....	106

# **CAPÍTULO I**

## **1. INTRODUÇÃO**

### **1.1 INTRODUÇÃO**

As indústrias buscam estratégias para aumentar sua lucratividade por meio de técnicas de redução de custos e minimização de desperdícios que ocorrem durante o processo operacional. Dentre as estratégias, destaca-se a implementação de programas de manutenção do maquinário visto que a verificação regular das máquinas impacta diretamente no desempenho do processo, na qualidade do produto final e na segurança dos operadores de máquinas.

Dentro da perspectiva da Engenharia de Manutenção, o setor industrial possui três formas de realizar manutenções em máquinas: manutenção corretiva, manutenção preventiva e manutenção preditiva. Sendo esta a que possui maior eficiência, principalmente dentro do que é proposto por esta pesquisa, devido a sua capacidade de avaliar as condições de máquinas. Alguns dos métodos mais utilizados e mais eficazes são a análise de óleo (tribologia), análise de temperatura (termologia), análise do som e a análise de vibrações (SANTOS, 2017)

As falhas e danos causados nas máquinas são provenientes das movimentações e desgastes nos componentes de máquinas, causados pelo funcionamento intenso durante o processo de produção. Quando estes defeitos entram em contato com outras superfícies causam vibrações e ruídos e, se não forem tratados adequadamente, podem causar a falha de outros componentes, comprometer a qualidade do produto e a quebra total da máquina.

Os problemas causados pelas vibrações em máquinas rotativas geram altos custos para as indústrias e, devido ao fato de usarem normalmente práticas corretivas, acabam por sobrecarregar os demais elementos mecânicos e reduzem a vida útil dos equipamentos do sistema fabril.

Para evitar que estas situações aconteçam, as técnicas de análise preditiva são empregadas, sendo a análise de vibrações uma das principais e mais viáveis. A análise de

vibrações é uma das técnicas mais relevantes e presentes nos estudos referentes à identificação de falhas em elementos mecânicos, principalmente rolamentos. Isto ocorre porque a análise de vibrações utiliza técnicas não invasivas para realizar as análises e diagnósticos.

Entretanto, as falhas em componentes são complexas de serem especificadas, visto que todos os elementos de máquina possuem suas próprias vibrações naturais e ruídos provenientes do funcionamento do maquinário e do próprio ambiente fabril. Com essa perspectiva, as técnicas de processamento de sinais de vibrações são as mais utilizadas em conjunto com as técnicas de análise de vibrações para a identificação de falhas de forma precisa e eficaz (BAI et al., 2023).

Para que a análise de vibrações seja devidamente realizada, algumas etapas devem ser seguidas. As máquinas devem ser monitoradas por determinados períodos de tempo, as características vibratórias devem ser extraídas e os dados coletados devem ser devidamente processados, utilizando as técnicas existentes de apreensão dos parâmetros dos sinais. Posteriormente, os dados devem ser comparados com os valores de referência previstos em cada situação específica, como as frequências de defeitos analíticas dos elementos de rolamentos, por exemplo.

Portanto, pode-se inferir que a implementação de técnicas de processamento de sinais avançadas é imprescindível no que diz respeito à realização de diagnóstico e prognóstico, conduzindo à identificação eficiente de defeitos, sendo a principal barreira para os pesquisadores a escolha correta da faixa ideal de frequência de amostragem e a utilização de instrumentos de alto custo e de difícil aplicação por operadores não qualificados.

Para que a análise de vibrações seja corretamente realizada, a coleta dos sinais deve ser efetuada de maneira cuidadosa e precisa, além de respeitar os fundamentos teóricos e os parâmetros de aquisição mínimos. Diversas técnicas são utilizadas para auxiliar na identificação da frequência de defeito correta, geralmente ao reduzir o sinal e analisa-lo separadamente para encontrar frequências corretas quando existem muitos ruídos, como a técnica do envelope ou a Transformada de Wavelet.

Entretanto, se os parâmetros de aquisição utilizados não forem corretos, as técnicas não serão eficazes pois o próprio sinal estará corrompido e pode apresentar fenômenos como *aliasing* ou *leakage*, comprometendo a frequência e as análises e diagnósticos realizados a partir disso.

Além das técnicas tradicionais de coleta, vários métodos estão em



desenvolvimento conforme a tecnologia avança rapidamente no cotidiano globalizado. Estudos utilizando *Machine Learning* e Redes Neurais para a detecção de falhas incipientes em elementos mecânicos possuem uma vasta ocupação no campo da Engenharia Mecânica. Contudo, a aplicação destas técnicas requer investimento alto, pessoal especializado e instrumentos específicos.

Com esta perspectiva, o presente trabalho busca responder perguntas científicas de alta importância: como garantir que os parâmetros de aquisição de dados de frequência estejam adequadamente configurados? Como identificar qual é a frequência de maior pico e determinar a que fenômeno ela corresponde? Como as frequências se relacionam aos defeitos das máquinas? A implementação de técnicas de aquisição de sinais é uma estratégia viável para a redução de custos e para a melhoria de processos produtivos?

Para responder essas questões, a pesquisa propõe a elaboração de um método para determinar os parâmetros corretos de aquisição de frequências de sinais diferentes, com a intenção de identificar a frequência dominante entre todas as encontradas e interpretar seu significado. Os testes serão realizados em um ambiente controlado e o método será submetido a avaliação para verificar sua eficácia e o alcance dos objetivos propostos.

Para além disso, o trabalho visa fomentar pesquisas científicas na área da Engenharia Mecânica, principalmente no que diz respeito a Análise de Vibrações, além de possibilitar a aplicação de conhecimentos teóricos em experimentos relevantes, validando-os. Da mesma forma, reforça a importância das pesquisas acadêmicas e laboratoriais para que as empresas aprimorem seus processos produtivos.

## **1.2 OBJETIVOS**

### **1.2.1 Objetivo Geral**

Desenvolver um algoritmo iterativo que determine os parâmetros de aquisição adequados – como a Frequência de Amostragem ( $F_a$ ) e o Número de Pontos (N) – para a leitura dos sinais de vibrações, respeitando o Teorema de Nyquist para evitar *aliasing* e *leakage*.

### 1.2.2 Objetivos Específicos

- Implementar um algoritmo iterativo capaz de reconhecer os parâmetros de captura do sinal para identificar o vazamento espectral;
- Definir uma bancada experimental que possibilite captura de sinais elétricos que possam ser oriundos de fenômenos físicos;
- Determinar conjuntos de frequências de estudo que estejam relacionadas entre si para garantir a robustez do método.

### 1.3 JUSTIFICATIVA

A pesquisa justifica-se por buscar o avanço de estratégias não invasivas para a detecção de frequências de defeitos em elementos de máquinas de forma precisa, eficaz e simplificada.

Apesar de ser uma área amplamente estudada e de possuir técnicas de processamento avançadas e consolidadas, a Análise de Vibrações apresenta possibilidades de aperfeiçoamento e inovação de seus métodos de análise, sobretudo com o objetivo de torná-los mais acessíveis a empresas que necessitam utilizá-los para melhorar seus processos produtivos. Tal avanço pode ser viabilizado por meio da redução do número de sensores, do tempo de análise e dos recursos computacionais necessários.

Sob esta perspectiva, o método proposto por esta pesquisa busca aperfeiçoar o uso dos parâmetros de aquisição para identificar corretamente as frequências de interesse, respeitando o Teorema de Nyquist e evitando fenômenos como *aliasing* e *leakage*. A proposta consiste em estabelecer e aplicar o método em um ambiente controlado com simulações de sinais reais a fim de comprovar sua eficácia.

Provada sua funcionalidade, o método pode ser aplicado em ambientes variados com condições diversas, adaptando-se às particularidades de cada um. Posteriormente, com posse das frequências reais, um diagnóstico completo e preciso pode ser elaborado, comparando os valores reais com os analíticos correspondentes para encontrar o mais próximo entre eles, consequentemente, encontrando o local mais próximo onde o defeito está localizado. O maior benefício da pesquisa diz respeito a necessidade de utilização de poucos instrumentos de medição, visto que pode ser realizada com um acelerômetro, uma placa de aquisição de dados e os recursos computacionais necessários.

Ademais, a pesquisa funciona como base para aperfeiçoamentos de técnicas tradicionais evitando que sejam realizadas em espectros corrompidos e identifiquem frequências falsas. Dessa forma, a pesquisa atua de forma intensa e eficiente como uma base científica importante para a área na qual atua, fortalecendo a pesquisa científica e atuando como referência para demais trabalhos na área.

## **1.4 ORGANIZAÇÃO DO TRABALHO**

O presente trabalho é organizado em 05 (cinco) capítulos, divididos em: Introdução, Referencial Teórico, Materiais e Métodos, Resultados e Conclusões. Os capítulos seguem uma ordem lógica para o melhor entendimento do leitor e para que os objetivos propostos pela pesquisa sejam devidamente alcançados.

O primeiro capítulo é relacionado à Introdução e possui os tópicos referentes a introdução do assunto a ser tratado, os objetivos gerais e específicos que são buscados com a pesquisa, a justificativa e a organização do trabalho.

O segundo capítulo é relacionado à Revisão da Literatura, onde os principais assuntos resgatados nas pesquisas bibliográficas realizadas são culminados em tópicos sobre defeitos em elementos mecânicos, manutenção mecânica, análise de vibrações e processamento de sinais e as principais técnicas de processamento de sinais, divididas entre tradicionais e em desenvolvimento.

O terceiro capítulo é relacionado aos Materiais e Métodos utilizados para alcançar os objetivos da pesquisa e divide-se na introdução, na explanação da bancada experimental, nos *softwares* utilizados e na explicação do método a ser relacionado.

O quarto capítulo relaciona-se aos Resultados obtidos pela pesquisa, apresentando discussões sobre os parâmetros de aquisição, como frequência de amostragem e número de pontos. Neste capítulo, o método de processamento de sinais elaborado é exposto e detalhado com exemplos dos testes feitos, bem como os resultados dos testes também são apresentados.

Finalmente, o quinto capítulo apresenta as últimas considerações sobre os resultados e a finalização com as percepções provenientes da pesquisa juntamente com prospecções de pesquisas futuras utilizando os temas relacionados.

## CAPÍTULO II

### 2. REVISÃO BIBLIOGRÁFICA

#### 2.1 DEFEITOS EM ELEMENTOS MECÂNICOS

A partir da análise da partida de máquinas elétricas e de seu funcionamento sob condições que sejam variáveis em carga e velocidade, podemos encontrar informações indispensáveis para a detecção e o diagnóstico de falhas nos elementos mecânicos que as compõem (RUIZ-SARRIO; ANTONINO-DAVIU; MARTIS, 2024).

O diagnóstico precoce de defeitos em elementos mecânicos pode vir a reduzir a necessidade de reparos emergenciais que comprometam o processo produtivo, como também reflete e acentua os danos potenciais que as máquinas podem apresentar ao longo da sua vida útil (SAMAL *et al.*, 2024).

Estas falhas inesperadas podem causar perdas financeiras e tempo de inatividade, que resultam em custos operacionais de 15% a 60% (AHMED; NANDI, 2023), além de abrir margem para a possibilidade de acidentes humanos irreversíveis. Para manter uma máquina saudável, seus componentes (motores, rolamentos, engrenagens, etc.) devem estar funcionando da forma como foram programados para funcionar.

Os sintomas de diversas naturezas podem ser levados em consideração para identificar falhas em rolamentos, desde campos térmicos, de pressão, ruídos e emissões de infravermelho até o consumo da corrente e análise baseada em lubrificante. Entretanto, a mais comumente utilizada e a mais eficaz é a baseada no estudo dos sinais de vibração dos elementos mecânicos (SACERDOTI; STROZZI; SECCHI, 2023).

Por exemplo, quando um motor está funcionando, fatores como impacto de sobrecarga, erro de montagem ou lubrificação deficiente levarão à falha do mancal. A partir do contato do ponto de falha com a superfície do equipamento, os sinais de vibração mostrarão características instáveis e os sinais não estacionários terão características de duração limitada e variação oportuna (MA *et al.*, 2021).

Liu *et al.* (2021) registram um panorama das principais técnicas de diagnóstico

de falhas em elementos mecânicos fazendo referência ao encontrado na literatura nos últimos anos.

Por sua vez, Ponomareva *et al.* (2024) destacam que a extração de dados é classificada como séries temporais e imagens e representam um estágio do processamento de dados. As séries temporais desempenham um papel crucial em muitos domínios e podem representar a saída de sensores de aceleração, sinais em linhas de comunicação, atividades sísmicas, entre outros tipos de dados. O processamento dessas séries temporais inclui a sua caracterização onde os sinais longos são transmutados para um espaço compacto representando apenas as propriedades mais importantes, que serão usadas para medições, classificação e previsão. Especificamente na engenharia, a extração das características das séries temporais é útil no projeto de sensores e na detecção de falhas.

A pesquisa de monitoramento das condições propõe o estudo da capacidade de diferentes sensores e técnicas de processamento para identificar as assinaturas características em sinais mecânicos e eletromagnéticos, os quais representam as características específicas de diversas falhas. Essas características são diretamente relacionadas aos parâmetros da máquina (tipo de máquina, número de polos, geometria do mancal, etc.) e suas condições de trabalho (velocidade, fonte de alimentação, etc.). Dessa forma, um conhecimento aprofundado da máquina é importante para não cometer erros durante a fase de tomada de decisão, seja esta realizada por um indivíduo ou por um algoritmo automático (MINERVINI *et al.*, 2021).

A análise dos defeitos mecânicos destaca a necessidade da aplicação de técnicas de aquisição e processamento de sinais alinhados aos princípios da manutenção mecânica preditiva, como será destacado nos próximos tópicos.

## **2.2 MANUTENÇÃO MECÂNICA**

As máquinas rotativas representam elementos importantes em diferentes setores no ambiente fabril e possuem diversos elementos mecânicos que são suscetíveis a falhas. O diagnóstico preciso, confiável e correto de defeitos nestes componentes é um importante desafio no campo industrial e um ponto crucial para sistemas de manutenção preditiva, visto que o custo com manutenções não planejadas é significativo, além de causar interrupções em seus processos de produção (RUIZ-SARRIO; ANTONINO-DAVIU; MARTIS, 2024).

Os custos referentes à manutenção representam cerca de 15 a 20% dos custos

totais de produção (SAHA; HOQUE; BADIHI, 2022). Entretanto, quase 30% destes custos são desperdiçados por serem aplicados de maneira inadequada pela estratégia de manutenção e a não realização da manutenção nos momentos certos, causando a necessidade de adotar medidas corretivas, além de que o colapso repentino dos componentes da máquina pode levar a perdas substanciais de produção.

A condição saudável das máquinas é garantida através das manutenções, que podem ser corretivas ou preventivas, e atuam por meio de reparos, modificações ou substituições de componentes. A manutenção corretiva é realizada após a máquina apresentar uma falha, o que a torna cara já que interrompe a produção e a máquina fica inativa durante o tempo necessitado para realizar a reparação do defeito (AHMED; NANDI, 2023).

Yuan *et al.* (2022) defendem que existem três formas básicas de realizar manutenção de máquinas:

- i. realizar ações de manutenção somente após a falha da máquina e analisar a peça que apresentou defeito e as demais regiões que falharam decorrentes disso;
- ii. realizar inspeções periódicas para determinar a quantidade de tempo restante até a falha e realizar as ações de manutenção apenas de acordo com o cronograma que foi criado baseando-se no tempo médio entre as últimas falhas apresentadas;
- iii. por fim, a manutenção preditiva que se caracteriza devido a sua proatividade onde os dados são adquiridos de forma contínua e as atividades de manutenção são guiadas de acordo com os direcionamentos reconhecidos através destes dados, objetivando o reconhecimento das falhas antes delas ocorrerem definitivamente.

Por sua vez, Aburakhia, Myers e Shami (2022) reforçam a manutenção corretiva (CM), a manutenção preventiva (PvM) e a manutenção preditiva (PdM). As ações decorrentes da CM são simples, mas significativamente caras, por envolver a interrupção do processo de produção e a substituição de peças. A PvM é uma estratégia programada com base no tempo médio que a manutenção é realizada. É uma técnica relevante, porém os tempos médios não são parâmetros corretos de intervenção nos equipamentos, o que pode causar a necessidade de realizar ações corretivas mesmo assim, e as ações preventivas aumentam muito os custos de manutenção. Por sua vez, a PdM é baseada no monitoramento contínuo das condições dos equipamentos e as ações são previstas e planejadas de acordo com as condições reais apresentadas. Essas informações são obtidas através de abordagens preditivas para monitorar a integridade do processo funcional do

equipamento.

El Bouharrouti, Morinigo-Sotelo e Belahcen (2024) ressaltam que detectar uma falha de forma antecipada em um componente chave durante operações industriais e possibilitar a sua prevenção nos estágios iniciais são etapas cruciais para garantir a eficácia e a boa execução dos processos fabris, sendo fundamental para o funcionamento de indústrias e empresas.

A manutenção preditiva identifica sinais característicos de falhas iminentes de forma antecipada, sem precisar esperar até que os defeitos se tornem visíveis e/ou em seu estágio inicial, como ocorria em abordagens ultrapassadas, como a “*run-to-break*”, a manutenção baseada no tempo e as substituições realizadas às cegas (SACERDOTI; STROZZI; SECCHI, 2023).

Por ser uma área muito abrangente, a manutenção preditiva tem muitas definições, frequentemente é referenciada como o monitoramento da vibração de máquinas rotativas devido a sua proposta de detecção de problemas incipientes e dificultar a ocorrência de falhas catastróficas. Quando a condição da máquina apresenta quebra/defeito, uma mudança ocorrerá em suas vibrações e será aparente, o que possibilita a utilização de recursos como o *Root Mean Square* (RMS) e valores de pico do sinal para detectar o início das falhas e começar o planejamento da manutenção (VERELLEN *et al.*, 2021).

A manutenção preditiva é amplamente utilizada no setor industrial e mecânico. Atualmente, com o avanço da Indústria 4.0, a manutenção preditiva possui um papel crucial para auxiliar na sua atualização e torna-la totalmente automática. Yuan *et al.* (2022) salientam a criação de um sensor de deformação baseado em um nanocompósito altamente sensível para implementação direta na Indústria 4.0. Além disso, ela também possui contribuições no avanço da manutenção preditiva através da utilização de *big data* e da Internet das Coisas.

Na manufatura inteligente, o gerenciamento da manutenção é imprescindível, porque uma manutenção eficaz e eficiente corrobora para a confiabilidade do equipamento, garantindo segurança, produtividade e qualidade no serviço executado (ABURAKHIA; MYERS; SHAMI, 2022).

Graças aos avanços das novas tecnologias que permitem o uso de sensores mais potentes, a manutenção preditiva se firmou como uma disciplina eficaz ao rastrear o estado das peças mecânicas em tempo real e ao auxiliar no apontamento dos momentos mais viáveis de aplicação de intervenções do ponto de vista da resolução do defeito e da

saúde econômica da empresa (SACERDOTI; STROZZI; SECCHI, 2023).

Ahmed e Nandi (2023) dividem a manutenção preventiva em duas: a manutenção baseada no tempo (TBM) e a manutenção baseada na condição (CBM), que pode ser localizada ou remota. A TBM é considerada cara e pode não cumprir a função de evitar falhas, diferentemente da CBM que é mais eficiente, já que 99% das falhas dos elementos são precedidas por condições não especificadas. Uma das características da CBM é que ela é baseada no monitoramento de condições (CM) para detectar falhas precocemente, tornando os processos de tomada de decisão na manutenção mais precisos.

O CM voltado para máquinas é composto pela detecção e diagnóstico de falhas e seu uso baseado em vibrações é muito utilizado por causa da sua capacidade de perceber a integridade da máquina sem o envolvimento físico. Dessa forma, o CM se torna essencial na otimização de detecção e diagnóstico de condições de falhas em máquinas (EL BOUHARROUTI; MORINIGO-SOTELO; BELAHCEN, 2024).

O monitoramento de condições e o diagnóstico de falha funcionam como técnicas de monitoramento do status de saúde em tempo real e podem determinar tanto a gravidade da falha quanto a sua localização pelas mudanças apresentadas nos sinais de vibração, evitando a ocorrência de grandes acidentes e economizando nos custos de manutenção (MA *et al.*, 2021).

Como uma das técnicas pertencente à manutenção preditiva, Pule, Matsebe e Samikannu (2022) reforçam o monitoramento de condições (CM) como uma ferramenta de estimativa da saúde atual dos equipamentos rotativos fazendo o uso de métodos como a análise de vibrações, análise da corrente do motor, análise de óleo ou análise de temperatura. O CM envolve a detecção e o diagnóstico de falhas de máquinas em vários setores.

Na implementação de um sistema CM a fim de detectar falhas em elementos mecânicos, é necessário estudar e selecionar um conjunto de padrões de comportamento dos defeitos mais comuns que podem existir, já que é este padrão que será monitorado durante a operação da máquina, possibilitando que o status do maquinário seja sempre conhecido sem que a máquina tenha que ser desligada (ZAMORANO; GÓMEZ; CASTEJÓN, 2024).

Zamorano, Gómez e Castejon (2024) fazem um panorama do que existe na literatura em relação à aplicação do CM, ressaltando a presença significativa da análise das vibrações produzidas durante a operação dos componentes, o que pode levar à detecção de uma variedade de defeitos. A detecção dos defeitos antes da falha ocorrer é



de extrema importância para que acidentes catastróficos e quebras irreversíveis sejam evitadas. Além disso, técnicas não invasivas estão sendo cada vez mais estudadas, como o *Machine Learning* que explora o conhecimento de abordagens de filtragem e definições de características fornecidas (BRITO *et al.*, 2021).

A detecção de falhas procura identificar qualquer desvio das condições esperadas de operação e funcionamento pré-definidas pelo elemento que está sendo analisado, e envolve comparações de dados e sinais medidos com os valores de referência (AHMED; NANDI, 2023). Assim, quando detectada uma falha, é feita uma análise posterior para identificar a causa raiz da sua existência, chamado de diagnóstico de falhas. O estudo posterior engloba toda a inspeção das medições e dos parâmetros das máquinas seguido pelo uso de técnicas (processamento de sinais, reconhecimento de padrões, análise estatística e algoritmos de aprendizado) para fazer um diagnóstico ou um prognóstico sobre o estado de saúde da máquina (EL BOUHARROUTI; MORINIGO-SOTELO; BELAHZEN, 2024).

Para elaborar estratégias de manutenção dos componentes de máquinas e prevenir sua quebra, é necessário que um monitoramento do comportamento dos elementos seja feito em tempo real com o objetivo de detectar falhas, evitando perdas graves. Altaf *et al.* (2019) defendem a existência de métodos diversos na literatura para detecção de falhas, como análise de vibrações, emissão acústica, resíduos de óleo, análise eletrostática e de temperatura.

Nos últimos anos, as principais abordagens da CM são as técnicas baseadas em dados que podem ser divididas em duas etapas principais: a extração de recursos e o uso dos recursos extraídos. A primeira etapa é realizada através de técnicas de extração de recursos que podem ser escolhidas conforme a particularidade de cada elemento a ser analisado. A segunda etapa envolve a utilização dos recursos que foram extraídos na primeira parte e realizar as suas devidas classificações ou a previsão precisa das condições normais e anormais (ABURAKHIA; MYERS; SHAMI, 2022).

Nesta perspectiva, é essencial que a extração dos recursos seja feita com alta sensibilidade a quaisquer alterações no processo para representar devidamente a integridade do processo operacional. Para realizar a avaliação do desempenho, a precisão e a complexidade (em termos de memória e tempo de processamento) são parâmetros muito relevantes na CM, visto que quanto maior a precisão, maior a confiabilidade do sistema, e quanto menor a complexidade, menores os requisitos computacionais do sistema (ABURAKHIA; MYERS; SHAMI, 2022).

Atualmente, os novos desafios na manutenção são orientados ao monitoramento das condições (CM), prognóstico e digitalização de todo o processo de tarefas de manutenção (do elemento aos gerentes executivos). Os sistemas modernos do CM podem incluir recursos significantes como o cálculo da vida útil restante dos elementos de máquina combinados com otimização e controle do processo (WODECKI *et al.*, 2023).

## 2.3 ANÁLISE DE VIBRAÇÕES E PROCESSAMENTO DE SINAIS

Dentre as principais técnicas para o diagnóstico de falhas em elementos de máquinas, destaca-se a análise de vibrações, que continua sendo tema de diversas pesquisas na área da Engenharia Mecânica. A análise dos sinais de vibração é um dos métodos mais utilizados no diagnóstico de falhas mecânicas, tendo em vista que os sistemas mecânicos possuem estruturas complexas. Sendo assim, o sinal de vibração é colhido por um sensor que reflete o comportamento de cada componente, podendo ser percebido pelo fato de que quando os equipamentos mecânicos sofrem falhas, o sinal da vibração se altera de forma não-linear. A análise de tempo-frequência leva em consideração os aspectos globais e locais dos componentes e revela com maior precisão os sinais de vibração (BAI *et al.*, 2023).

A análise do sinal de vibração é um dos métodos mais eficazes de investigação de falhas porque ela é apoiada por técnicas de processamento de sinais bem estabelecidas junto a algoritmos de computação que contribuem para sua confiabilidade (KUMAR; ANAND, 2024). Apesar disso, ainda está muito exposta à contaminação de ruídos e também requer a montagem satisfatória dos sensores de vibração para adquirir os dados experimentais.

A maior vantagem desta técnica se dá ao fato de que não é necessária desligar a máquina para poder aplicá-la, o que faz com que a produção não pare, sendo ideal na aplicação real no ambiente industrial. Sendo caracterizada como uma abordagem não intrusiva, a análise de vibrações permite a determinação da condição da máquina ao analisar sua amplitude ou frequência, tanto em estágios anteriores quanto posteriores às falhas de rolamento incipientes (KUMAR; ANAND, 2024).

Brito *et al.* (2021) destacam mais alguns fatores que fazem a análise de vibrações ser uma técnica de tanta visibilidade no campo de estudo o qual está inserida, entre elas, temos:

- i. não é necessário parar o sistema para realizar os processos de medição;

- ii. o posicionamento do sensor para a aquisição de dados (os acelerômetros são os mais comuns) possui grande facilidade;
- iii. proporciona um amplo conhecimento sobre as características de falhas;
- iv. o tempo de aquisição é consideravelmente rápido;
- v. fornece informações de condições elétricas, mecânicas e estruturais.

Os métodos inteligentes de diagnóstico utilizam conceitos variados como inteligência artificial, aprendizado de máquina e técnicas de processamento de sinais, e são divididos em 4 (quatro) fases principais: pré-processamento, processamento de sinais e extração de recursos, pós-processamento e reconhecimento de padrões. Os recursos extraídos são as informações estatísticas de tempo e frequência e as falhas detectadas utilizando as técnicas de processamento de sinais (CHEGINI; BAGHERI; NAJAFI, 2020). Gunerkar, Jalan e Belgamar (2019) também defendem que a taxa de sucesso proveniente do diagnóstico de falhas mecânicas está na extração de recursos precisos dos sinais originais. Desta forma, a essência do diagnóstico é construir uma função adequada para extrair os recursos óbvios dos sinais.

A aquisição de dados, o processamento de sinais e a classificação de falhas são pilares para o procedimento satisfatório de diagnóstico de falhas na análise de vibrações. Nesta etapa, são utilizados sensores e placas de aquisição de dados para a captação dos sinais. Os sensores utilizados com mais frequência são os acelerômetros, transdutores de deslocamento e transdutores de velocidade. E os sensores piezoelétricos são utilizados para coletar sinais de emissão acústica. Os dados coletados são transferidos para uma unidade de processamento de sinal, onde os dados com as informações relevantes serão devidamente processados. A extração e a seleção de recursos podem ser conduzidas em técnicas de três domínios: do tempo, da frequência e do tempo-frequência (ANWARSHA; BABU, 2022).

Os acelerômetros são sensores de contato e precisam se conectar aos dispositivos para capturarem sinais de vibração. Se os sensores não vierem previamente equipados no maquinário, podem ser alocados com o auxílio de ímãs, tornando a investigação completamente não intrusiva (VERELLEN *et al.*, 2021).

A escolha correta dos sensores depende da faixa de frequência desejada para o objeto do estudo, comumente são utilizados sensores de deslocamento na baixa frequência, sensores de velocidade na média frequência e acelerômetros na alta frequência (BOUAOUICHE; MENASRIA; KHALFA, 2023).

A extração de sinais realizada em equipamentos modernos é complicada devido o aparecimento de ruído de fundo, o que deixa os sinais de vibração mais complexos de serem analisados. A extração ainda pode ser impactada por fatores não lineares, por exemplo a folga ou o atrito de carga (TANG *et al.*, 2022), pois os padrões de pulso causados pelo início da falha podem ser mascarados pelos ruídos. A situação ainda pode ser mais exacerbada por efeitos de propagação de caminhos de transmissão desconhecidos (ZHANG, 2024).

As transformações de tempo-frequência mostram informações valiosas sobre o sinal de vibração, o que possibilita definir integridade do maquinário. As maiores dificuldades encontradas pelos pesquisadores é a extração eficiente dos sinais, devido ao índice de ruídos e componentes semelhantes na imagem tempo-frequência. Bai *et al.* (2023) indica que o método de análise mais antigo é a estatística através da análise quantitativa da matriz tempo-frequência do sinal de vibração, entretanto, devido às estruturas de dados complexas, os recursos estatísticos de níveis inferiores não são comumente usados. Com o avanço da tecnologia, novos métodos de análises surgem com o objetivo de automatizar de forma inteligente os diagnósticos de falhas.

Dentre alguns dos principais métodos de análises, destacam-se a análise de vibração, a análise de assinatura de corrente do motor e a emissão acústica. A análise de vibrações é o método mais tradicional e seus principais desafios são acesso, custo e manuseio correto dos sensores de vibração. Já a análise a partir da assinatura de corrente do motor se trata de uma técnica não invasiva, evitando os problemas relacionados aos sensores, mas apresentando novos relacionados à falta de precisão da atual condição do elemento (PANDARAKONE; MIZUNO; NAKAMURA, 2019).

Dentre os principais desafios para a extração e a identificação correta dos sinais de vibração é a determinação correta das regiões que apresentam informações relevantes, ou seja, quais são as faixas de frequência que apresentam informações sobre o comportamento dinâmico da máquina ou falha (BRITO *et al.*, 2024).

Identificar as bandas de frequência relevantes para a extração/seleção de característica é crucial para uma aplicação bem-sucedida. Pois a extração das características do sinal bruto sem uma relevância prévia, carrega grandes chances de introduzir informações irrelevantes na análise. Por outro lado, se as características forem informativas o suficiente, qualquer algoritmo de classificação pode ter um desempenho bom (BRITO *et al.*, 2024).

Nos estudos relacionados ao diagnóstico de falhas em rolamentos de elementos

rolantes, a análise das vibrações é comumente utilizada para detectar as falhas e treinar algoritmos. De forma experimental, as vibrações são coletadas a partir de parâmetros de frequência de amostragem ( $F_a$ ) e com o uso de acelerômetros que são alocados em pontos estratégicos do maquinário a fim de coletar os dados referentes às vibrações (EL BOUHARROUTI; MORINIGO-SOTELO; BELAHCEN, 2024). Quanto maior a  $F_a$ , maior é a precisão dos dados que serão coletados, entretanto, o custo dos sensores utilizados é proporcional ao tamanho da  $F_a$ .

Dessa forma, é possível entender que a qualidade de um modelo de sistema é completamente ligada à qualidade dos dados coletados no treinamento. Já que a  $F_a$  está ligada a precisão das vibrações medidas, é necessária uma relação equilibrada entre os esforços computacionais de processamento dos dados e a qualidade destes (EL BOUHARROUTI; MORINIGO-SOTELO; BELAHCEN, 2024).

Os sinais de vibrações possuem dados importantes relacionados à condição de saúde do elemento e são relativamente fáceis de serem coletados. O ponto crucial para que a análise de vibrações seja realizada de forma satisfatória é a extração das características das falhas dos elementos. A análise clássica do espectro da frequência é realizada a partir da Transformada de Fourier, pois a partir da falha de um rolamento, os harmônicos provenientes desta falha se mostram presentes e podem ser analisados para determinar sua falha e gravidade (WANG *et al.*, 2021). Entretanto, seu maior desafio é a extração satisfatória do sinal, visto que o método clássico é baseado no processamento de sinais de vibração lineares (YUE *et al.*, 2023).

Por exemplo, quando o rolamento possui uma falha, o sinal se reflete como sendo a operação de convolução que acontece durante os impulsos de falha e a função de transferência percebida entre a razão da falha e o sensor, gerando sinais que possuem características de não linearidade, não estacionariedade, forte acoplamento e presença de ruídos (PEI; YUE; JIAO, 2024). Para isto, a análise tempo-frequência é mais eficaz quando tratamos de sinais não estacionários, auxiliando na revelação dos componentes de frequência e suas particularidades de acordo com a variação do tempo (TANG *et al.*, 2022).

Os sinais de vibração provenientes do atrito entre as zonas defeituosas e os elementos que compõem o rolamento exibem características não lineares e não estacionárias devido à atenuação do coeficiente de amortecimento do sistema no caminho de transmissão da vibração (QIFENG; LONGSHENG; NAEEM, 2024).

Wang *et al.* (2021) explicitam algumas das características que podem ser

extraídas do domínio da frequência, como a frequência média, a frequência central – que mede a linha do espectro ponderada a sua amplitude –, a frequência quadrática média e a frequência de desvio padrão. Além disso, enquanto a frequência média e a frequência quadrática média caracterizam a falha e sua distribuição pelo espectograma, a frequência de desvio padrão pode ser usada para caracterizar a extensão da dispersão de energia para cada espectro.

Sistemas de simulação de falhas de vibração foram implementados para ajudar na observação dos padrões de vibração e aprimorar técnicas de processamento de sinais. A forma mais tradicional de identificação de falhas é a partir da obtenção do *Root Mean Square* (RMS), segundo os estudos propostos por Jayasinghe *et al.* (2021).

O RMS é comumente utilizado para medir a intensidade da vibração e, dessa forma, indicar um possível defeito futuro. O valor RMS é definido pela raiz quadrada do valor quadrático médio de um sinal (BAUER *et al.*, 2023). Porém, apenas reflete a amplitude do sinal e não fornece informações detalhadas sobre a forma da vibração que está sendo analisada.

Defeitos relacionados a desbalanceamento de massa, desalinhamento, falhas em engrenagens e rolamentos, são alguns dos que podem ser detectados e localizados a partir da análise dos sinais de vibração a partir da emissão acústica. Altaf *et al.* (2019) explicam que a emissão acústica pode possibilitar a detecção precoce destes defeitos, visto que é gerada como uma onda elástica transitória resultante da descarga de energia de deformação como resultado de danos dentro ou na superfície do material. Isto acontece porque rachaduras em eixos e engrenagens possuem frequências típicas de 20kHz a 1 MHz.

Para o diagnóstico de falhas em máquinas rotativas, também podem ser utilizados como indicadores a imagem de infravermelhos e o *feedback* acústico como forma de avaliação do estado da máquina, embora não sejam amplamente usados pelo fato de possuírem um alto custo de aquisição (BAUER *et al.*, 2023).

Bouaouiche, Menasria e Khalfa (2023) dividem os métodos de análise de vibrações em dois grupos, sendo o primeiro baseado no projeto e na análise de um modelo associado a um sistema ou a uma máquina rotativa, como as Redes Neurais Artificiais. E o segundo grupo são os que se concentram na extração das características de sinais de vibração, seja no domínio do tempo ou da frequência ou no domínio tempo-frequência.

Por sua vez, Zhang *et al.* (2023) dividem as técnicas de análise no tempo-frequências em duas categorias. A primeira diz respeito às técnicas que não precisam de

definição de parâmetros antes da análise dos sinais de vibração, como a Decomposição Média Local (LMD). Já o segundo grupo diz respeito aos que necessitam das definições de parâmetros e aquisição, como a Transformada de Wavelet (WT).

A LMD decompõe sinais complexos em múltiplas funções de produtos de acordo com a vibração inerente do sinal de vibração. Apesar de apresentar eficácia considerável a LMD ainda sofre com problemas como o efeito de ponto final e o *aliasing* (ZHANG *et al.*, 2023).

Algumas ferramentas modernas que estão em ascensão e podem ser utilizadas são a Rede Neural Artificial (ANN) e a Máquina de Vetor de Suporte (SVM). A rede neural e outras técnicas de inteligências artificiais convencionais se baseiam no princípio de minimizar o risco empírico e possuem limitações relacionadas à geração de resultados em modelos que podem superestimar as amostras. Já o SVM é um método de aprendizado estatístico e se baseia no princípio de minimização de risco estrutural, possuindo propriedades como alta precisão e boa generalização para um número menor de amostra de falhas (CHEGINI; BAGHERI; NAJAFI, 2020).

Alonso-Gonzalez *et al.* (2023) ressalta os algoritmos clássicos mais utilizados sobre detecção de falhas e enfatiza o *K-Nearest Neighbors* (k-NN), *Support Vector Machine* (SVM), *Decision Trees* e *Naive Bayes*. Também ressaltam o sucesso obtido por pesquisadores ao utilizarem o SVM em suas pesquisas e reflete o aproveitamento do uso de algoritmos de aprendizagem profunda na utilização das redes neurais artificiais, apontando os mais mencionados como sendo: rede neural convolucional (CNN), codificadores automáticos, rede de crença profunda (DBN) e rede neural recorrente (RNN).

Apesar do aprimoramento das técnicas de identificação de falhas, ainda é presente a necessidade de aumentar a precisão do diagnóstico e a previsão correta de quando estas falhas vão acontecer em um sistema de monitoramento alternativo e avançado, como por análise de tendências (JAYASINGHE *et al.*, 2021).

## **2.4 TÉCNICAS DE ANÁLISE DE SINAIS TRADICIONAIS**


Abedin *et al.* (2023) lista as principais técnicas de processamento de sinais, sendo as mais tradicionais a Transformada Rápida de Fourier (FFT), a Transformada de Wavelet (WT), a Análise do Envelope, a Decomposição de Modo Empírico (EMD), Decomposição de Modo Empírico do Conjunto (EEMD) e Decomposição do Modo

Variacional (VMD). Todas as técnicas podem ser utilizadas para diagnosticar falhas em rolamentos e demais componentes de máquinas. Nesta seção, serão discutidas algumas das principais técnicas tradicionais.

#### 2.4.1 Domínios do Tempo e da Frequência

O domínio do tempo consiste na forma do sinal de vibração em relação ao tempo em que ela ocorre e são obtidos diretamente a partir dos acelerômetros posicionados no maquinário. Os sinais que se apresentam no domínio do tempo registram históricos de energia e são amplamente utilizados na extração de dados estatísticos, que podem vir a sinalizar defeitos e auxiliar na avaliação das suas gravidades (SAMAL *et al.*, 2024) É possível observar uma representação do domínio do tempo na Figura 1.

Figura 1 - Exemplo de Domínio do Tempo



Fonte: Elaboração Própria (2025)

A análise realizada no domínio do tempo é considerada a técnica mais direta a ser aplicada em relação à detecção e ao diagnóstico de falhas, pois envolve índices de natureza escalar para determinar as condições de saúde do elemento a ser estudado. Segundo Chen *et al.* (2023), entretanto, as respostas de vibração geram formas de onda complexas, tornando a distinção de sinais corretos e pormenorizados uma tarefa árdua, que vem sendo objeto de investigação de diversos estudiosos ao longo de várias décadas (ALMUTAIRI; SINHA, 2023).

O domínio do tempo-frequência usa simultaneamente do tempo e da frequência para analisar os dados de séries temporais. A análise do domínio do tempo pode fornecer



uma compreensão da saúde motora e possui uma aplicação significativamente simples, enquanto a análise do domínio da frequência diferencia a frequência de falha daquelas que são apenas interferências de ruídos, e é vantajosa porque não necessita de informações prévias para identificar as características de falhas (KUMAR; ANAND, 2024).

Para analisar os sinais obtidos, são utilizados indicadores como média, amplitude de pico a pico, raiz quadrada média (RMS), fator de crista, fator de impulso, índice de energia e curtose (ALONZO-GONZALEZ *et al.*, 2023), sendo a curtose e o fator de forma mais sensíveis a defeitos significativos. A RMS, por sua vez, é um parâmetro amplamente utilizado para medir a gravidade de uma vibração, pois representa a energia geral do sinal e é calculada pela Equação 1 (ALMUTAIRI; SINHA, 2023).

$$RMS = \sqrt{\frac{1}{N} \sum_{j=1}^N |a_j|^2} \quad (1)$$

A curtose é outra medida estatística usada para a caracterização de estruturas de dados distribuídos. Ela é amplamente utilizada na análise de vibrações para auxiliar na detecção de falhas e é de extrema importância para o diagnóstico de falhas em rolamentos, devido à formação de caudas pesadas que aumentam o valor da curtose causadas pelos impactos gerados através das falhas (ALMUTAIRI; SINHA, 2023), e pode ser representada pela Equação 2.

$$K = \frac{\frac{1}{N} \sum_{j=1}^N (a_j - \bar{a})^4}{(\frac{1}{N} \sum_{j=1}^N (a_j - \bar{a})^2)^2} \quad (2)$$

Um método típico de diagnóstico de falhas mecânicas que possui a curtose como núcleo é o curtograma, que se dedica ao aprimoramento dos impulsos transientes repetitivos que são gerados pelas falhas e distingue uma banda de frequência informativa. Para melhorar os sinais da curtose, os valores serão calculados a partir do espectro do envelope e sequência de autocorrelação são introduzidos como critérios de seleção para a banda de frequência ótima (CHEN *et al.*, 2022).

Além destes parâmetros, El Bouharrouti, Morinigo-Sotelo e Belahcen (2024)

também reforçam outros que são importantes, como as variâncias dos sinais que medem as distribuições dos pontos relacionados ao valor médio do mesmo sinal e a assimetria que mede a distribuição da probabilidade. A Tabela 1 apresenta alguns dentre os principais critérios que podem ser analisados no Domínio do Tempo.

Tabela 1 - Atributos do Domínio do Tempo

<b>Atributo</b>	<b>Descrição</b>
<b>Raiz Quadrada Média</b>	Mede o nível geral de um sinal discreto, sendo N o número de pontos discretos que representa o sinal de cada ponto da amostra.
<b>Média</b>	Indica a amplitude de um determinado segmento e indica o primeiro momento dos dados considerados.
<b>Valor de Pico</b>	Aceleração máxima da amplitude do sinal.
<b>Fator de Crista</b>	A razão entre a aceleração de pico e o RMS, detectando rajadas de aceleração mesmo se o RMS permanecer constante.
<b>Assimetria</b>	Usado para medir a assimetria da distribuição de probabilidade junto com a média. É representada de acordo com o terceiro momento de distribuição.
<b>Curtose</b>	Versão escalar do quarto momento e busca encontrar a causa na curva de distribuição da probabilidade.
<b>Variância</b>	Mede indiretamente a distribuição de dados da média do segmento e se caracteriza como sendo o segundo momento central da distribuição.
<b>Desvio Padrão</b>	A raiz quadrada positiva da variância para medir a variação dos dados.
<b>Fator de Folga</b>	Caracteriza-se como sendo o máximo para rolamentos saudáveis e diminui com os rolamentos defeituosos em máquinas rotativas.
<b>Fator de Impulso</b>	Extraí os impulsos e anexa o valor ao recurso retornado pela função de extração.
<b>Fator de Forma</b>	Corresponde ao RMS dividido pela média do valor absoluto e depende do formato do sinal, independentemente das dimensões do sinal.

Fonte: Adaptado de Raqeeb *et al.* (2023)

Para realizar análises mais robustas e identificar a origem da falha nos elementos,

parte-se para o domínio da frequência, que consiste na transformação do sinal em uma série de componentes de frequência discretos, chamando-se de espectro do sinal (ALONZO-GONZALEZ *et al.*, 2023).

Enquanto no domínio do tempo, recursos estatísticos são utilizados, como o fator RMS, a Média, os Valores de Pico, a Curtose, o Fator de Forma, entre outros. Já no domínio da frequência, são utilizadas as técnicas como a Transformada Rápida de Fourier (FFT), Espectro de Potência, Transformada de Wavelet e outras. Nos últimos anos, técnicas de computação estão sendo fundidas com técnicas tradicionais sugerindo abordagens promissoras nos estudos referentes à identificação de falha em rolamentos (KUMAR; ANAND, 2024). A Transformada Rápida de Fourier (FFT) é um dos métodos mais utilizados para a análise de frequência tradicional. Para um sinal ser convertido do domínio do tempo para o domínio da frequência é utilizada a Transformada de Fourier. A maioria dos sinais processados são sinais discretos e não domínios contínuos, então a FFT calcula da Transformada Discreta de Fourier (TDF) de uma sequência, possibilitando a observação dos sinais proeminentes no domínio da frequência, diferentemente do que é visto no domínio do tempo (KUO; CHUANG; LI, 2022).

A FFT é um método de representar um sinal como uma combinação de sinais de seno e cosseno, então o espectro da frequência produzido mostrará as amplitudes e fases dos vários componentes da frequência do sinal de entrada e as assinaturas das falhas podem ser observadas (AYANKOSO *et al.*, 2024). Dentre as propriedades observadas estão as magnitudes dos picos de frequência, a presença de harmônicos, as bandas laterais e a distribuição espectral.

A FFT pode ser utilizada para identificar as frequências de falhas de forma correta e direta a partir da análise do espectro da frequência, possibilitando a extração dos componentes que caracterizam as frequências de falhas para um diagnóstico mais automático em elementos mecânicos (ZHOU *et al.*, 2015).


Do ponto de vista matemático, a FFT transforma a forma de onda de  $x(t)$  com um número  $t$  de amostras no domínio da frequência que será representado por um número de linhas de frequências  $f$ , como mostra a Equação 3.

$$x(k) = \sum_{n=0}^{N-1} x(n) * e^{-i*2*\pi*n*k/N} \quad (3)$$

Os harmônicos são caracterizados por serem múltiplos inteiros da frequência

natural do sistema e se apresentam como picos claros em valores de  $2f$ ,  $3f$  e assim por diante (AYANKOSO *et al.*, 2024). É possível observar uma representação do domínio da frequência utilizando a FFT na Figura 2.

Figura 2 - Exemplo Domínio da Frequência



Fonte: Elaboração Própria (2025)

Para capturar os sinais referentes às frequências, utilizamos parâmetros de coleta, como a frequência de amostragem ( $F_a$ ) – determinado número de amostras por período de frequência de referência – e o número de pontos selecionados ( $N$ ) – número mínimo de ordens a serem retidas em todos os lugares. A frequência de amostragem é proporcional à frequência de referência e varia ao longo do registro, e para que o sinal seja adequadamente filtrado, deve satisfazer a condição imposta por Nyquist (RANDALL, 2021).

O teorema de Nyquist dita que dentro do espectro da frequência pode ocorrer interpretações errôneas de picos de frequências (*aliasing*) devido a taxa de amostragem, se esta não corresponder a, no mínimo, o dobro da maior taxa de frequência a ser coletada (RANDALL, 2021). Já que a velocidade varia em diferentes tipos de faixas, pode ser necessário a alteração das taxas de amostragem para filtrar frequências mais baixas e vice-versa. Outra forma de fazer isso é estabelecer uma taxa fixa que seja muito maior do que a necessária para atender à condição de Nyquist.

O pré-processamento de sinais é realizado para destacar as principais frequências que caracterizam as falhas e, assim, aprimorar a extração de seus atributos. O sinal do impulso de falha do rolamento se modula a partir dos sinais que portam os ruídos e ressonância das máquinas. Então, quando o sinal de falha modulado é transformado para

o espectro da frequência, as características de falhas se mesclam com as demais frequências e se tornam complexas de serem identificadas. Para resolver este problema, é necessária a utilização de técnicas de demodulação do sinal para extrair os sinais de falha satisfatoriamente (KIM; KIM, 2024).

#### **2.4.2 Técnica do Envelope**

A Técnica do Envelope ou Técnica da Ressonância de Alta Frequência é uma das técnicas mais renomadas de análise de vibrações. A região de ressonância é previamente excitada pelo defeito que o componente possui e a aquisição do sinal será feita nesta região. É uma técnica bastante utilizada devido a sua capacidade de realizar a demodulação mesmo com flutuações aleatórias e ruídos (ALMUTAIRI; SINHA, 2023).

A análise do espectro do envelope consiste em uma parte crucial para o processamento de sinais. É a partir do envelope de um sinal de vibração que conseguimos identificar os padrões de vibração do equipamento, identificando as frequências características das falhas e onde estão localizadas (DU *et al.*, 2024). Além disso, o sinal do envelope apresenta informações essenciais sobre as oscilações e os eventos anormais que podem ocorrer durante a operação da máquina.

O sinal de vibração gerado por uma estimulação periódica é um sinal modulado em amplitude. O principal objetivo da análise do envelope é substituir os sinais de vibração de um choque que são causados pela interação dos defeitos presentes nos equipamentos. Assim, a demodulação do sinal é necessária para separar o sinal da frequência portadora de defeito, possibilitando uma melhor visualização dos pulsos de choque (BAUER *et al.*, 2023).

Na análise do envelope, existe um espectro unilateral composto de somente frequências positivas que é inversamente transformado para o domínio do tempo. Assim, esta parte é demodulada de forma efetiva a partir da extração utilizando um filtro e separa os elementos próximos (BAUER *et al.*, 2023).

A análise do envelope surge da necessidade de encontrar precisamente assinaturas de falhas em elementos rotativos e juntamente com outras técnicas de detecção de falhas se mostrou um processo otimizado de detecção de defeitos. Toma, Kim e Kim (2021) ilustram uma utilização da análise do envelope integrada a um modelo de decomposição de modo empírico (EMD) para identificar frequências de ressonância de forma precisa e são eficientes na identificação de falhas em rolamentos. Entretanto, a

eficiência de todos os métodos relacionados à técnica do envelope é diretamente proporcional à escolha dos parâmetros de filtros adequados para que, assim, a aquisição do sinal seja realizada corretamente.

A extração ideal do sinal depende da escolha certa região de ressonância, onde a relação sinal-ruído é maior. Alonso-Gonzalez *et al.* (2023) citam técnicas desenvolvidas para eliminar ruídos que podem prejudicar o diagnóstico. Um método utilizado é o Kurtograma, que extrai a região de frequência ideal, auxiliando quando não existe conhecimento prévio do comportamento da máquina.

Essa técnica é baseada na Curtose Espectral, que é caracterizada por valores altos causados nas regiões onde os defeitos são dominantes e quando os valores são aproximados de zero são dominadas por componentes estacionários, possuindo alta sensibilidade para detecção de defeitos nas regiões onde são maiores (ALONZO-GONZALEZ *et al.*, 2023).

O envelope de Hilbert (representado pela Equação 4) permite uma demodulação complexa e se adapta melhor aos sinais. Este consiste em uma parte real e uma parte imaginária e é uma ferramenta popular e eficaz, pois possibilita encontrar defeitos pequenos de rolamentos e acompanhar a evolução dos defeitos (BAUER *et al.*, 2023). O principal desafio relacionado a esta técnica consiste na escolha correta da janela de análise das falhas e vêm sendo o objeto de estudo de diversos pesquisadores da área.

$$HT[x(t)] = \hat{x}t = A[\cos(\omega t) + j\sin(\omega t)] \quad (4)$$

O valor absoluto do sinal analítico de  $x_h(t)$  é chamado de envelope do sinal bruto e seus harmônicos são claramente visíveis no domínio da frequência (Kim e Kim, 2024).

Os componentes do envelope sempre são analisados no domínio da frequência e mesmo em casos de sinais perturbados ou pulsos de choque fracos, a frequência de repetição ainda pode ser detectada no espectro de frequência do envelope (Bauer *et al.*, 2023).

Bauer *et al.* (2023) definem um tipo de envelope chamado de *Peak-envelope* que observa os picos presentes no espectro. Os picos são definidos como eventos que preenchem o critério de que há um máximo local com uma amplitude acima de um valor de gatilho pré-definido. Entretanto, o seu efeito de demodulação é fraco e o sinal do envelope pode perder as características de amortecimento e harmônicos do sinal, se não

houver solavancos óbvios.

### 2.4.3 Técnica de Wavelet

Os sinais de vibração dos rolamentos podem ser analisados pela Transformada Discreta de Wavelet (DWT), que fornece uma análise múltipla do sinal e oferece uma boa resolução de tempo nas alta e baixa frequências. Segundo Gunerkar, Jalan e Belgamwar (2019), a redução de ruído do sinal de vibração bruto com base na Transformada de Wavelet consiste em 3 (três) etapas básicas:

- a) decompor os sinais de vibração com base na Wavelet Ortogonal para obter o coeficiente detalhado;
- b) suprimir o coeficiente detalhado e manter o nível adequado;
- c) reconstruir o sinal aplicando WT inverso ao coeficiente de limiarização.

Zhang, Zhang e Li (2023) defendem que o requisito para a aplicação da Técnica de Wavelet é restrito e requer conhecimento especializado, necessitando que a “Wavelet Mãe” e seus níveis de decomposição sejam determinados manualmente e com antecedência. Também definem estratégias de decomposição de sinais, como a decomposição da média local (LMD) e o método de diagnóstico de falhas baseado na decomposição de modo empírico (EMD). O LMD é afetado pelo ruído e adiciona componentes redundantes após a decomposição do sinal e o EMD pode extrair os componentes de modo da estrutura local do sinal.

Maliuk, Ahmad e Kim (2023) utilizam o método da transformada de pacotes Wavelet e defendem ser um método mais generalizado em comparação a wavelet básica por se dividir em espectros de frequências mais baixas e mais altas, possibilitando a caracterização de assinaturas de falhas não estacionárias.

A decomposição baseada em Wavelet foi adotada em diversas aplicações, pois oferece uma ferramenta flexível para analisar os sinais com alta resolução do tempo e da frequência. Aburakhia, Myers e Shami (2022) relatam que as técnicas recentes retratadas na literatura dizem respeito ao aumento do poder de discriminação dos recursos extraídos. As principais abordagens baseadas em wavelet são: as baseadas em entropia, as baseadas em energia, as baseadas em espectro e as baseadas em estatística.

A entropia é uma medida de incerteza utilizada para medir a irregularidade dos dados de séries temporais. A partir do conhecimento de que os sinais de vibração saudáveis possuem alta irregularidade perante rolamentos defeituosos, podemos concluir

que a combinação da decomposição de wavelet com medidas de entropia ajudam a quantificar o grau de irregularidade de um sinal de vibração (ABURAKHIA; MYERS; SHAMI, 2022).

A abordagem baseada em energia usa as alterações da energia nas sub-bandas de wavelet para extrair os recursos relacionados a falhas. Entretanto, a alteração do conteúdo de energia não é significativa nos estágios iniciais da falha, porque o conteúdo de energia possui baixa sensibilidade a falhas incipientes (ABURAKHIA; MYERS; SHAMI, 2022).

A abordagem em espectro faz uso das características espectrais das formas de ondas elementares que são reconstruídas para a extração de recursos e, para isso, são utilizadas técnicas de extração, como Fourier, o espectro do envelope ou a curtose espectral (ABURAKHIA; MYERS; SHAMI, 2022).

As abordagens baseadas em estatísticas dependem das propriedades provenientes do domínio do tempo das formas de onda reconstruídas, como assimetria, curtose, RMS, entre outros (ABURAKHIA; MYERS; SHAMI, 2022).

## **2.5 TÉCNICAS DE ANÁLISE DE SINAIS EM DESENVOLVIMENTO**

Com o passar dos anos e o aprimoramento das técnicas utilizadas, diversos estudos começaram a ser desenvolvidos baseando-se em *Machine Learning* e *Deep Learning*, sendo os principais as Redes Neurais Artificiais (ANN), *Support Vector Machines* (SVM), *K-Nearest Neighbor* (KNN), Redes Neurais Convolucionais (CNN) e Redes Neurais Recorrentes (RNN). Todos os métodos podem ser adaptados para serem utilizados em diagnósticos de falhas em máquinas (ABEDIN *et al.*, 2023). Nesta seção, discutiremos as técnicas mais atuais de processamento de sinais.

### **2.5.1 Machine Learning**

Barai *et al.* (2022) discutem sobre a dificuldade dos métodos tradicionais de diagnosticar falhas em componentes a partir da análise de correntes, devido à baixa relação sinal-ruído, harmônicos de baixa altitude, perda de informações no campo magnético, etc. Então, com base no encontrado na literatura, Barai *et al.* (2022) exploram as pesquisas relacionadas às novas técnicas utilizando Inteligência Artificial (IA) e *Machine Learning* (ML).

Pandarakone, Mizuno e Nakamura (2019) justificam dois tipos de algoritmos de



Machine Learning: supervisionados e não supervisionados, sendo os supervisionados compostos por variáveis-alvo que devem ser previstas partindo de um conjunto de variáveis independentes, usadas para gerar função e mapas de entrada a fim de obter a saída desejada. Já os algoritmos não supervisionados não possuem uma variável-alvo e adota-se a técnica de agrupamento, que pode segmentar o grupo e certos níveis de diagnóstico podem ser alcançados.

Dentre os métodos utilizados de ML, o que mais se destaca nas pesquisas é o *Support Vector Machine* (SVM), que é um algoritmo utilizado para reconhecer padrões e possui dois parâmetros básicos: o hiperplano e a margem. O primeiro é responsável por separar conjuntos de dados e classificar, e o segundo é responsável por identificar os vetores de suporte (PANDARAKONE; MIZUNO; NAKAMURA, 2019). O SVM é utilizado para realizar a decomposição de sinal e a computação de entradas de modelo, além de classificar e prever condições de falhas, assim como a transformada de wavelet empírica e a entropia fuzzy (TOMA; KIM; KIM, 2021).

Entretanto, mesmo sendo técnicas de diagnóstico que possuem uma taxa razoável de sucesso, também possuem desvantagens relacionadas à extração dos recursos a partir de técnicas de processamento de sinais que exigem experiência e uma quantidade significativa de tempo (TOMA; KIM; KIM, 2021). Além disso, os processos de extração e seleção de um tipo específico de sinal pode vir a não fornecer resultados que sejam satisfatórios para outros tipos de sinais.

Além disso, outra desvantagem das técnicas que são baseadas no aprendizado de máquina é o fato de que elas exigem uma quantidade exacerbada de dados para serem treinadas e podem exigir demandas computacionais complexas (SACERDOTI; STROZZI; SECCHI, 2023).

### **2.5.2 Redes Neurais**

As Redes Neurais Artificiais (ANN) são modelos computacionais de conjuntos interconectados de elementos e unidades de processamento. Com o passar dos anos, as ANN vêm sendo muito utilizadas em prognósticos, classificação, reconhecimento de padrões, etc. E, cada vez mais, aparecem nas pesquisas relacionadas à detecção de falhas em máquinas e foi bem-sucedida no diagnóstico em rolamentos.

A ANN é composta por nós de processamento artificiais interconectados que são chamados de neurônios e possuem 03 (três) camadas: camada de entrada, camada oculta

e camada de saída. O número de nós nas camadas é ditado pelas variáveis do problema a ser resolvido. Gunerkar, Jalan e Belgamwar (2019) falam sobre estruturas que utilizam apenas um neurônio como forma de processamento, o que causa uma computação lenta.

Uma forma de utilizar as ANN é pelo algoritmo *K-nearest neighbor*, que armazena e classifica os casos disponíveis em uma distância mínima. Possui duas fases principais: o treinamento e as fases de teste. A primeira fase é relacionada ao treinamento dos objetos de diferentes classes a fim de encontrar relações entre preditores e alvos. Na fase posterior, o modelo é testado com base em uma amostra de testes. O KNN utiliza uma distância euclidiana para encontrar os mais próximos de um exemplo. (Gunerkar, Jalan e Belgamwar, 2019).

## CAPÍTULO III

### 3. MATERIAIS E MÉTODOS

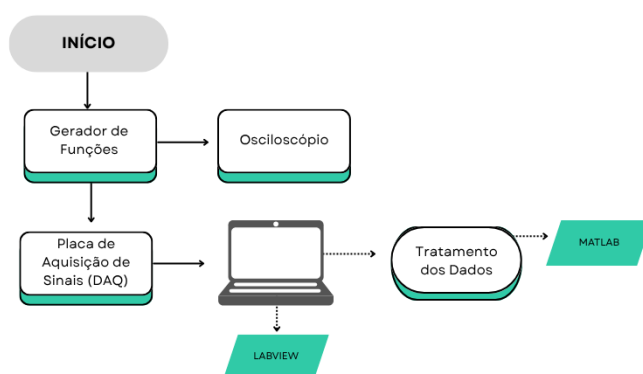
#### 3.1 INTRODUÇÃO

O trabalho apresentado utiliza uma bancada de ensaio experimental para a simulação de sinais elétricos reais com características correspondente aos sinais oriundos de máquinas mecânicas monitoradas. Nesta pesquisa, a contribuição concentra-se na apresentação da metodologia de aquisição de sinais oriundos de um gerador de sinais elétrico simulando condições reais de operação. Nesta seção, são descritos a bancada experimental e os métodos utilizados na pesquisa.

#### 3.2 BANCADA EXPERIMENTAL

A bancada experimental é composta por um gerador de sinais, uma placa de aquisição de dados, um osciloscópio, um computador e *softwares* para o auxílio na coleta e no tratamento dos dados. O fluxograma representado na Figura 3, ilustra a composição da bancada e as conexões entre seus itens.

Figura 3 – Diagrama de Blocos



Fonte: Elaboração Própria (2025)

O sinal elétrico é gerado pelo gerador de funções *Agilent 33220A*, que está conectado ao canal analógico da placa de aquisição de dados da *National Instruments NI 9201*, a qual o envia para o computador por meio de uma porta USB. Neste trabalho, foi necessário utilizar o gerador de sinais na função de sinais arbitrários para que fosse possível criar um sinal com várias frequências, simulando uma situação real de coleta de dados de uma máquina em funcionamento. Para criar a função arbitrária, foi utilizado um *software* específico do gerador para carregar em sua memória uma função como mostrada na Equação 5.

$$y(t) = A\text{sen}(2\pi f_1 t) + B\text{sen}(2\pi f_2 t) + C\text{sen}(2\pi f_3 t) + \dots + Z\text{sen}(2\pi f_n t) \quad (5)$$

Onde:

$y(t)$  representa o sinal elétrico;

$A...Z$  representa as amplitudes das frequências;

$f_1...f_n$  representa as frequências desejadas;

$t$  representa o tempo decorrido.


O osciloscópio foi conectado ao gerador de funções para verificar o sinal gerado e compará-lo com o sinal capturado pela placa de aquisição de dados. O gerador de funções também está conectado à placa de aquisição de sinais que possui uma velocidade máxima de aquisição de 800 ks/s, usando apenas um canal de aquisição, e 12 bits de resolução.

No computador, foram instalados *softwares* para coleta e tratamento de dados, como o LabVIEW e o MATLAB. O LabVIEW foi utilizado para vincular a placa de aquisição de dados ao computador e coletar os sinais gerados a partir de parâmetros de aquisição manipuláveis, como o número de pontos e a frequência de amostragem. Após a coleta, o MATLAB é utilizado para a visualização e tratamento dos dados, conforme as necessidades apresentadas pela pesquisa.

A Figura 4 ilustra a bancada experimental utilizada como base para os testes realizados no ambiente laboratorial, empregada na geração e na coleta dos sinais elétricos. Na imagem, é possível observar o gerador de funções (1), utilizado para gerar os sinais simulados; conectado a um osciloscópio (2) que verifica o sinal simulado; o gerador também se conecta a uma placa de aquisição de dados (3), responsável pela leitura e

aquisição dos dados; que, por fim, conecta-se ao computador (4) que executa um programa de aquisição de sinais com parâmetros manipuláveis no LabVIEW.

Figura 4 - Bancada Experimental



Fonte: Elaboração Própria (2025)

### 3.3 PARÂMETROS DE AQUISIÇÃO

#### 3.3.1 Frequência de Amostragem ( $F_a$ )

O ambiente industrial é repleto de sinais tipicamente contínuos que possuem essas características por se tratarem de sinais analógicos. Entretanto, os dispositivos digitais que são comumente utilizados apenas conseguem armazenar sinais discretos e finitos.

Para que o processo de amostragem seja realizado da forma correta, utilizam-se parâmetros de aquisição manipuláveis. O principal parâmetro de aquisição utilizado é a frequência de amostragem que é a taxa com que um sinal contínuo é convertido para um sinal digital, ou seja, a quantidade de amostras capturadas por unidade de tempo. É necessário definir o intervalo de tempo entre duas amostras do sinal e, para isso, utilizaremos o período de amostragem definido pela Equação 6.

$$T_s = \frac{1}{F_a} \quad (6)$$

Para definir a faixa de frequência do sinal de interesse, é necessário definir a

largura da banda. De acordo com o critério de *Nyquist*, a frequência de amostragem mais baixa possível deve ser maior ou igual a duas vezes a largura da banda, como ilustrado na Equação 7.

$$F_a > 2 * f_{\text{signal}} \quad (7)$$

A definição da frequência de amostragem é de extrema importância para que não aconteça *aliasing*, fenômeno de apresentação de frequências falsas. O *aliasing* acontece quando um sinal é amostrado com uma taxa de amostragem insuficiente e não satisfaz ao Teorema de *Nyquist*, que estabelece que a taxa de amostragem de um sinal deve ser duas vezes maior que a frequência de *Nyquist*, ou seja, duas vezes maior que a maior frequência a ser encontrada no espectro.

Quando o sinal tem frequência maior do que àquelas que a janela de amostragem suporta, retornam ao espectro como frequências falsas. Isso acontece porque o processo de amostragem não foi capaz de capturar o período do sinal completo, causando um efeito de *aliasing* (falsa frequência) no espectro

### 3.3.2 Número de Pontos (N)

O número de pontos (N) diz respeito à quantidade de amostras que serão coletadas de um sinal durante um determinado período de tempo. O número de pontos impacta diretamente no espectro que será modulado por se conectar a resolução da frequência (df).

A resolução de frequência ou taxa de frequência pode ser definida como o intervalo entre pontos consecutivos no espectro da frequência. Por exemplo, se df for igual a 0,1 Hz, o espectro distinguirá os componentes de frequência separados a cada 0,1 Hz.

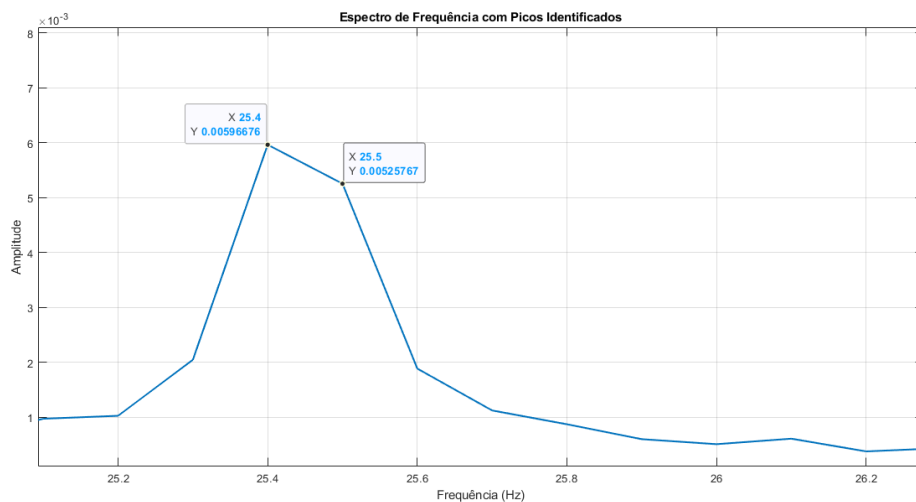
A resolução em frequência faz a identificação correta dos componentes espectrais, permitindo o diagnóstico preciso caso haja frequências de falhas em componentes mecânicos, como rolamentos e engrenagens.

A taxa de frequência é importante pois a partir dela pode ocorrer um fenômeno chamado *leakage* (vazamento espectral), que acontece quando o sinal analisado não se encontra na porção periódica dentro da janela de amostragem definida pela resolução de frequência (df), ou seja, o sinal não completa um número inteiro de ciclos em um

determinado intervalo de tempo.

Quando a FFT é aplicada, o sinal se torna periódico e a janela de amostragem possui um número de ciclos. Quando esse número de ciclos não corresponde a uma frequência existente, a sua energia se espalha para outras frequências próximas, criando picos ou vazamentos, camuflando a frequência real do sinal, como apresentado na Figura 5. Nesta figura, está mostrado um pico em 25,4 Hz e outro em 25,5 Hz. Neste caso, não é possível afirmar se a frequência do sinal é uma ou outra, ou se existe alguma frequência entre elas, ou se apresentam dois picos de frequências. Este é o problema de aquisição que a proposta deste trabalho apresenta uma maneira de resolver.

Figura 5 - Exemplo de *Leakage*



Fonte: Elaboração Própria (2025)

### 3.4 EXPLICAÇÃO DO MÉTODO

Durante a aquisição e análise de sinais digitais, alguns fenômenos podem ocorrer e os mais comuns são *aliasing* e *leakage*, que se apresentam durante a identificação da frequência após a utilização da FFT.

Portanto, o método proposto busca uma estratégia para evitar que esses fenômenos ocorram na aquisição do sinal e que a análise do espectro da frequência não seja feita de forma equivocada, possibilitando que a frequência correta seja devidamente encontrada.

As frequências as quais os testes foram submetidos estão relacionadas na Tabela 2 e foram escolhidas ao acaso, sendo harmônicas perfeitas entre si ou não, com o

propósito de simular sinais de máquinas mecânicas monitoradas da forma mais real possível.

Tabela 2 - Frequências dos Sinais

<b>Testes</b>	<b>Frequências</b>
<b>Teste 01</b>	$f_1 = 33,33 \text{ Hz};$ $f_2 = 66,66 \text{ Hz};$ $f_3 = 166,65 \text{ Hz}.$
<b>Teste 02</b>	$f_1 = 81,24 \text{ Hz};$ $f_2 = 162,42 \text{ Hz};$ $f_3 = 406,18 \text{ Hz}.$
<b>Teste 03</b>	$f_1 = 66,21 \text{ Hz};$ $f_2 = 132,42 \text{ Hz};$ $f_3 = 264,84 \text{ Hz}.$
<b>Teste 04</b>	$f_1 = 155,21 \text{ Hz};$ $f_2 = 310,42 \text{ Hz};$ $f_3 = 465,63 \text{ Hz}.$
<b>Teste 05</b>	$f_1 = 13,48 \text{ Hz};$ $f_2 = 40,44 \text{ Hz};$ $f_3 = 94,36 \text{ Hz};$ $f_4 = 107,84 \text{ Hz}.$
<b>Teste 06</b>	$f_1 = 10,55 \text{ Hz};$ $f_2 = 63,3 \text{ Hz};$ $f_3 = 73,85 \text{ Hz};$ $f_4 = 94,95 \text{ Hz}.$
<b>Teste 07</b>	$f_1 = 24,57 \text{ Hz};$ $f_2 = 49,14 \text{ Hz}.$
<b>Teste 08</b>	$f_1 = 63,14 \text{ Hz};$ $f_2 = 189,42 \text{ Hz};$ $f_3 = 252,56 \text{ Hz}.$
<b>Teste 09</b>	$f_1 = 36,61 \text{ Hz};$ $f_2 = 73,22 \text{ Hz}.$

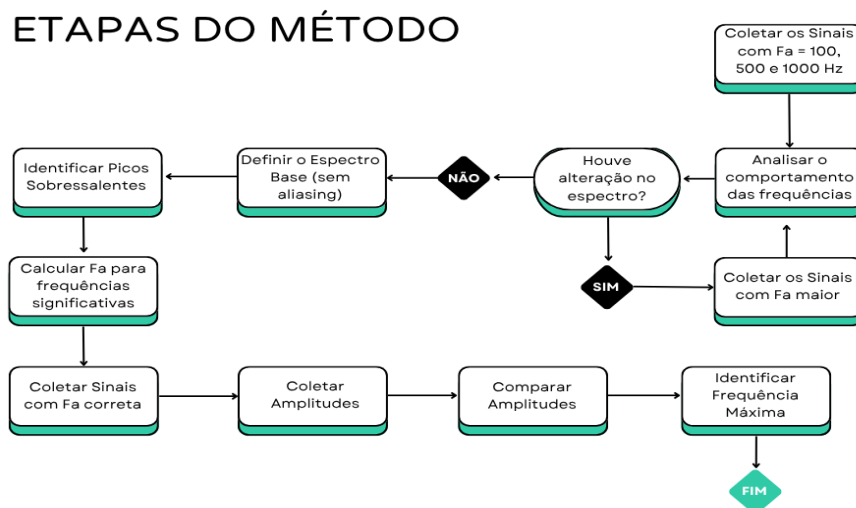


<b>Teste 10</b>	$f_1 = 27,84 \text{ Hz};$ $f_2 = 83,52 \text{ Hz};$ $f_3 = 194,88 \text{ Hz}.$
<b>Teste 11</b>	$f_1 = 7,89 \text{ Hz};$ $f_2 = 23,67 \text{ Hz}.$
<b>Teste 12</b>	$f_1 = 10,25 \text{ Hz};$ $f_2 = 30,75 \text{ Hz};$ $f_3 = 41 \text{ Hz}.$

Fonte: Elaboração Própria (2025)

Para encontrar cada frequência exata foi considerada uma frequência dominante (frequência fundamental) que possui a maior amplitude porque esta representará a componente do sinal que contém a maior parte da energia. A definição da frequência dominante reflete a característica mais proeminente do sinal, sendo imprescindível para a análise de defeitos em elementos mecânicos de máquinas. Para que o encontro da frequência correta seja possível, os fenômenos discutidos de *aliasing* e *leakage* devem ser mitigados. A metodologia proposta segue as etapas ilustradas na Figura 6 com o objetivo de eliminar os fenômenos que corrompem as informações do sinal e para encontrar a frequência dominante correta.

Figura 6 - Etapas do Método



Fonte: Elaboração Própria (2025)

Para evitar o fenômeno de *aliasing*, necessita-se aumentar a taxa de amostragem do sinal para que obedeça o Teorema da Amostragem e capture todas as frequências existentes no sinal. O principal problema é que não é possível definir qual o número exato que condiz ao dobro da frequência, já que ela é desconhecida, então é necessário que tentativas sejam repetidas para observar o comportamento da frequência e entender se a taxa de amostragem experimentada corresponde ao esperado.

No método proposto, utilizam-se taxas de amostragem de 100 Hz, 500 Hz e 1000 Hz para analisar o comportamento dos picos de frequência, observando quais desaparecem e quais permanecem a fim de dar continuidade ao tratamento dos dados. Ao observar o comportamento dos picos de frequência, é possível determinar um espectro com parâmetros base que respeitem o Teorema da Amostragem, retornando um espectro com picos de frequências corretos, sem a presença de frequências falsas.

Para evitar o *leakage*, o processo pode ser mais complexo. Para isso, será utilizada uma janela de amostragem que contenha um número inteiro de ciclos do sinal, ou seja, os sinais serão coletados com as frequências de amostragem corretas de forma a encontrar a resolução de frequência ideal.

Com a posse do espectro base sem *aliasing*, é possível identificar os picos máximos de frequências presentes e, a partir deles, é possível calcular as frequências de amostragem das frequências significativas de acordo com a taxa de frequência (df) do espectro base.

O método se propõe a ser desenvolvido na aquisição e análise dos sinais nos domínios do tempo e da frequência, iniciando as análises com uma resolução espectral preliminar de 0,1 Hz ou 0,2 Hz e identificando os picos proeminentes. A partir dessa resolução, as frequências de amostragem corretas para cada pico de frequência significativo podem ser calculadas.

Os picos de frequências significativos serão indicados a fim de cobrir todas as frequências que não estão compreendidas dentro da resolução espectral inicial, entendendo o comportamento que os valores possuem quando ilustrados no espectro da frequência. Por exemplo, se determinado sinal possui a frequência dominante em 10,23 Hz e foi coletado com uma taxa de frequência de 0,1 Hz, o pico ilustrado estará presente em 10,2 Hz, e o mesmo aconteceria se a frequência fosse de 10,16 Hz. Portanto, é necessário coletar os sinais para abranger todas as frequências que não estão presentes no número de ciclos da taxa de frequência.

Para calcular a  $F_a$  correta para as frequências significativas, a metodologia propõe que o número de pontos do espectro base permaneça fixo, enquanto a frequência de amostragem deve crescer até convergir para um valor de resolução em frequência no qual a Equação 8 pertença ao conjunto dos números naturais, ou seja, retorne um número inteiro positivo. Dessa forma, a frequência esperada será capturada de forma exata, se ela existir.

$$x = \frac{f_{\text{sinal}}}{df} \mid x \in \mathbb{N} \quad (8)$$

Quando todos os sinais são coletados, as amplitudes de todas as frequências significativas serão coletadas e comparadas entre si a fim de encontrar qual possui a maior amplitude.

Conforme a amplitude aumenta, ocorre a convergência para a frequência dominante exata, que corresponde à oscilação mais perceptível ou intensa do sinal original. Em sinais com ruídos, outras frequências possuem amplitudes significativas e várias frequências podem ter amplitudes semelhantes, mas a dominante será aquela com maior contribuição energética, ou seja, com a maior amplitude.

Para validar os resultados coletados e avaliar a precisão e eficácia do método de forma analítica, utiliza-se uma percentagem de erro que é calculada pela diferença entre os valores da frequência inicial submetida ao gerador de sinais e aquela que foi capturada após todos os passos da metodologia, conforme mostrado na Equação 9. Após isto, o cálculo da Equação 10 será realizado, coletando a percentagem de erro entre cada uma das frequências coletadas.

$$\textit{Erro Absoluto} = | \textit{Valor Inicial} - \textit{Valor Coletado} | \quad (9)$$

$$\textit{Erro} (\%) = \left( \frac{\textit{Erro Absoluto}}{\textit{Valor Inicial}} \right) * 100 \quad (10)$$

Com todos os passos realizados, o método procura alcançar os objetivos propostos e encontrar as frequências dominantes durante os testes realizados em ambientes controlados simulando sinais reais. A abordagem pode ser adaptada para diferentes aplicações mediante ajustes nos parâmetros de aquisição de acordo com as necessidades de cada situação encontrada.

### 3.5 SOFTWAREs

Para apoiar as etapas percorridas pela metodologia, foram utilizados *softwares* para a coleta e para o tratamento dos dados, conforme serão indicados nesta seção.

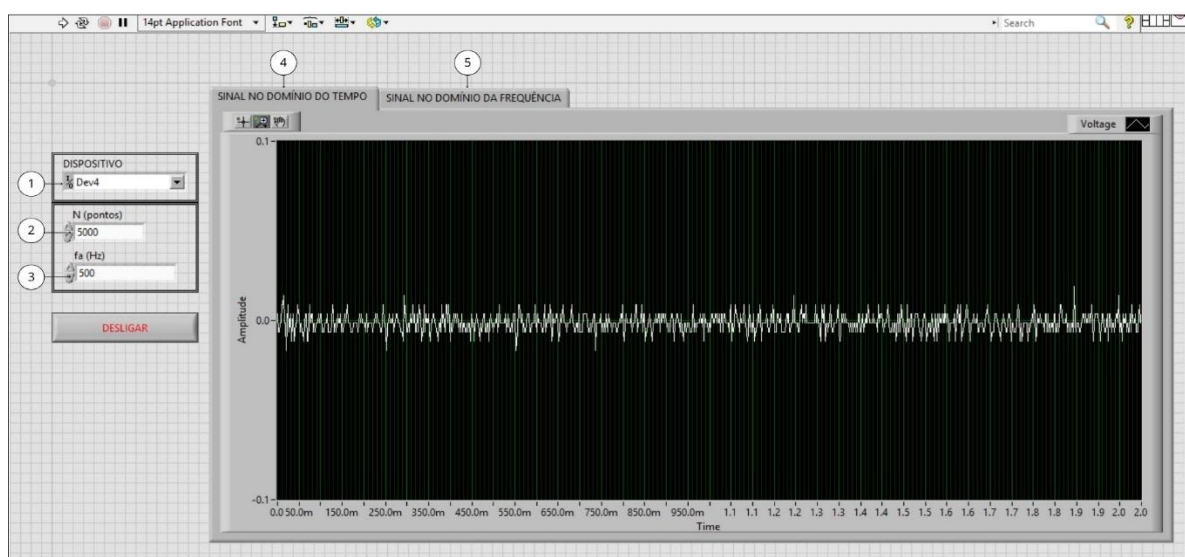
#### 3.5.1 LabVIEW

O Laboratory Virtual Instrumentation Engineering Workbench (LabVIEW) é um *software* que utiliza uma linguagem de programação gráfica a partir de fluxos de dados na qual programas podem ser estruturados a partir da escolha, posicionamento e ligação de blocos. É uma plataforma otimizada e amplamente utilizada na automação e instrumentação de sistemas elétricos e mecânicos por apresentar fácil usabilidade na aquisição de dados por meio de dispositivos de *hardware*.

Para a metodologia, foi desenvolvido um programa em LabVIEW para realizar a coleta dos dados gerados a partir de parâmetros manipuláveis pelo usuário, como o dispositivo (1), o número de pontos (2) e a frequência de amostragem (3). O programa realiza cálculos para gerar os espectros no domínio do tempo (4) e, utilizando FFT, do domínio da frequência (5), mostrando o comportamento do sinal e as amplitudes das frequências, como ilustrado na Figura 5.

O código é executado pelo tempo que for requisitado pelo usuário e quando o botão “Desligar” é acionado, o programa gerará um arquivo de extensão .lvm (LabVIEW Measurement File) com os dados que foram coletados.

Figura 7 - Tela LabView



Fonte: Elaboração Própria (2025)

### 3.5.2 MATLAB

O MATLAB é um software de cálculo numérico amplamente utilizado nas engenharias e possui diversas aplicações, como operações com matrizes, processamento e aquisição de sinais, visão computacional, entre outras ferramentas.

O MATLAB é utilizado em dois momentos na metodologia realizada. No primeiro momento, executa-se o código referenciado no Apêndice I, que lê o sinal coletado anteriormente e extrai as informações inerentes a este, como o número de pontos, que, juntamente com a frequência de amostragem, permitem calcular os demais parâmetros do sinal, como o vetor de tempo, o vetor de frequência e a resolução em frequência. Então, a FFT pode ser calculada e as imagens referentes aos domínios do tempo e da frequência podem ser geradas.

O objetivo do código é calcular as frequências de amostragem para determinados picos de frequência dos sinais. Para isso, será utilizada uma função que identifica os picos máximos locais do espectro de base determinado, permitindo definir critérios de análise como altura mínima do pico de amplitude e a distância mínima entre os picos.

Para encontrar as frequências de amostragem corretas, utiliza-se a resolução em frequência, de forma que quando os parâmetros **N** (número de pontos) e **F<sub>a</sub>** (frequência de amostragem) são alterados, o **df** (taxa de frequência) também se altera. A Equação 11 ilustra o cálculo correspondente à taxa de frequência.

$$df = \frac{Fa}{N} \quad (11)$$

Se a frequência do sinal for um múltiplo inteiro da resolução em frequência, isso implica que a frequência de amostragem utilizada capturará a frequência do sinal exata, se ela existir. A metodologia utilizada no MATLAB busca encontrar a frequência de amostragem exata para satisfazer a condição de encontrar as frequências dos sinais indicadas, utilizando o espectro de frequência como base.

O sinal utilizado como base deve ser aquele que possui o espectro com a frequência de amostragem que atende o critério de *Nyquist*, de forma a acrescentar valores à frequência de amostragem inicial sem violar o teorema. Por sua vez, o número de pontos do espectro base permanecerá fixo e apenas a frequência de amostragem irá aumentar até convergir para que a frequência esperada do sinal seja um múltiplo inteiro da resolução em frequência.

Dessa forma, a metodologia retornará os valores das frequências de amostragem para cada um dos valores esperados, permitindo que novas coletas de dados sejam realizadas e que as amplitudes correspondentes a cada uma sejam coletadas.

O segundo código utilizado no MATLAB, descrito no Apêndice II, propõe a indicação das frequências e suas respectivas amplitudes. Por sua vez, o programa retornará qual frequência possui o maior pico de amplitude.

## CAPÍTULO IV

### 4. RESULTADOS E DISCUSSÕES

#### 4.1 INTRODUÇÃO

Nessa seção, serão apresentados os resultados coletados a partir dos experimentos realizados em condições controladas, replicando as condições operacionais de máquinas rotativas reais. Os dados serão exibidos e analisados, e os parâmetros de aquisição serão refinados quando necessários a fim de garantir a validade do estudo e o alcance dos objetivos propostos com o método.

#### 4.2 APRESENTAÇÃO DOS RESULTADOS

Nesta seção, serão apresentados os resultados obtidos em 12 testes, com o objetivo de comparar e analisar os resultados obtidos com os resultados esperados, para calcular uma taxa de erro, além de analisar o comportamento da frequência quando submetida a situações diversas.

##### 4.2.1 Teste 01

O primeiro teste diz respeito ao sinal gerado pela Equação 12, somado a um fenômeno de ruído para simular satisfatoriamente um sinal real. Este sinal possui uma curva senoidal, como a mostrada na Figura 8.


$$y(t) = A\text{sen}(2\pi f_1 t) + B\text{sen}(2\pi f_2 t) + C\text{sen}(2\pi f_3 t) + \text{Noise} \quad (12)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 33,33 \text{ Hz}$ ;  $f_2 = 66,66 \text{ Hz}$ ;  $f_3 = 166,65 \text{ Hz}$ ;

- *Noise* = variável de ruído.


Figura 8 - Forma de Onda do Teste 01



Fonte: Elaboração Própria (2025)

A forma de onda representa um fragmento do sinal, com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas. Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 9. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 9 - Domínio do Tempo do Teste 01



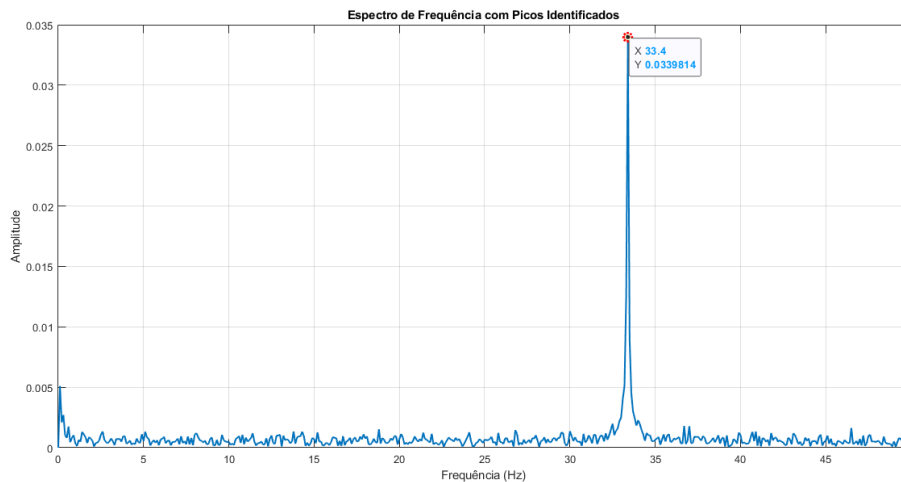
Fonte: Elaboração Própria (2025)

Nesse caso, o sinal foi coletado com os parâmetros de amostragem de  $N = 1000$  e  $F_a = 100$ , conseguindo a aquisição do espectro de frequência mostrado na Figura 10. O fenômeno de *aliasing* ilustrado na figura é mascarado pelo fato de que as demais



frequências que não correspondem ao espectro se apresentam sobrepostas umas às outras no pico de 33,4 Hz.


Figura 10 - Espectro para  $F_a = 100$  e  $N = 1000$



Fonte: Elaboração Própria (2025)

Após isto, as frequências foram novamente coletadas, com os parâmetros de  $N = 5000$  e  $F_a = 500$ , como ilustrado na Figura 11. Nesse espectro, é possível perceber que os picos correspondentes às frequências indicadas se tornam visíveis, erradicando o fenômeno de *aliasing* presente no espectro anterior. Os demais picos que não se configuram às frequências e picos indicados se apresentam devido ao ruído que foi imputado à função original. Dentro do fenômeno de ruído, ocorre a soma de senos e cossenos de frequências ômega, e ao se somarem à função original, evidenciam os harmônicos das frequências introduzidas, como pode ser percebido no espectro ilustrado na Figura 11.

Figura 11 - Espectro para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Sabendo que estes picos de frequências correspondem a frequências existentes, é possível utilizar os parâmetros base para calcular as taxas de amostragem corretas para outras frequências de sinais, escolhendo-se um intervalo de  $\pm 5$  pontos de frequências. Isto ocorre porque, na expressa maioria das vezes, as frequências que se apresentam com números relativos a 0,05 são arredondados para o valor imediatamente acima, e os menores arredondados para o valor imediatamente abaixo. Por exemplo, no caso de uma frequência de valor 13,67 Hz, o espectro com resolução de frequência de 0,1 Hz apresentará 13,7 Hz como o pico de frequência. Do mesmo modo, se a frequência for 13,72 Hz, também se apresentará como 13,7 Hz, e isso justifica a escolha das frequências dos sinais procuradas.

A resposta do programa MATLAB para encontrar as frequências de amostragem corretas é coletada. Considerando que o número de pontos é estático e não mudará neste caso, apenas as frequências de amostragem sofrerão alterações com o objetivo de ajustar a resolução em frequência (**df**) para um número no qual a frequência do sinal a ser adquirido seja um múltiplo inteiro.

Em seguida, as taxas de amostragem encontradas são utilizadas na coleta dos sinais, o espectro da frequência é analisado e a amplitude da frequência encontrada é armazenada. Em alguns casos, as frequências podem não coincidir com as esperadas, o que permite inferir que as frequências desejadas são inexistentes. Outras frequências aparecerão no lugar destas e suas amplitudes também devem ser analisadas, visto que são as mais próximas encontradas em relação aos valores esperados. Então, relacionam-se as amplitudes referentes às frequências conforme mostrado na Tabela 3, ilustrando também

as frequências de amostragem utilizadas para capturar cada frequência.

Nos testes, foram considerados sete casas decimais para diferenciar qual dentre as frequências possui a maior amplitude, visto que a diferença entre alguns dos valores só pode ser percebida após com esses valores.

Tabela 3 - Frequências e Amplitudes do Teste 01

33,3				66,7				166,6			
<i>F<sub>esperada</sub></i>	Amplitude	Fa	df	<i>F<sub>esperada</sub></i>	Amplitude	Fa	df	<i>F<sub>esperada</sub></i>	Amplitude	Fa	df
33,26	0,037515	1663	0,3326	66,52	0,02806	1663	0,3326	166,45	0,027789	3329	0,6658
33,27	0,036451	1109	0,2218	66,54	0,02294	1109	0,2218	166,55	0,029801	3331	0,6662
33,28	0,028323	512	0,1024	66,58	0,035163	3329	0,6658	166,572	0,027427	1109	0,2218
33,29	0,040293	3329	0,6658	66,62	0,035226	3331	0,6662	166,6	0,026684	500	0,1
33,3	0,035942	500	0,1	66,625	0,032254	625	0,125	166,605	0,028148	512	0,1024
33,31	0,040339	3331	0,6662	66,64	0,035257	595	0,119	166,625	0,029845	625	0,125
33,32	0,040007	595	0,119	66,66	0,034733	505	0,101	166,633	0,029708	1663	0,3326
33,33	0,040378	505	0,101	66,662	0,035206	512	0,1024	166,635	0,029683	575	0,115
33,34	0,040346	1667	0,3334	66,68	0,035024	1667	0,3334	166,65	0,027391	505	0,101
33,35	0,037187	575	0,115	66,7	0,025509	500	0,1	166,7	0,027449	1667	0,3334
33,375	0,030493	625	0,125								

Fonte: Elaboração Própria (2025)

As frequências que possuem as maiores amplitudes estão ilustradas na tabela. Desta forma, os valores podem ser comparados com a frequência indicada primordialmente e é possível calcular a taxa de erro aproximada, como visto na Tabela 4.

Tabela 4 - Comparação de Frequências

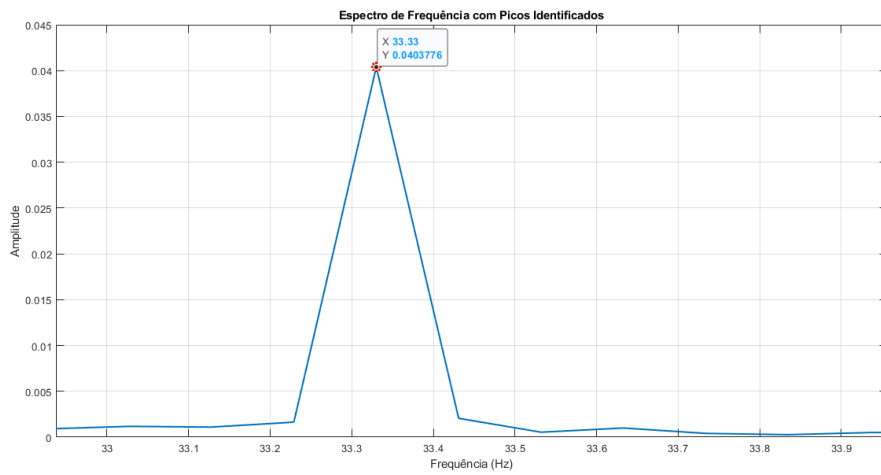
<i>F<sub>indicada</sub></i> (Hz)	<i>F<sub>aqusitada</sub></i> (Hz)	Taxa de Erro (%)
33,33	33,33	0
66,66	66,64	0,03
166,65	166,625	0,015

Fonte: Elaboração Própria (2025)

Dentre as três maiores frequências, a frequência com a maior amplitude corresponde a frequência de 33,33 Hz. É possível perceber que os valores coletados possuem taxas de erros baixas de, aproximadamente, 0%, 0,03% e 0,015%, respectivamente.


Observando a ocorrência dos picos máximos em relação à amplitude, pode-se perceber que as frequências dominantes são encontradas e que todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, conforme proposto pelas etapas minuciosas do teste. Os picos dominantes estão ilustrados nas Figuras 12, 13 e 14.

Figura 12 - Pico para 33,33 Hz, com  $F_a = 505$  e  $N = 5000$



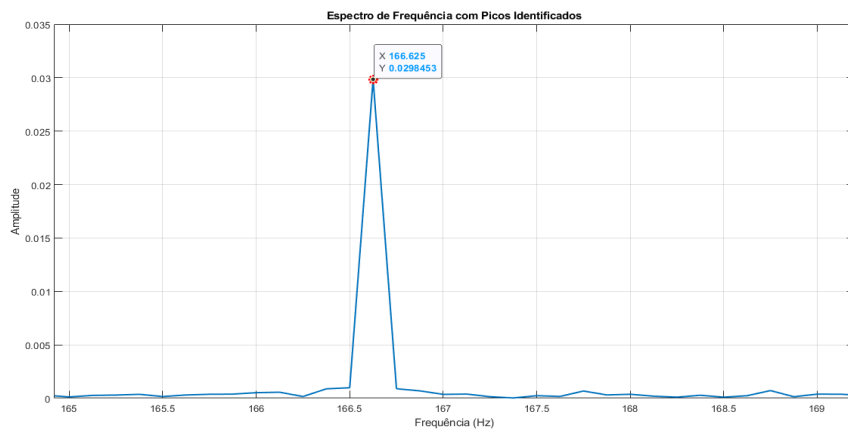
Fonte: Elaboração Própria (2025)

Figura 13 - Pico para 66,64 Hz, com  $F_a = 595$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 14 - Pico para 166,675 Hz, com  $F_a = 625$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.2.2 Teste 02


Esse teste diz respeito ao sinal gerado pela Equação 13 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 15.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + \text{Noise} \quad (13)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 81,24 \text{ Hz}$ ;  $f_2 = 162,42 \text{ Hz}$ ;  $f_3 = 406,18 \text{ Hz}$ ;
- $\text{Noise}$  = variável de ruído.

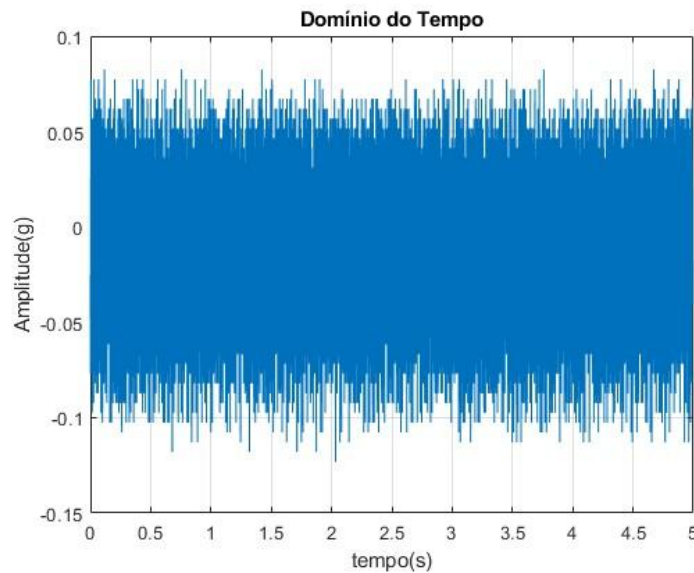
Figura 15 - Forma de Onda do Teste 02



Fonte: Elaboração Própria (2025)

A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas. Ao realizar a aquisição do sinal com o vetor de tempo de 5 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 16. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

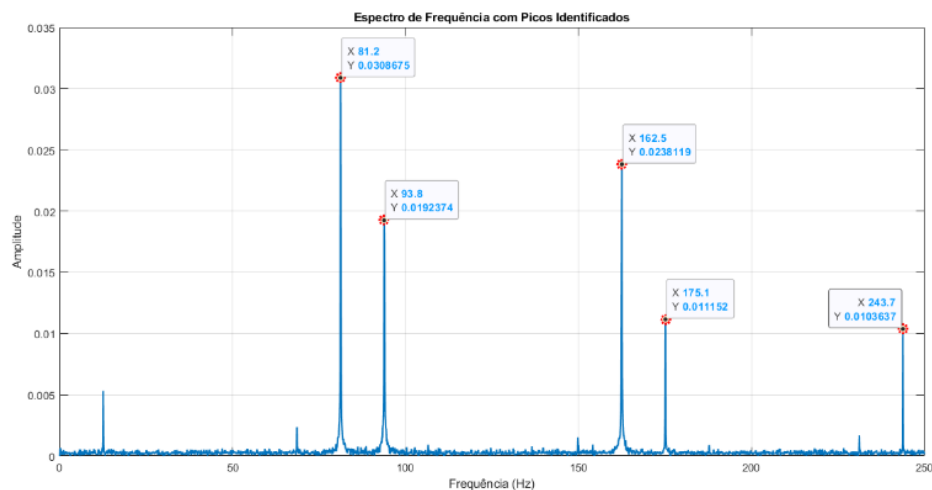
Figura 16 - Domínio do Tempo do Teste 02



Fonte: Elaboração Própria (2025)


Nesse caso, os dados foram coletados com  $N = 5000$  e  $F_a = 500$ , gerando o espectro de frequência da Figura 17, que apresenta 05 picos de frequências significativos. Em seguida, coletou-se novamente com  $N = 5000$  e  $F_a = 1000$  e foi obtido o espectro da Figura 18. Nesse espectro, as frequências falsas causadas pelo *aliasing* foram erradicadas e os picos sobressalentes dizem respeito às frequências indicadas. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 17 - Espectro para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 18 - Espectro para  $F_a = 1000$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

É possível perceber uma mudança significativa no espectro da frequência, algumas frequências desapareceram e outras surgiram quando se altera a Frequência de Amostragem. Com os padrões base estabelecidos, é possível encontrar as frequências de amostragem corretas para cada um dos pontos correspondentes e coletar as amplitudes de cada um conforme observado na Tabela 5, que também ilustra as frequências de amostragem utilizadas para a coleta de cada frequência.

Tabela 5 - Frequências e Amplitudes para Teste 02

81,2				162,4				406,2			
$F_{esperada}$	Amplitude	$F_a$	df	$F_{esperada}$	Amplitude	$F_a$	df	$F_{esperada}$	Amplitude	$F_a$	df
81,15	0,029224	1082	0,2164	162,32	0,025547	2029	0,4058	405,85	0,028165	8117	1,6234
81,16	0,034549	2029	0,4058	162,34	0,031687	8117	1,6234	406,05	0,028579	2707	0,5414
81,17	0,036039	8117	1,6234	162,36	0,020859	1025	0,205	406,1	0,027753	1310	0,262
81,18	0,032911	1025	0,205	162,38	0,02653	1150	0,23	406,105	0,027425	1025	0,205
81,19	0,034898	1150	0,23	162,4	0,026392	1000	0,2	406,15	0,028641	8123	1,6246
81,2	0,034876	1000	0,2	162,42	0,030981	2707	0,5414	406,18	0,025985	1150	0,23
81,21	0,036445	2707	0,5414	162,44	0,030638	1310	0,262	406,183	0,026181	1082	0,2164
81,22	0,036044	1310	0,262	162,46	0,030979	8123	1,6246	406,2	0,02627	1000	0,2
81,23	0,036084	8123	1,6246	162,48	0,030496	1354	0,2708	406,206	0,027265	2029	0,4058
81,24	0,035948	1354	0,2708	162,5	0,029764	1250	0,25	406,25	0,022422	1250	0,25
81,25	0,035873	1250	0,25	162,516	0,026731	1082	0,2164				

Fonte: Elaboração Própria (2025)

Analisando as amplitudes, é possível encontrar os picos mais proeminentes como sendo 81,21 Hz, 162,34 Hz e 406,15 Hz. Dentre estas, pode-se ver que o pico maior é aquele correspondente a 81,21 Hz, conforme observado na Tabela 5. Percebe-se que a frequência encontrada é um pouco diferente daquela que foi submetida, mas ainda está

dentro dos padrões de erro que podem ser tolerados.

A Tabela 6 apresenta a comparação entre os valores obtidos e os valores inicialmente indicados, mostrando a taxa de erro existente de, aproximadamente, 0,037%, 0,086% e 0,012%, respectivamente.

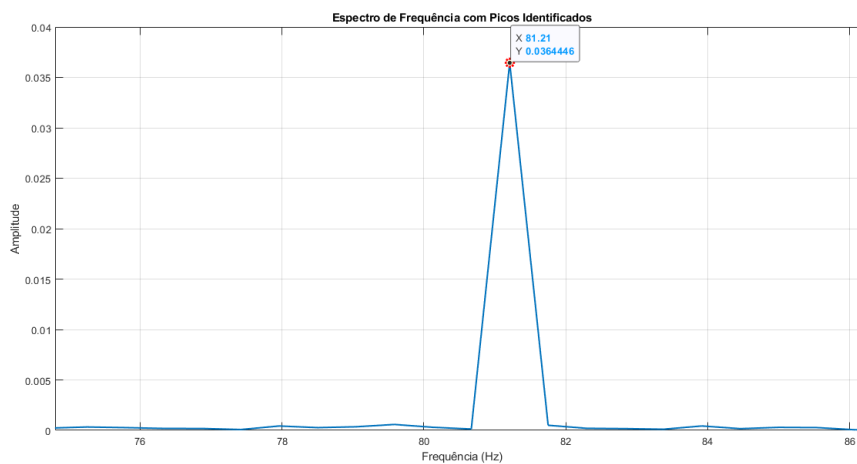
Tabela 6 - Comparação de Frequências

$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
81,24	81,21	0,037
162,48	162,34	0,049
406,2	406,15	0,007

Fonte: Elaboração Própria (2025)

Observando a ocorrência dos picos máximos em relação à amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 19, 20 e 21.

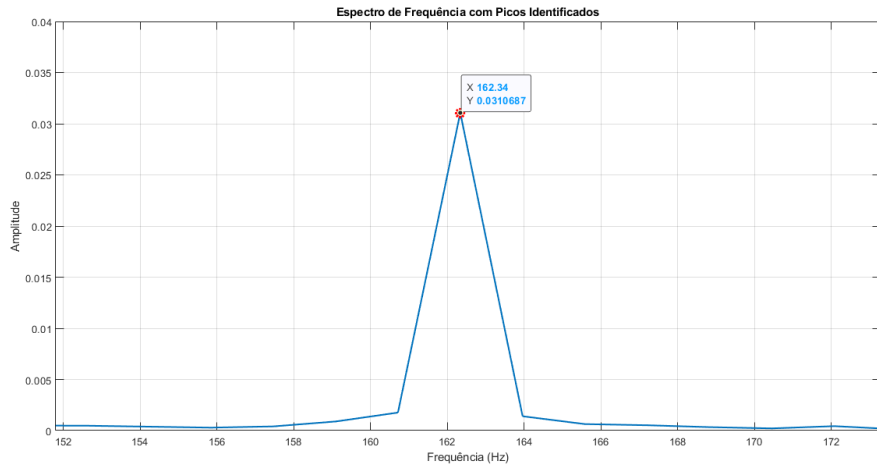
Figura 19 - Pico para 81,21 Hz, com  $F_a = 2707$  e  $N = 5000$



Fonte: Elaboração Própria (2025)




Figura 20 - Pico para 162,34 Hz, com  $F_a = 8117$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 21 - Pico para 406,15 Hz, com  $F_a = 8123$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

### 4.2.3 Teste 03


Esse teste diz respeito ao sinal gerado pela Equação 14 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Este sinal possui uma curva senoidal, como a mostrada na Figura 22. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + Noise \quad (14)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 66,21 \text{ Hz}$ ;  $f_2 = 132,42 \text{ Hz}$ ;  $f_3 = 264,84 \text{ Hz}$ ;
- $Noise$  = variável de ruído.


Figura 22 - Forma de Onda do Teste 03



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 5 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 23. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 23 - Domínio do Tempo do Teste 03

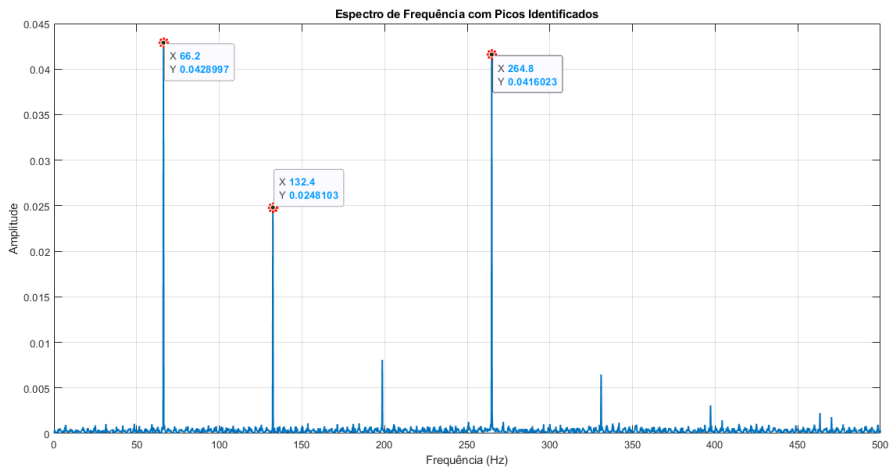


Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de aquisição de  $N = 5000$  e  $F_a = 500$  e para  $N = 5000$  e  $F_a = 1000$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 500$

apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 1000$ , portanto, são frequências falsas que foram eliminadas. Então, o espectro base correto é o que é mostrado na Figura 24. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 24 - Espectro da Frequência para  $F_a = 1000$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 1000$ , é possível encontrar as frequências de amostragem corretas e aquisitar os sinais das frequências correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 7, que também ilustra as frequências de amostragem utilizadas para coletar cada uma das frequências.

Tabela 7 - Frequências e Amplitudes do Teste 03

66,2				132,4				264,8			
$F_{esperada}$	Amplitude	$F_a$	$\Delta f$	$F_{esperada}$	Amplitude	$F_a$	$\Delta f$	$F_{esperada}$	Amplitude	$F_a$	$\Delta f$
66,15	0,0276521	1050	0,21	132,32	0,0157292	1654	0,3308	264,72	0,0336711	1103	0,2206
66,16	0,0387225	1654	0,3308	132,36	0,0229305	1103	0,2206	264,741	0,0365392	1479	0,2958
66,17	0,0365856	1018	0,2036	132,37	0,0214331	1085	0,217	264,76	0,04168	6619	1,3238
66,18	0,0420261	1103	0,2206	132,38	0,0246026	6619	1,3238	264,77	0,0346207	1450	0,29
66,19	0,0429551	6619	1,3238	132,394	0,0241956	1249	0,2498	264,788	0,0391298	1060	0,212
66,2	0,0428997	1000	0,2	132,4	0,0248103	1000	0,2	264,8	0,0416023	1000	0,2
66,21	0,0432246	2207	0,4414	132,405	0,024438	1261	0,2522	264,805	0,0421788	1055	0,211
66,22	0,0411799	1075	0,215	132,42	0,0244723	2207	0,4414	264,84	0,041336	2207	0,4414
66,23	0,0414129	1790	0,358	132,44	0,0198485	1075	0,215				
66,24	0,0355386	1035	0,207	132,46	0,0196873	1790	0,358				
66,25	0,0289799	1250	0,25								

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, é possível comparar o valor coletado com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0%, 0,015% e 0,013%, aproximadamente, conforme ilustrado na Tabela 8.

Tabela 8 - Comparação de Frequências

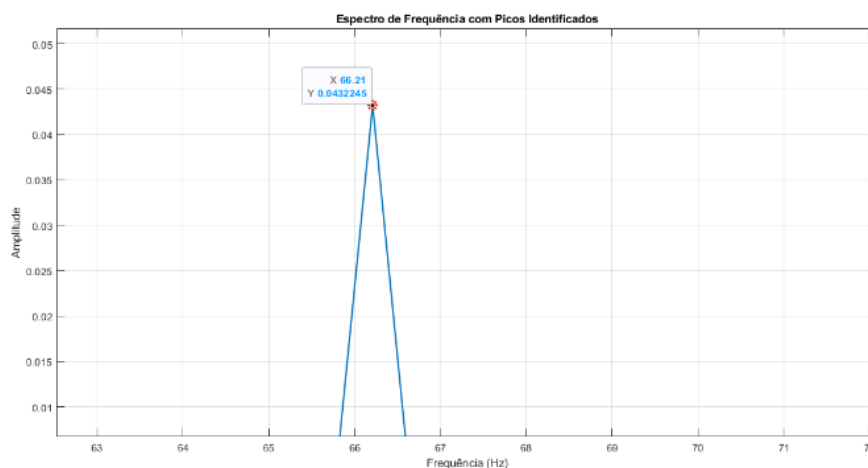
$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
66,21	66,21	0
132,42	132,4	0,015
264,84	264,805	0,013

Fonte: Elaboração Própria (2025)

No Teste 03, consegue-se observar uma eficácia equivalente a, aproximadamente, 99,97% de aproveitamento, pois as frequências coletadas são muito próximas àquelas que foram submetidas ao sinal original, respeitando os limites de erros toleráveis.

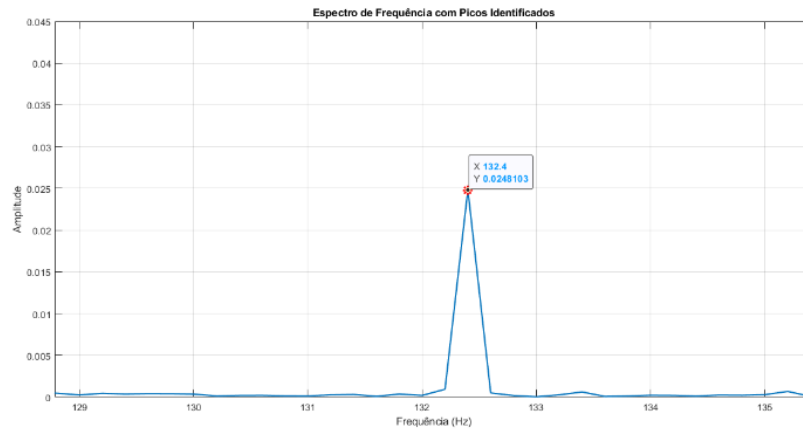
Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 25, 26 e 27.

Figura 25 - Pico para 66,21 Hz, com  $F_a = 2207$  e  $N = 5000$



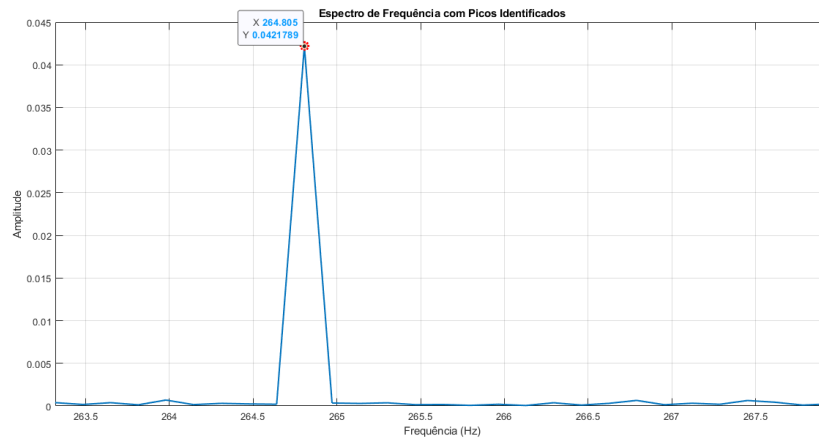
Fonte: Elaboração Própria (2025)

Figura 26 - Pico para 132,4 Hz, com  $F_a = 1000$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 27 - Pico para 264,805 Hz, com  $F_a = 1055$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.2 Teste 04


Esse teste diz respeito ao sinal gerado pela Equação 15 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Este sinal possui uma curva senoidal como a mostrada na Figura 28. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + Noise \quad (15)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 155,21 \text{ Hz}$ ;  $f_2 = 310,42 \text{ Hz}$ ;  $f_3 = 465,63 \text{ Hz}$ ;
- $Noise$  = variável de ruído.

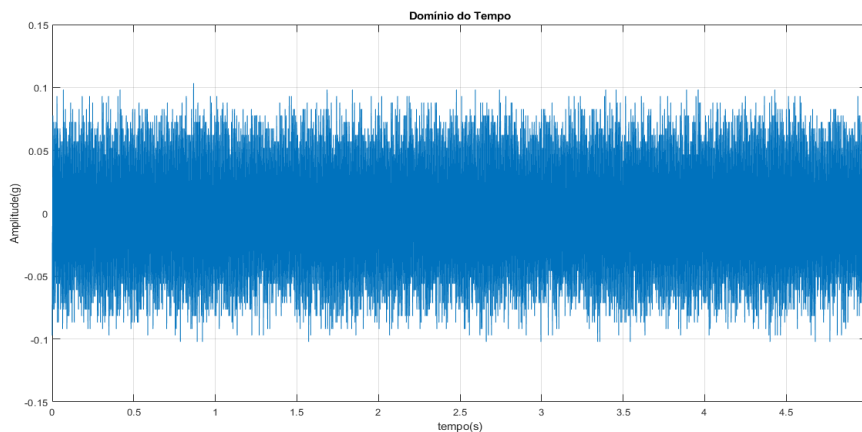
Figura 28 - Forma de Onda do Teste 04



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 5 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 29. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 29 - Domínio do Tempo Teste 04




Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de aquisição de  $N = 1000$  e  $F_a = 100$ , para  $N = 5000$  e  $F_a = 500$  e para  $N = 5000$  e  $F_a = 1000$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 100$  e  $F_a = 500$  apresentam algumas frequências que não estão presentes no espectro de  $F_a = 1000$ , portanto, são frequências falsas que foram eliminadas.

Então, o espectro base correto é o que é mostrado na Figura 30. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 30 - Espectro da Frequência para  $F_a = 1000$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 1000$ , é possível encontrar as frequências de amostragem corretas e adquirir os sinais das frequências correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, coletam-se os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 9, que também ilustra as frequências de amostragem utilizadas para a coleta de cada uma das frequências.

Tabela 9 - Frequências e Amplitudes para Teste 04

155,2				310,4				465,6			
$F_{esperada}$	Amplitude	$F_a$	df	$F_{esperada}$	Amplitude	$F_a$	df	$F_{esperada}$	Amplitude	$F_a$	df
155,15	0,0651652	1070	0,214	310,293	0,0148613	1035	0,207	465,45	0,0083878	1070	0,214
155,16	0,0664398	1293	0,2586	310,3	0,0175252	1070	0,214	465,475	0,00924863	1075	0,215
155,17	0,0664693	1315	0,263	310,32	0,0189808	1293	0,2586	465,48	0,00957351	1293	0,2586
155,18	0,066937	7759	1,5518	310,34	0,0193959	1315	0,263	465,51	0,010558	1315	0,263
155,19	0,0670036	1050	0,21	310,36	0,0198697	7759	1,5518	465,54	0,0107809	7759	1,5518
155,2	0,0661362	1000	0,2	310,38	0,019681	1050	0,21	465,543	0,0105857	1035	0,207
155,21	0,0658502	1411	0,2822	310,4	0,019367	1000	0,2	465,6	0,0104226	1000	0,2
155,22	0,0649692	1194	0,2388	310,42	0,0184936	1411	0,2822	465,63	0,00961203	1411	0,2822
155,23	0,0611279	1075	0,215	310,44	0,017286	1194	0,2388	465,66	0,00839096	1194	0,2388
155,24	0,065173	3881	0,7762	310,46	0,0135334	1075	0,215	465,67	0,0107232	1050	0,21
155,25	0,0576214	1035	0,207	310,48	0,0175482	3881	0,7762				

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes

do espectro. Desta forma, é possível comparar o valor coletado com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0,012%, 0,019% e 0,019%, respectivamente, conforme ilustrado na Tabela 10.

Tabela 10 - Comparação de Frequências


$F_{indicada}$ (Hz)	$F_{aqusitada}$ (Hz)	Taxa de Erro (%)
155,21	155,19	0,012
310,42	310,36	0,019
465,63	465,54	0,019

Fonte: Elaboração Própria (2025)

No Teste 04, é possível identificar uma eficácia de aproveitamento de, aproximadamente, 99,95%, o que se configura a uma percentagem satisfatória e respeita os limites de erros toleráveis.

Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 31, 32 e 33.

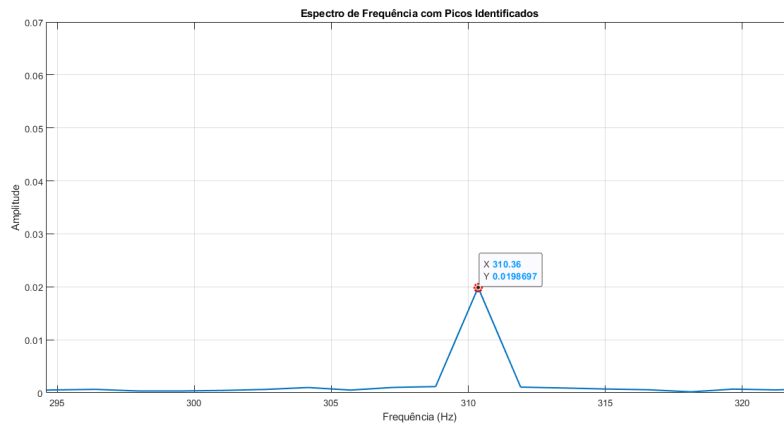
Figura 31 - Pico para 155,19 Hz, com  $F_a = 1050$  e  $N = 5000$



Fonte: Elaboração Própria (2025)




Figura 32 - Pico para 310,36 Hz, com  $F_a = 7759$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 33 - Pico para 465,64 Hz, com  $F_a = 7759$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

### 4.3.3 Teste 05

Esse teste diz respeito ao sinal gerado pela Equação 16 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 34. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.


$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + D\sin(2\pi f_4 t) + \text{Noise} \quad (16)$$

Onde:

- $A, B, C$  e  $D = 0,1$ ;

- $f_1 = 13,48 \text{ Hz}$ ;  $f_2 = 40,44 \text{ Hz}$ ;  $f_3 = 94,36 \text{ Hz}$ ;  $f_4 = 107,84 \text{ Hz}$ ;
- *Noise* = variável de ruído.


Figura 34 - Forma de Onda do Teste 05



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 35. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 35 - Domínio do Tempo do Teste 05




Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$ , para  $N = 5000$  e  $F_a = 500$  e para  $N = 5000$  e  $F_a = 1000$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 100$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 500$  ou  $F_a = 1000$ , portanto, são frequências falsas que foram eliminadas. Neste

caso, pode-se perceber que os espectros são similares e que nenhuma frequência é perdida entre um e outro, então se torna possível fixar  $F_a = 500$  como sendo o espectro base, conforme mostrado na Figura 36. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 36 - Espectro da Frequência para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , as frequências de amostragem corretas são coletadas e os sinais das frequências correspondentes são coletados. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, os pontos selecionados são os mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 11, que também ilustra as frequências de amostragem utilizadas para coletar cada uma das frequências.

Tabela 11 - Frequências e Amplitudes do Teste 05

13,5				40,4				94,3				107,8			
<i>Fesperada</i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>
13,442	0,032066	542	0,1084	40,337	0,0230242	965	0,193	94,288	0,0237766	710	0,142	107,76	0,0105688	898	0,1796
13,45	0,03522088	538	0,1076	40,38	0,0278883	673	0,1346	94,29	0,0264668	898	0,1796	107,778	0,0110157	677	0,1354
13,46	0,0384803	673	0,1346	40,4	0,029464	500	0,1	94,3	0,0210033	500	0,1	107,8	0,0119496	500	0,1
13,47	0,040317	898	0,1796	40,41	0,0351489	898	0,1796	94,308	0,025329	542	0,1084	107,815	0,0138191	673	0,1346
13,48	0,0399516	674	0,1348	40,433	0,0362516	542	0,1084	94,328	0,0308082	520	0,104	107,82	0,0129425	538	0,1076
13,49	0,0393285	710	0,142	40,44	0,0363197	674	0,1348	94,355	0,0312841	673	0,1346	107,84	0,0132811	674	0,1348
13,5	0,0368018	500	0,1	40,456	0,0338902	520	0,104	94,36	0,0312034	674	0,1348	107,848	0,0122456	520	0,104
13,51	0,037691	965	0,193	40,458	0,0337631	538	0,1076	94,365	0,0302579	538	0,1076	107,858	0,0114899	542	0,1084
13,52	0,0297952	520	0,104	40,47	0,0330877	710	0,142	94,377	0,0303962	965	0,193	107,887	0,0109599	965	0,193
13,53	0,0268671	525	0,105	40,48	0,0274952	525	0,105	94,374	0,0298587	677	0,1354				
13,54	0,0273259	677	0,1354	40,485	0,0288291	677	0,1354	94,38	0,0283708	525	0,105				

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, é possível comparar o valor coletado com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0,07%, 0%, 0% e 0,023%, respectivamente, como visto na Tabela 12.

Tabela 12 - Comparação de Frequências


$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
13,48	13,47	0,07
40,44	40,44	0
94,36	94,36	0
107,84	107,815	0,023

Fonte: Elaboração Própria (2025)

No Teste 05, é possível identificar uma eficácia de aproveitamento muito satisfatória de, aproximadamente, 99,9%, o que não ultrapassa os limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 37, 38, 39 e 40.

Figura 37 - Pico para 13,47 Hz, com  $F_a = 898$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 38 - Pico para 40,44 Hz, com  $F_a = 674$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 39 - Pico para 94,36 Hz, com  $F_a = 674$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 40 - Pico para 107,815 Hz, com  $F_a = 673$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.4 Teste 06


Esse teste diz respeito ao sinal gerado pela Equação 17 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 41. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + D\sin(2\pi f_4 t) + \text{Noise} \quad (17)$$

Onde:

- $A, B, C$  e  $D = 0,1$ ;
- $f_1 = 10,55 \text{ Hz}$ ;  $f_2 = 63,3 \text{ Hz}$ ;  $f_3 = 73,85 \text{ Hz}$ ;  $f_4 = 94,95 \text{ Hz}$ ;
- $\text{Noise}$  = variável de ruído.


Figura 41 - Forma de Onda do Teste 06



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 42. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.


Figura 42 - Domínio do Tempo do Teste 06



Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 100$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 500$ , portanto, são frequências falsas que foram eliminadas. Então, pode-se fixar  $F_a = 500$  como sendo o espectro base, conforme mostrado na Figura 43. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 43 - Espectro da Frequência para  $F_a = 500$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , é possível identificar as frequências de amostragem corretas. Em alguns casos, um fenômeno

interessante chamado *leakage* ocorre. Este episódio acontece porque as frequências não se alinham com a resolução da frequência devido ao fato de não se coincidirem com os vetores de frequência existentes.

No Teste 06, pode-se perceber que há um *leakage* no espectro, como mostrado na Figura 44, então é necessário coletar as frequências existentes entre os picos de frequências apresentados. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 13, que também ilustra os valores das frequências de amostragem correspondentes para realizar a coleta de cada uma das frequências.

Figura 44 – *Leakage* apresentado no Espectro



Fonte: Elaboração Própria (2025)

Tabela 13 - Frequências e Amplitudes do Teste 06

10,5				6,3				73,8				94,9			
<i>Fesperada</i>	<i>Amplitude</i>	<i>Fa</i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>Fa</i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>Fa</i>	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	<i>Fa</i>	<i>df</i>
10,49	0,027841	1049	0,2098	63,18	0,00609228	1053	0,2106	73,78	0,0247614	1051	0,2102	94,886	0,0232455	706	0,1412
10,5	0,0204934	500	0,1	63,24	0,00680674	527	0,1054	73,8	0,0204379	500	0,1	94,89	0,0268824	1052	0,2104
10,51	0,0300597	1051	0,2102	63,254	0,00823846	528	0,1056	73,814	0,0251779	528	0,1056	94,9	0,0224396	500	0,1
10,52	0,0303814	1052	0,2104	63,258	0,00901018	706	0,1412	73,839	0,0281242	755	0,151	94,903	0,023662	529	0,1058
10,53	0,0307953	1053	0,2106	63,268	0,00938118	529	0,1058	73,848	0,0278221	706	0,1412	94,934	0,0290965	528	0,1056
10,54	0,0311415	527	0,1054	63,269	0,00992372	755	0,151	73,85	0,0275804	1055	0,211	94,95	0,028859	1055	0,211
10,55	0,0317312	1055	0,211	63,27	0,0102139	1051	0,2102	73,885	0,0202649	527	0,1054	94,965	0,0257956	527	0,1054
10,56	0,0311541	528	0,1056	63,3	0,0101983	500	0,1	73,92	0,0218279	1053	0,2106	94,979	0,0258549	755	0,151
10,57	0,0305137	755	0,151	63,33	0,00938638	1052	0,2104					94,98	0,0270022	1053	0,2106
10,58	0,027105	529	0,1058	63,36	0,00865321	1049	0,2098					95,039	0,0185218	1049	0,2098
10,59	0,0274609	706	0,1412									95,01	0,0228443	1051	0,2102

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes



do espectro. Dessa forma, pode-se comparar com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0%, 0,047%, 0,002% e 0,016%, respectivamente, como visto na Tabela 14.


Tabela 14 - Comparação de Frequências

$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
10,55	10,55	0
63,3	63,27	0,047
73,85	73,848	0,002
94,95	94,934	0,016

Fonte: Elaboração Própria (2025)


No Teste 06, é possível identificar uma eficácia satisfatória equivalente a, aproximadamente, 99,93%, o que se configura dentro dos limites de erros toleráveis. Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 45, 46, 47 e 48.

Figura 45 - Pico para 10,55 Hz, com  $F_a = 1055$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 46 - Pico para 63,27 Hz, com  $F_a = 1051$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 47 - Pico para 73,848, com  $F_a = 529$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 48 - Pico para 94,934 Hz, com  $F_a = 528$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

### 4.3.3 Teste 07


Esse teste diz respeito ao sinal gerado pela Equação 18 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 49. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + \text{Noise} \quad (18)$$

Onde:

- $A \text{ e } B = 0,1$ ;
- $f_1 = 24,57 \text{ Hz}$ ;  $f_2 = 49,14 \text{ Hz}$ ;
- $\text{Noise}$  = variável de ruído.


Figura 49 - Forma de Onda do Teste 07



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 50. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.


Figura 50 - Domínio do Tempo do Teste 07



Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 100$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 500$ , portanto, são frequências falsas que foram eliminadas. Então, é possível fixar  $F_a = 500$  como sendo o espectro base, conforme mostrado na Figura 51. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 51 - Espectro de Frequência para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , é possível identificar as frequências de amostragem corretas e aquisitar os sinais para as frequências

correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 15, que também ilustra os valores das frequências de amostragem utilizadas para coletar as frequências indicadas.

Tabela 15 - Frequências e Amplitudes para Teste 07

24,6				49,1			
<i>F<sub>esperada</sub></i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>	<i>F<sub>esperada</sub></i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>
24,53	0,0466816	550	0,11	49,096	0,0295905	821	0,1642
24,55	0,0564159	982	0,1964	49,1	0,0325666	500	0,1
24,56	0,0568717	614	0,1228	49,113	0,035959	535	0,107
24,57	0,0572502	525	0,105	49,12	0,0332771	614	0,1228
24,58	0,0570034	1229	0,2458	49,14	0,0336301	525	0,105
24,59	0,0570395	2459	0,4918	49,16	0,0337117	1229	0,2458
24,6	0,0481057	500	0,1	49,17	0,0278619	550	0,11
24,61	0,0425611	535	0,107	49,18	0,0338434	2459	0,4918
24,62	0,0528629	1231	0,2462	49,24	0,0247567	1231	0,2462
24,63	0,0433461	821	0,1642				

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, é possível compara-lo com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0% e 0,055%, respectivamente, conforme visto na Tabela 16.

Tabela 16 - Comparação de Frequências


<i>F<sub>indicada</sub></i> (Hz)	<i>F<sub>aqusitada</sub></i> (Hz)	<i>Taxa de Erro</i> (%)
24,57	24,57	0
49,14	49,113	0,055

Fonte: Elaboração Própria (2025)

No Teste 07, é possível identificar uma eficácia satisfatória equivalente a, aproximadamente, 99,94%, o que se configura dentro dos limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 52 e 53.

Figura 52 - Pico para 24,57 Hz, com  $F_a = 525$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 53 - Pico para 49,113 Hz, com  $F_a = 535$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.6 Teste 08


Esse teste diz respeito ao sinal gerado pela Equação 19 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 54. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\text{sen}(2\pi f_1 t) + B\text{sen}(2\pi f_2 t) + C\text{sen}(2\pi f_3 t) + \text{Noise} \quad (19)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 63,14 \text{ Hz}$ ;  $f_2 = 189,42 \text{ Hz}$ ;  $f_3 = 252,56 \text{ Hz}$ ;
- $Noise$  = variável de ruído.


Figura 54 - Forma de Onda do Teste 08



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 5 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 55. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.


Figura 55 - Domínio do Tempo do Teste 08



Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 5000$  e  $F_a = 500$  e para  $N = 5000$  e  $F_a = 1000$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 500$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 1000$ , portanto, são frequências falsas que foram eliminadas. Então, o espectro base correto é o que é mostrado na Figura 56. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 56 - Espectro de Frequência para  $F_a = 1000$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 1000$ , é possível identificar as frequências de amostragem corretas e aquistar os sinais das frequências correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 17, que também ilustra as frequências de amostragem correspondentes para cada frequência coletada.



Tabela 17 - Frequências e Amplitudes para Teste 08

63,1				189,4				252,6			
<i>F<sub>esperada</sub></i>	Amplitude	<i>F<sub>a</sub></i>	<i>df</i>	<i>F<sub>esperada</sub></i>	Amplitude	<i>F<sub>a</sub></i>	<i>df</i>	<i>F<sub>esperada</sub></i>	Amplitude	<i>F<sub>a</sub></i>	<i>df</i>
63,05	0,0551928	1261	0,2522	189,24	0,0196213	1577	0,3154	252,44	0,0131062	6311	1,2622
63,06	0,054364	1051	0,2102	189,27	0,02053	1402	0,2804	252,45	0,0110918	1051	0,2102
63,07	0,0580955	1190	0,238	189,3	0,0244984	1262	0,2524	252,452	0,0118315	1261	0,2522
63,08	0,0630074	1577	0,3154	189,33	0,0288663	6311	1,2622	252,48	0,0124493	1052	0,2104
63,09	0,0630421	1402	0,2804	189,36	0,0288894	1052	0,2104	252,518	0,013071	1190	0,238
63,1	0,0640624	1000	0,2	189,39	0,0292876	1051	0,2102	252,52	0,0130854	1070	0,214
63,11	0,0652288	6311	1,2622	189,4	0,0290255	1000	0,2	252,56	0,0127822	1025	0,205
63,12	0,0651515	1052	0,2104	189,402	0,0289419	1261	0,2522	252,6	0,0108751	1000	0,1
63,13	0,06532	1070	0,214	189,42	0,0279001	1025	0,205	252,635	0,0103829	1577	0,3154
63,14	0,0648132	1025	0,205	189,448	0,0271054	1190	0,238	252,64	0,00950884	1402	0,2804
63,15	0,0648678	1263	0,2526	189,45	0,0272145	1263	0,2526				

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, pode-se comparar com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0,016%, 0,015% e 0,047%, respectivamente, como mostrado na Tabela 18.

Tabela 18 - Comparação de Frequências


<i>F<sub>indicada</sub></i> (Hz)	<i>F<sub>aquisitada</sub></i> (Hz)	Taxa de Erro (%)
63,14	63,13	0,016
189,42	189,39	0,015
252,56	252,44	0,047

Fonte: Elaboração Própria (2025)

No Teste 08, é possível identificar uma eficácia de aproveitamento satisfatório equivalente a, aproximadamente, 99,92%, o que se configura dentro dos limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 57, 58 e 59.

Figura 57 - Pico para 63,13 Hz, com  $F_a = 1070$  e  $N = 5000$



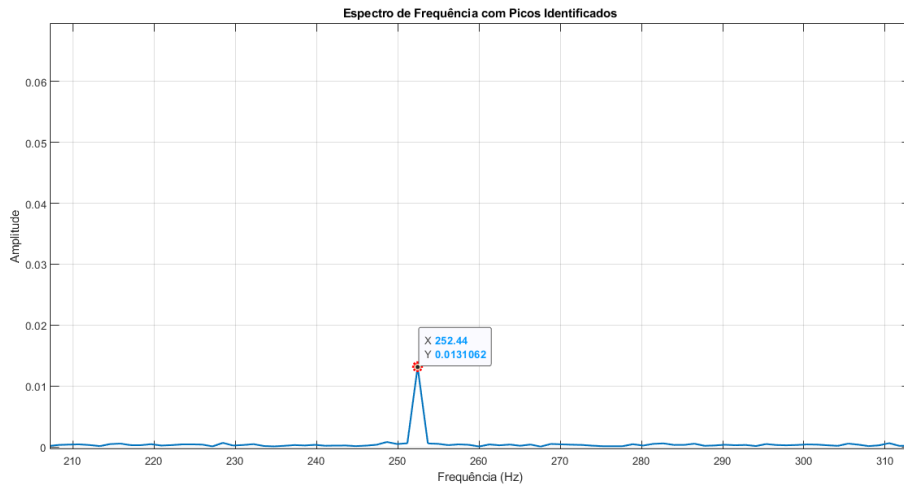
Fonte: Elaboração Própria (2025)

Figura 58 - Pico para 189,39 Hz, com  $F_a = 1070$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 59 - Pico para 252,44 Hz, com  $F_a = 6311$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.7 Teste 09


Esse teste diz respeito ao sinal gerado pela Equação 20 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 60. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\text{sen}(2\pi f_1 t) + B\text{sen}(2\pi f_2 t) + \text{Noise} \quad (20)$$

Onde:

- $A$  e  $B = 0,1$ ;
- $f_1 = 36,61 \text{ Hz}$ ;  $f_2 = 73,22 \text{ Hz}$ ;
- $\text{Noise}$  = variável de ruído.


Figura 60 - Forma de Onda do Teste 09



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 61. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.


Figura 61 - Domínio do Tempo do Teste 09



Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 500$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 100$ , portanto, são frequências falsas que foram eliminadas. Então, o espectro base correto é o que é mostrado na Figura 62. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 62 – Espectro de Frequência para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , é possível identificar as frequências de amostragem corretas e adquirir os sinais correspondentes a cada pico. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 19, que também ilustram as frequências de amostragem utilizadas para coletar cada uma das frequências.

Tabela 19 – Frequências e Amplitudes para Teste 09

36,6				73,2			
$F_{esperada}$	Amplitude	$F_a$	df	$F_{esperada}$	Amplitude	$F_a$	df
36,57	0,0427799	530	0,106	73,16	0,034018	590	0,118
36,58	0,0477788	590	0,118	73,18	0,0453639	3659	0,7318
36,59	0,0511152	3659	0,7318	73,2	0,0443395	500	0,1
36,6	0,0509437	500	0,1	73,22	0,0444023	523	0,1046
36,61	0,051054	523	0,1046	73,24	0,0443887	1831	0,3662
36,62	0,0508864	1831	0,3662	73,246	0,0371874	530	0,106
36,63	0,0472882	550	0,11	73,26	0,0316218	550	0,11
36,64	0,0476635	800	0,16	73,28	0,0329762	800	0,16

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, pode-se comparar com o valor indicado primordialmente e

calcular a taxa de erro de, aproximadamente, 0,055% e 0,054%, respectivamente, como visto na Tabela 20.

Tabela 20 – Comparação de Frequências


$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
36,61	36,59	0,055
73,22	73,18	0,054

Fonte: Elaboração Própria (2025)

No Teste 09, é possível identificar uma eficácia de aproveitamento satisfatória equivalente a, aproximadamente, 99,89%, o que se configura dentro dos limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 63 e 64.

Figura 63 - Pico para 36,59 Hz, com  $F_a = 3659$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 64 - Pico para 73,18 Hz, com  $F_a = 3659$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.8 Teste 10


Esse teste diz respeito ao sinal gerado pela Equação 21 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 65. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + Noise \quad (21)$$

Onde:

- $A, B$  e  $C = 0,1$ ;
- $f_1 = 27,84 \text{ Hz}$ ;  $f_2 = 83,52 \text{ Hz}$ ;  $f_3 = 194,88 \text{ Hz}$ ;
- $Noise$  = variável de ruído.


Figura 65 - Forma de Onda do Teste 10



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 66. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 66 - Domínio do Tempo do Teste 10




Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 500$  apresenta algumas frequências que não estão presentes no caso do espectro de  $F_a = 100$ , portanto, são frequências falsas que foram eliminadas. Então, o espectro base correto é o que é mostrado na Figura 67. O espectro também apresenta picos menos significativos de



harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 67 - Espectro de Frequência para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , é possível identificar as frequências de amostragem corretas e adquirir os sinais de frequências correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 21, que também ilustra as frequências de amostragem correspondentes para coletar cada uma das frequências.

Tabela 21 - Frequências e Amplitudes para Teste 10

27,8				83,5				194,9			
<i>Fesperada</i>	<i>Amplitude</i>	$F_a$	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	$F_a$	<i>df</i>	<i>Fesperada</i>	<i>Amplitude</i>	$F_a$	<i>df</i>
27,77	0,0373884	2777	0,5554	83,31	0,0284196	2777	0,5554	194,81	0,0251236	506	0,1012
27,78	0,032431	926	0,1852	83,46	0,0244033	535	0,107	194,83	0,0346887	926	0,1852
27,79	0,0327043	794	0,1588	83,49	0,0329231	506	0,1012	194,839	0,0344535	557	0,1114
27,8	0,0302078	500	0,1	83,5	0,0341908	500	0,1	194,847	0,0346048	535	0,107
27,81	0,0340277	515	0,103	83,52	0,0341671	580	0,116	194,848	0,0350131	794	0,1588
27,82	0,0367805	535	0,107	83,525	0,0337685	926	0,1852	194,875	0,0339163	694	0,1388
27,83	0,0374697	506	0,1012	83,529	0,0338443	794	0,1588	194,876	0,0310386	515	0,103
27,84	0,0379749	580	0,116	83,533	0,0315134	515	0,103	194,88	0,0311873	580	0,116
27,85	0,0369139	557	0,1114	83,55	0,0268026	557	0,1114	194,9	0,0255238	500	0,1
27,899	0,0266206	694	0,1388	83,558	0,0281033	694	0,1388	194,945	0,0330376	2777	0,5554

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Dessa forma, pode-se comparar com o valor indicado primordialmente e

calcular a taxa de erro de, aproximadamente, 0%, 0,023% e 0,017%, respectivamente, como visto na Tabela 22.

Tabela 22 - Comparação de Frequências


$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
27,84	27,84	0
83,52	83,5	0,023
194,88	194,847	0,017

Fonte: Elaboração Própria (2025)

No Teste 10, é possível identificar uma eficácia de aproveitamento satisfatório equivalente a, aproximadamente, 99,96%, o que se configura dentro dos limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 68, 69 e 70.

Figura 68 - Pico para 27,84 Hz, com  $F_a = 580$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 69 - Pico para 83,5 Hz, com  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 70 - Pico para 194,847 Hz, com  $F_a = 535$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

#### 4.3.9 Teste 11


Esse teste diz respeito ao sinal gerado pela Equação 22 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 71. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + \text{Noise} \quad (22)$$

Onde:

- $A$  e  $B = 0,1$ ;
- $f_1 = 7,89 \text{ Hz}$ ;  $f_2 = 23,67 \text{ Hz}$ ;
- $\text{Noise}$  = variável de ruído.


Figura 71 - Forma de Onda do Teste 11



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 72. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

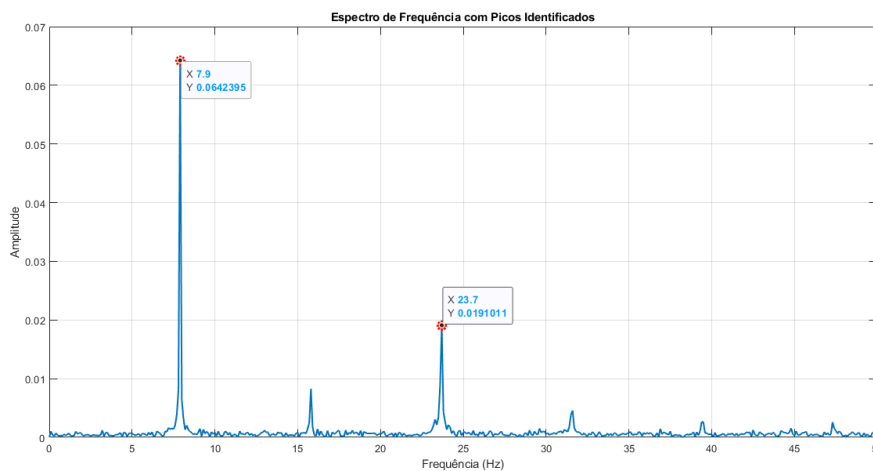
Figura 72 - Domínio do Tempo do Teste 11



Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que os espectros são similares e possuem frequências coerentes. Então, o espectro base correto é o que é mostrado na Figura 73. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.

Figura 73 – Espectro de Frequência para  $F_a = 100$  e  $N = 1000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 1000$  e  $F_a = 100$ , é possível identificar as frequências de amostragem corretas e aquisitar os sinais de frequências correspondentes. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 23, que também ilustra as frequências de amostragem utilizadas para coletar cada uma das frequências.

Tabela 23 – Frequências e Amplitudes para Teste 11

7,9				23,7			
<i>F<sub>esperada</sub></i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>	<i>F<sub>esperada</sub></i>	<i>Amplitude</i>	<i>F<sub>a</sub></i>	<i>df</i>
7,844	0,0475612	106	0,106	23,61	0,0231044	787	0,787
7,85	0,0592785	157	0,157	23,617	0,0160399	113	0,113
7,86	0,0598673	131	0,131	23,638	0,0192826	106	0,106
7,87	0,066341	787	0,787	23,64	0,0231165	197	0,197
7,88	0,0654669	197	0,197	23,65	0,0215844	110	0,11
7,89	0,0665888	263	0,263	23,668	0,0223769	122	0,122
7,9	0,0642395	100	0,1	23,67	0,0229541	263	0,263
7,91	0,0625037	113	0,113	23,7	0,0191011	100	0,1
7,92	0,0577195	110	0,11	23,707	0,0203249	157	0,157
7,93	0,0536046	122	0,122	23,711	0,0188237	131	0,131
7,94	0,0631377	397	0,397	23,82	0,0180375	397	0,397

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, pode-se comparar com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0% e 0,001%, respectivamente, como visto na Tabela 24.

Tabela 24 – Comparação de Frequências


<i>F<sub>indicada</sub></i> (Hz)	<i>F<sub>aquisitada</sub></i> (Hz)	Taxa de Erro (%)
7,89	7,89	0
23,67	23,64	0,001

Fonte: Elaboração Própria (2025)

No Teste 11, é possível identificar uma eficácia de aproveitamento muito satisfatória equivalente a, aproximadamente, 99,99%, o que se configura dentro dos limites de erros toleráveis.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 74 e 75.

Figura 74 - Pico para 7,89 Hz, com  $F_a = 263$  e  $N = 1000$



Fonte: Elaboração Própria (2025)

Figura 75 - Pico para 23,64 Hz, com  $F_a = 197$  e  $N = 1000$



Fonte: Elaboração Própria (2025)

#### 4.3.10 Teste 12


Esse teste diz respeito ao sinal gerado pela Equação 23 somado com um fenômeno de ruído para simular satisfatoriamente um sinal real. Esse sinal possui uma curva senoidal como a mostrada na Figura 76. A forma de onda representa um fragmento do sinal com a intenção de mostrar o comportamento que o sinal apresenta quando submetido às frequências indicadas.

$$y(t) = A\sin(2\pi f_1 t) + B\sin(2\pi f_2 t) + C\sin(2\pi f_3 t) + Noise \quad (23)$$

Onde:

- $A, B \text{ e } C = 0,1$ ;
- $f_1 = 10,25 \text{ Hz}$ ;  $f_2 = 30,75 \text{ Hz}$ ;  $f_3 = 41 \text{ Hz}$ ;
- $Noise$  = variável de ruído.


Figura 76 - Forma de Onda do Teste 12



Fonte: Elaboração Própria (2025)

Ao realizar a aquisição do sinal com o vetor de tempo de 10 segundos, o sinal no domínio do tempo é obtido, conforme ilustrado na Figura 77. Isso significa que, no domínio do tempo, o fragmento ilustrado pela forma de onda se repete inúmeras vezes, formando o espectro.

Figura 77 - Domínio do Tempo do Teste 12




Fonte: Elaboração Própria (2025)

Esse teste foi coletado com os parâmetros de  $N = 1000$  e  $F_a = 100$  e para  $N = 5000$  e  $F_a = 500$ . Nesse caso, foi possível perceber que o espectro de  $F_a = 500$  apresenta



algumas frequências que não estão presentes no caso do espectro de  $F_a = 100$ , portanto, são frequências falsas que foram eliminadas. Então, o espectro base correto é o que é mostrado na Figura 78. O espectro também apresenta picos menos significativos de harmônicos que são evidenciados pelo fenômeno de ruído imputado à função.


Figura 78 - Espectro de Frequência para  $F_a = 500$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Estabelecendo os parâmetros base como sendo  $N = 5000$  e  $F_a = 500$ , é possível identificar as frequências de amostragem corretas. Neste caso, pode-se perceber que há um *leakage* no espectro, como mostrado na Figura 79, então é necessário coletar as frequências existentes entre os dois picos de frequência apresentados. Em alguns casos, as frequências não são encontradas na sua forma mais exata, portanto, são selecionados os pontos mais próximos relacionados a elas, chegando aos resultados presentes na Tabela 25, que também ilustra as frequências de amostragem utilizadas para coletar cada uma das frequências.

Figura 79 – Leakage



Fonte: Elaboração Própria (2025)

Tabela 25 - Frequências e Amplitudes do Teste 12

10,2				30,7				41			
$F_{esperada}$	Amplitude	Fa	df	$F_{esperada}$	Amplitude	Fa	df	$F_{esperada}$	Amplitude	Fa	df
10,2	0,039663	500	0,1	30,68	0,013435	650	0,13	40,95	0,014935	650	0,13
10,21	0,058045	1021	0,2042	30,69	0,013138	550	0,11	40,96	0,01518	512	0,1024
10,22	0,053585	511	0,1022	30,7	0,014596	500	0,1	40,982	0,017666	511	0,1022
10,23	0,058882	550	0,11	30,72	0,018986	512	0,1024	41	0,01831	500	0,1
10,24	0,060803	512	0,1024	30,737	0,0209	514	0,1028	41,017	0,016945	514	0,1028
10,25	0,06177	625	0,125	30,75	0,021386	625	0,125	41,03	0,015509	550	0,11
10,26	0,06052	513	0,1026	30,762	0,020491	511	0,1022	41,04	0,012676	513	0,1026
10,27	0,05894	650	0,13	30,765	0,019568	525	0,105	41,044	0,016788	1021	0,2042
10,28	0,052542	514	0,1028	30,78	0,017577	513	0,1026				
10,29	0,047269	525	0,105	30,834	0,015222	1021	0,2042				
10,3	0,038565	500	0,1	30,8	0,012134	500	0,1				

Fonte: Elaboração Própria (2025)

Ao observar as amplitudes das frequências coletadas, é possível identificar as frequências que possuem as maiores amplitudes, ou seja, são as frequências dominantes do espectro. Desta forma, pode-se comparar com o valor indicado primordialmente e calcular a taxa de erro de, aproximadamente, 0%, como visto na Tabela 26.

Tabela 26 - Comparação de Amplitudes


$F_{indicada}$ (Hz)	$F_{aquisitada}$ (Hz)	Taxa de Erro (%)
10,25	10,25	0
30,75	30,75	0
41	41	0

Fonte: Elaboração Própria (2025)

No Teste 12, é possível identificar uma eficácia equivalente a, aproximadamente, 100% de aproveitamento pois coleta-se uma frequência exatamente igual àquela que foi indicada inicialmente.


Observando a ocorrência dos picos máximos em relação a amplitude, é possível perceber as frequências dominantes e todas possuem um pico sobressalente e correto, sem *leakage* e sem *aliasing*, como foi proposto nas etapas minuciosas do teste. Os picos estão ilustrados nas Figuras 80, 81 e 82.

Figura 80 - Pico para 10,25 Hz, com  $F_a = 625$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

Figura 81 - Pico para 30,75 Hz, com  $F_a = 625$  e  $N = 5000$



Fonte: Elaboração Própria (2025)

Figura 82 - Pico para 41 Hz, com  $F_a = 625$  e  $N = 5000$




Fonte: Elaboração Própria (2025)

### 4.3 DISCUSSÕES GERAIS

De acordo com os testes realizados e ilustrado na Figura 83, é possível perceber que a metodologia possui um alcance significativo e satisfatório onde 37,14% das frequências encontradas correspondem exatamente àquelas as quais os sinais foram submetidos inicialmente. Do mesmo modo, 34,3% das frequências possuem taxas de erros entre 0,01% e 0,02%, e 8,57% possuem taxas de erros entre 0,02% e 0,03%.

Apenas 2,86% das frequências apresentam taxas entre 0,03% e 0,04%, e 5,71% possuem taxas entre 0,04% e 0,05%. Os demais 11,42% apresentam taxas de erros acima de 0,05%, entretanto, nenhuma delas chega a ultrapassar o valor de 0,1% de erro, mostrando a eficácia do método, encontrando os picos de frequência maiores que se correspondem às frequências dominantes ou o mais próximo possível destas.

Figura 83 - Percentagem de Erros



Fonte: Elaboração Própria (2025)

O processo realizado durante os testes pode ser repetido para encontrar frequências diversas, mesmo quando se tratarem de sinais em ambientes complexos. Ao encontrar os maiores picos de frequência, os valores podem ser comparados às frequências de defeito analíticas e indicar onde estão localizadas as falhas dos componentes.

## CAPÍTULO V

### 5. CONCLUSÕES

A partir de todos os conhecimentos expostos nos capítulos que compõem esta Dissertação de Mestrado, é possível concluir que as perguntas científicas propostas foram devidamente respondidas. O método desenvolvido cumpre o seu propósito ao acertar corretamente 37,14% das frequências experimentais, e 34,3% correspondem a taxas de erros mínimas entre 0,01% e 0,02%. Os demais 28,56% chegam em valores extremamente próximos, sem ultrapassar diferenças superiores a 0,1% de erro entre o valor coletado experimentalmente e aquele previamente indicado, possuindo uma taxa de erro média de apenas 0,02%.

A diferença entre os valores não é prejudicial à aplicação e à eficácia do método, pois possui uma taxa de erro tolerável. Essas incongruências podem acontecer por diversos fatores, sendo os principais o ruído gerado pelas máquinas e pelo ambiente – no caso do método proposto, pelo ruído o qual o sinal foi submetido –, por desregulação dos instrumentos de medição ou por algum fenômeno que possa ter ocorrido durante a aquisição dos dados.

Em práticas reais, os valores das frequências aquisitadas podem não coincidir completamente com os valores das frequências analíticas por todos os motivos já citados, mas também pelo arredondamento de valores provenientes da geometria dos próprios elementos mecânicos. A intenção principal é que as frequências reais cheguem o mais próximo possível das frequências analíticas para que as causas possam ser identificadas corretamente.

O ajuste dinâmico dos parâmetros de aquisição de frequência de amostragem e número de pontos minimiza e auxilia na erradicação dos fenômenos de *leakage* e *aliasing*, de forma a garantir a captura precisa dos picos espectrais.

O método possui eficácia considerável e pode ser aplicado em diversos ambientes com condições diferentes, possuindo ênfase na aplicação industrial para encontrar frequências desconhecidas e auxiliar na descoberta de componentes defeituosos ou falhas mecânicas, como desalinhamento ou desregulamento.

Ademais, as técnicas de aquisição de dados também são importantes por se tratarem de uma forma não invasiva para detectar defeitos de máquinas, reduzindo custos de manutenção por indicar exatamente o lugar defeituoso auxiliando na identificação das técnicas a serem utilizadas para eliminar o defeito, subsidiando as estratégias de manutenção.

A técnica experimental pode ser adotada para avaliar o desempenho dos sinais a longo prazo e verificar a robustez da aquisição quando submetidas a diferentes condições operacionais, subsidiado pelos parâmetros de aquisição manipuláveis que são estabelecidos pelo método.

Seguindo as etapas de forma correta, o objetivo alcançado será a garantia da captura precisa, confiável e reproduzível de dados para a análise de desempenho, diagnóstico de falhas e manutenção preditiva, atendendo os padrões científicos exigidos pela base bibliográfica existente.

O método experimental funciona como base de aperfeiçoamento de técnicas tradicionais de processamento de sinais, bem como tem possibilidades de ser aplicada juntamente a técnicas com componentes tecnológicos em desenvolvimento para automatizar este processo. Além de auxiliar em técnicas atuais para identificação de defeitos incipientes, ou seja, antes mesmo de ocorrerem.

Para trabalhos futuros, o método espera ser totalmente automatizado priorizando a alteração interativa dos parâmetros de aquisição e minimizando o tempo necessário para ser executado e para encontrar as frequências de defeitos proeminentes.

Além disso, o trabalho também apresenta prospecções futuras de aplicação para validação do método em bancadas experimentais com elementos mecânicos e sinais reais, como rolamentos com condições variadas. Pode ser integrado a práticas de *Machine Learning* e Redes Neurais para a melhoria do método e a detecção automática de defeitos incipientes.

Ademais, a pesquisa atua como base científica para fortalecer os conhecimentos primordiais da análise de vibrações e do processamento e aquisição de sinais para que todos os trabalhos derivados desta possam ter um alicerce bibliográfico forte e congruente.

## REFERÊNCIAS

- ABEDIN, T. et al., 2023. Vibration Signal for Bearing Fault Detection Using Random Forest. *Journal of Physics*, v. 2467.
- ABURAKHIA, S.A., MYERS, R. e SHAMI, A., 2022. A Hybrid Method for Condition Monitoring and Fault Diagnosis of Rolling Bearings With Low System Delay. *IEEE Transactions on Instrumentation and Measurement*, v. 71.
- AHMED, H.O.A. e NANDI, A.K., 2023. Convolutional-Transformer Model with Long-Range Temporal Dependencies for Bearing Fault Diagnosis Using Vibration Signals. *Machines*, v. 11, n. 746.
- ALHAMS, A. et al., 2024. Enhanced Bearing Fault Diagnosis Through Trees Ensemble Method and Feature Importance Analysis. *Journal of Vibration Engineering & Technologies*, v. 12, p. 109-125.
- ALMUTAIRI, K.M. e SINHA, J.K., 2023. Experimental Vibration Data in Fault Diagnosis: A Machine Learning Approach to Robust Classification of Rotor and Bearing Defects in Rotating Machines. *Machines*, v. 11, n. 943.
- ALONSO-GONZALEZ, M. et al., 2023. Bearing Fault Diagnosis with Envelope Analysis and Machine Learning Approaches Using CWRU Dataset *IEEE Access*, v. 11, p. 57796-57805.
- ALTAF, M. et al., 2019. Automatic and Efficient Fault Detection in Rotating Machinery using Sound Signals. *Acoustics Australia*, v. 47, v. 2, p. 125–139.
- ANWARSHA, A.; BABU, T., 2022. Recent Advancements of Signal Processing and Artificial Intelligence in the Fault Detection of Rolling Element Bearings: A Review. *Journal of Vibroengineering*, v. 24, n. 6, p. 1027-1055.
- AYANKOSO, S. et al., 2024. Performance of vibration and current signals in the fault diagnosis of induction motors using deep learning and machine learning techniques. *Structural Health Monitoring*.
- BAI, Y. et al., 2023. Application of Time-Frequency Analysis in Rotating Machinery Fault Diagnosis. *Shock and Vibration*.
- BARAI, V. et al., 2022. Bearing fault diagnosis using signal processing and machine learning techniques: A review. *International Conference on Advances in Mechanical Engineering*.
- BAUER, M. et al., 2023. Comparison of envelope demodulation methods in the analysis of rolling bearing damage. *Journal of Vibration and Control*, v. 29, p. 5009-5020.
- BOUAOUICHE, K., MENASRIA, Y. e KHALFA, D., 2023. Detection and diagnosis of bearing defects using vibration signal processing. *Archive of Mechanical Engineering*, v. 70, n. 3, p. 433-452.



- BRITO, L.C., SUSTO, G.A., BRITO, J.N. e DUARTE, M.A.V., 2021. Fault Detection of Bearing: An Unsupervised Machine Learning Approach Exploiting Feature Extraction and Dimensionality Reduction. *Informatics*, v. 8, n. 85.
- BRITO, L.C., SUSTO, G.A., BRITO, J.N. e DUARTE, M.A.V., 2024. Band Relevance Factor (BRF): A novel automatic frequency band selection method based on vibration analysis for rotating machinery. *ISA Transactions*, v. 155, p. 439-453.
- CHEGINI, S.; BAGHERI, A.; NAJAFI, F., 2019. A New Intelligent Fault Diagnosis Method for Bearing in Different Speeds Based on The FDAF-Score Algorithm, Binary Particle Swarm Optimization and Support Vector Machine. *Springer*.
- CHEN, B., CHENG, Y., ZHANG, W. e GU, F., 2022. Investigations on improved Gini indices for bearing fault feature characterization and condition monitoring. *Mechanical Systems and Signal Processing*, v. 176.
- CHEN, F. et al., 2023. Instantaneous Square Current Signal Analysis for Motors Using Vision Transformer for the Fault Diagnosis of Rolling Bearings. *Applied Sciences*, v. 13, n. 9349.
- DU, N.T., TRUNG, P.T., CUONG, N.H. e DIEN, N.P., 2024. Automatic rolling bearings fault classification: a case study at varying speed conditions. *Frontiers in Mechanical Engineering*.
- EL BOUHARROUTI, N., MORINIGO-SOTELO, D. e BELAHCEN, A., 2024. Multi-Rate Vibration Signal Analysis for Bearing Fault Detection in Induction Machines Using Supervised Learning Classifiers. *Machines*, v. 12, n. 17.
- FONSECA, G.B.T., LIMA, V.B. e CAJUEIRO, E.B., 2019. Gerador de Funções Microprocessado. In: *International Symposium on Innovation and Technology, V SIINTEC*.
- GUNERKAR, R.; JALAN, A.; BELGAMWAR, S., 2019. Fault Diagnosis of Rolling Element Bearing Based on Artificial Neural Network. *Journal of Mechanical Science and Technology*, v. 33, n. 2, p. 505-511.
- GUO, J., LIU, Y., LI, K. e LIU, Q., 2022. Research on an ID-PCA Early Fault Detection Method for Rolling Bearings. *Applied Sciences*, v. 12, n. 4267.
- JAYASINGHE, H.P. et al., 2021. Predictive and Standalone Fault Diagnosis System for Induction Motors. *Engineer*, v. 54, n. 4, p. 01-13.
- KIM, Y. e KIM, Y.K., 2024. Physics-Informed Time-Frequency Fusion Network With Attention for Noise-Robust Bearing Fault Diagnosis. *IEEE Access*, v. 12.
- KUMAR, R. e ANAND, R. S., 2024. A methodological integration of fisher score technique with intelligent machine learning methods for ball bearing fault investigation. *Engineering Research Express*, v. 6.
- KUO, C.H., CHUANG, Y.F. e LIANG, S.H., 2022. Failure Mode Detection and Validation of a Shaft-Bearing System with Common Sensors. *Sensors*, v. 22, n. 6167.

- LIU, C., CHENG, G., CHEN, X. e LI, Y., 2021. Monopulse Feature Extraction and Fault Diagnosis Method of Rolling Bearing under Low-Speed and Heavy-Load Conditions. *Hindawi*.
- MA, Y., WANG, C., YANG, D. e WANG, C., 2021. Adaptive Extraction Method Based on Time-Frequency Images for Fault Diagnosis in Rolling Bearings of Motor. *Hindawi*.
- MALIUK, A.S., AHMAD, Z. e KIM, J.M., 2023. A Technique for Bearing Fault Diagnosis Using Novel Wavelet Packet Transform-Based Signal Representation and Informative Factor LDA. *Machines*, v. 11, n. 1080.
- MINERVINI, M., MONAGSCHI, M.E., BARBA, P.D. e FROSINI, L., 2021. Convolutional Neural Networks for Automated Rolling Bearing Diagnostics in Induction Motors Based on Electromagnetic Signals. *Applied Sciences*, v. 11, n. 7878.
- PANDAKARONE, S.; MIZUNO, Y.; NAKAMURA, H., 2019. A Comparative Study Between Machine Learning Algorithm and Artificial Intelligence Neural Network in Detecting Minor Bearing Fault of Induction Motors. *Energies*, Switzerland, v. 12, p. 1-14.
- PEI, D., YUE, J. e JIAO, J., 2024. Fuzzy Entropy-Assisted Deconvolution Method and Its Application for Bearing Fault Diagnosis. *Entropy*, v. 26, n. 304.
- PONOMAREVA, V. et al., 2024. Time-Series Feature Extraction by Return Map Analysis and Its Application to Bearing-Fault Detection. *Big Data and Cognitive Computing*, v. 8, n. 82.
- PULE, M., MATSEBE, O. e SAMIKANNU, R., 2022. Application of PCA and SVM in Fault Detection and Diagnosis of Bearings with Varying Speed, *Hindawi*.
- RANDALL, Robert Bond, 2021. Vibration-Based Condition Monitoring: Industrial Automotive and Aerospace Applications. 2. ed. Australia: *Wiley*.
- RAQEEB, A. et. al., 2023. Data-Driven Bearing Fault Diagnosis for Induction Motor. *Hindawi*.
- RUIZ-SARRIO, J.E., ANTONINO-DAVIU, J.A. e MARTIS, C., 2024[2]. Localized Bearing Fault Analysis for Different Induction Machine Start-Up Modes via Vibration Time–Frequency Envelope Spectrum. *Sensors*, v. 24, n. 6935.
- RUIZ-SARRIO, J.E., ANTONINO-DAVIU, J.A. e MARTIS, C., 2024. Comprehensive Diagnosis of Localized Rolling Bearing Faults during Rotating Machinery Start-Up via Vibration Envelope Analysis. *Electronics*, v. 13, n. 375.
- SACERDOTI, D., STROZZI, M. e SECCHI, C., 2023. A Comparison of Signal Analysis Techniques for the Diagnostics of the IMS Rolling Element Bearing Dataset *Applied Sciences*, v. 13, n. 5977.
- SAHA, D.K., HOQUE, M.E. e BADIHI, H., 2022. Development of Intelligent Fault Diagnosis Technique of Rotary Machine Element Bearing: A Machine Learning Approach. *Sensors*, v. 22, n. 1073.
- SAMAL, P.K., SUNIL, K., JAMADAR, I.M. e SRINIDHI, R., 2024. AI-Enhanced Fault Diagnosis in Rolling Element Bearings: A Comprehensive Vibration Analysis Approach. *FME Transactions*, v.

- SANTOS, R.S., 2017. *Deteção de falhas em rolamentos de máquinas rotativas utilizando técnicas de processamentos de sinais*. 136p. Tese (Engenharia Mecânica) - Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá.
- QIFENG, Y., LONGSHENG, C. e NAEEM, M.T., 2024. Hidden Markov Models based inteligente health assessment and fault diagnosis of rolling element bearings. *Plos One*, v. 19, n. 2.
- TANG, J., WU, J., QING, J. e KANG, T., 2022. Rolling Bearing Fault Monitoring for Sparse Time-Frequency Representation and Feature Detection Strategy. *Entropy*, v. 24, n. 1822.
- TAO, L. et al., 2025. LLM-based framework for bearing fault diagnosis. *Mechanical Systems and Signal Processing*.
- TOMA, R. N., KIM, C.H. e KIM, J.M., 2021. Bearing Fault Classification Using Ensemble Empirical Mode Decomposition and Convolutional Neural Network. *Electronics*, v. 10, n. 1248.
- VERELLEN, T., VERBELEN, F., STOCKMAN, K. e STECKEL, J., 2021. Beamforming Applied to Ultrasound Analysis in Detection of Bearing Defects. *Sensors*, v. 21, 6803.
- WANG, H., HUANG, H., YU, S. e GU, W., 2021. Size and Location Diagnosis of Rolling Bearing Faults: An Approach of Kernel Principal Component Analysis and Deep Belief Network. *International Journal of Computational Intelligence Systems*, v. 14, n. 1, p. 1672-1686.
- WEEKS, M., 2011. *Processamento Digital de Sinais*. 2. ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora.
- WODECKI, J. et al., 2023. Condition Monitoring of Horizontal Sieving Screens – A Case Study of Inertial Vibrator Bearing Failure in Calcium Carbonate Production Plant. *Materials*, v. 16, n. 1533.
- YAO, K. et al., 2022. Establishing an Intelligent Emotion Analysis System for Long-Term Care Application Based on LabVIEW. *Sustainability*, v. 14, n. 8932.
- YUAN, X., AZEEM, N., KHALID, A. e JABBAR, J., 2022. Vibration Energy at Damage-Based Statistical Approach to Detect Multiple Damages in Roller Bearings. *Applied Sciences*, v. 12, n. 8541.
- YUE, H., CHEN, X., SHI, X. e LOU, W., 2023. Rolling bearing fault diagnosis method based on ELMD hybrid feature extraction and wavelet neural network. *Journal of Vibroengineering*, v. 25, n. 6.
- ZAMORANO, M., GÓMEZ, M.J. e CASTEJON, C., 2024. An Analysis of the WPT Function for Pattern Optimization to Detect Defects in Bearings. *Machines*, v. 12, n. 207.
- ZHANG, M., 2024. MKurt-LIA: mechanical fault vibration signal measurement scheme with frequency tracking capability for bearing condition monitoring. *Measurement Science and Technology*, v. 35.
- ZHANG, L., ZHANG, Y. e LI, G., 2023. Fault-Diagnosis Method for Rotating Machinery Based on SVM Entropy and Machine Learning. *Algorithms*, v. 16, n. 304.

- ZHANG, X. et al., 2023. Fault Diagnosis of Mine Ventilator Bearing Based on Improved Variational Mode Decomposition and Density Peak Clustering. *Machines*, v. 11, n. 27.
- ZHOU, Y. et al., 2015. Detection of bearing fault frequencies using FFT in industrial environments. *Mechanical Systems and Signal Processing*, v. 52, p. 422–431.
- ZHOU, Z., SUN, J., CAI, W. e LIU, W., 2023. Test Investigation and Rule Analysis of Bearing Fault Diagnosis in Induction Motors. *Energies*, v. 16, n. 699.

## APÊNDICE I – Programa MATLAB para Frequência de Amostragem

```
% Coleta de amplitudes dos picos no espectro de frequência
close all
clear all
clc

% Parâmetros
Fa = 500; % Frequência de amostragem
load TESTE_626.lvm;
y = TESTE_626;
data = y - mean(y);
N = length(data); % Número de amostras
t = (0:N-1)/Fa; % Vetor de tempo
df = Fa/N;
dt = 1/Fa;
T = N*dt;

% Calcular o espectro via FFT
Y = fft(data);
P2 = abs(Y/N); % Magnitude normalizada
P1 = P2(1:floor(N/2)+1); % Espectro unilateral
P1(2:end-1) = 2*P1(2:end-1); % Ajustar amplitudes
f = Fa*(0:(N/2))/N; % Vetor de frequências

% Encontrar picos no espectro
[amps, picos] = findpeaks(P1, f, 'MinPeakHeight', 0.01, 'MinPeakDistance',
5);

% Exibir resultados
disp('Frequências e Amplitudes dos Picos:');
if isempty(amps)
    disp('Nenhum pico encontrado com os parâmetros especificados.');
```

```
else
    for i = 1:length(amps)
        fprintf('Pico %d: Frequência = %.2f Hz, Amplitude = %.6f\n', i,
picos(i), amps(i));
        vetor = picos(i);
    end
end

% Plotar espectro com picos
figure(1)
plot(t, data)
grid on
title('Domínio do Tempo')
xlabel('tempo (s)')
ylabel('Amplitude (g)')

figure(2)
plot(f, P1, 'LineWidth', 1.5);
hold on;
plot(picos, amps, 'r*', 'MarkerSize', 10, 'LineWidth', 2);
xlabel('Frequência (Hz)');
```

```

ylabel('Amplitude');
title('Espectro de Frequência com Picos Identificados');
grid on;
zoom xon; % Permitir zoom no eixo x

if isempty(picos)
    error('Não existem picos segundo os parâmetros estabelecidos.');
```

end

```

if any(isnan(picos)) || any(isinf(picos))
    error('Não existem picos.');
```

end

```

% Itera sobre cada valor de minPeakDistance
for i = 1:length(picos)
    fprintf('Processando Frequências de Amostragem(%d): %.2f\n', i,
picos(i));

    % Gera o vetor de incrementos
    a = 0.01:0.01:(picos(i) + 0.05);

    % Calcula soma e subtração de forma vetorizada
    soma = picos(i) + a;
    subtracao = picos(i) - a;

    % Seleciona os primeiros 5 valores de soma e subtração
    soma_5 = soma(1:min(5, length(soma)));
    subtracao_5 = subtracao(1:min(5, length(subtracao)));

    % Lista de valores a processar: original, soma (5 primeiros), subtração
    (5 primeiros)
    valores = [picos(i), soma_5, subtracao_5];

    % Processa cada valor
    for j = 1:length(valores)
        fsinal = valores(j);
        fprintf('\nCalculando para fsinal = %.2f\n', fsinal);

        % Inicializa Fa para cada valor
        Fa = 500; % Valor inicial, ajuste conforme necessário
        sinal = 1/fsinal;
        df = Fa/N;
        r = mod(fsinal, df);

        % Lógica para encontrar Fa ideal
        if r ~= 0
            while r ~= 0
                Fa = Fa + 1;
                df = Fa/N;
                r = mod(fsinal, df);
                if r == 0
                    fprintf('A frequência de amostragem ideal é: %d\n', Fa);
                end
            end
        else
            fprintf('A frequência de amostragem ideal é: %d\n', Fa);
        end
    end
end
end
```

## APÊNDICE II – Programa MATLAB para Maior Amplitude

```
% Programa para encontrar o maior valor de amplitude e sua frequência
correspondente
clc

% Inicializa vetores para armazenar as 10 frequências e amplitudes
frequencias = zeros(1, 12);
amplitudes = zeros(1, 12);

% Solicita os 10 valores de frequência ao usuário
for i = 1:12
    frequencias(i) = input(['Digite o ', num2str(i), 'º valor de frequência:
    ']);
end

% Solicita as amplitudes correspondentes às frequências
for i = 1:12
    amplitudes(i) = input(['Disponha o valor da amplitude correspondente à
    frequência ', num2str(frequencias(i)), ': ']);
end

% Encontra a maior amplitude e seu índice
[maior_amplitude, indice] = max(amplitudes);

% Obtém a frequência correspondente à maior amplitude
frequencia_correspondente = frequencias(indice);

% Exibe o resultado
fprintf('A maior amplitude é: %.5f, correspondente à frequência: %.2f\n',
    maior_amplitude, frequencia_correspondente);
```